

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E SANEAMENTO
AMBIENTAL

JULIANA ANDRADE CAMPOS

MODELAGEM HIDROSEDIMENTOLÓGICA EM ESCALA ESPACIAL E TEMPORAL
NA BACIA DO ALTO PARAGUAI UTILIZANDO REDES NEURAS ARTIFICIAIS

PORTO ALEGRE

2019

JULIANA ANDRADE CAMPOS

MODELAGEM HIDROSEDIMENTOLÓGICA EM ESCALA ESPACIAL E TEMPORAL
NA BACIA DO ALTO PARAGUAI UTILIZANDO REDES NEURAIIS ARTIFICIAIS

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul, como requisito parcial à obtenção do grau de Mestre em Recursos Hídricos e Saneamento Ambiental.

Orientador: Prof. Dr. Olavo Correa Pedrollo

PORTO ALEGRE

2019

JULIANA ANDRADE CAMPOS

MODELAGEM HIDROSEDIMENTOLÓGICA EM ESCALA ESPACIAL E TEMPORAL
NA BACIA DO ALTO PARAGUAI UTILIZANDO REDES NEURAS ARTIFICIAIS

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul, como requisito parcial à obtenção do grau de Mestre em Recursos Hídricos e Saneamento Ambiental.

BANCA EXAMINADORA:

Olavo Correa Pedrollo, Dr (Orientador, IPH/UFRGS)

Nilza Maria dos Reis Castro, Dra (IPH/UFRGS)

Vanessa Sari, Dra (UFSM)

Ibraim Fantin da Cruz, Dr (UFMT)

Porto Alegre, 01 de março de 2019.

Aos meus pais, Meiry e Leco, pelo amor, apoio,
compreensão e por me ensinarem a sempre lutar
pelos meus sonhos...

Dedico.

AGRADECIMENTOS

A seguir, meus sinceros agradecimentos.

Começo agradecendo ao meu orientador, Prof. Olavo Pedrollo, por todo o apoio dado nesta pesquisa; pela amizade sincera; pela imensa alegria e dedicação em transmitir seus conhecimentos; pela motivação em momentos difíceis; pela constante inspiração e entusiasmo por novos conhecimentos; e por ter me conduzido tão bem durante o desenvolvimento desta pesquisa. Professor Olavo, minha sincera e eterna gratidão.

Ao Prof. Ibraim Fantin, por ter me inspirado e encorajado a estudar no IPH; pela inspiração e contribuições na definição desta pesquisa; por ter me indicado o Prof. Olavo para ser meu orientador; pelo fornecimento de diversos dados que nortearam esta pesquisa; pela sincera amizade e parceria de sempre; e por aceitar ser examinador deste trabalho.

Ao Professor Joel Goldenfum, por ter me acolhido no projeto Tubarão; pelos conhecimentos transmitidos ao longo das atividades do Projeto; pela amizade e confiança a mim depositada.

A Prof.^a Vanessa e Prof.^a Nilza, pelas grandes contribuições e sugestões para melhoria desta pesquisa durante a aprovação do plano de dissertação; e por aceitarem participar como examinadoras desta pesquisa. Me sinto lisonjeada em contar com duas mulheres inspiradoras como membras da banca.

Meus sinceros agradecimentos aos colegas da sala do projeto Tubarão, Hidrologia, HGE e demais grupos de pesquisa, pela amizade, companheirismo, ajuda e discussões. Um agradecimento especial aos amigos Dani, Fran V, Fran Z, Benício, Juan Carlos, Camila, Ferzinha e Débs, pela união e apoio de sempre. Vocês são maravilhosos.

Um agradecimento especial para Fer, pela linda amizade que criamos, por ter me acolhido tão bem em Porto Alegre, me dando conselhos e dicas, sempre do meu lado em todos os momentos. Fer, minha sincera gratidão.

Agradeço a CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pela bolsa de mestrado concedida.

Sou muito grata a minha família – minha mãe Meiry, meu pai Leco, minha irmã Tais, minhas sobrinhas Maria Julia e Maria Helena – vocês são a razão de tudo. Graças a vocês eu tive e tenho a oportunidade de viver com alegria.

Acima de tudo, quero agradecer a pessoa que mais esteve do meu lado durante todo o desenvolvimento deste trabalho, sempre me ajudando nas mais diversas dificuldades, lendo meus textos, me ajudando a programar, me ajudando com inglês, dando ideias e compartilhando a vida de uma forma tão leve. Erik, você foi fundamental para que eu chegasse até aqui. Obrigada pelo amor, carinho, respeito e companheirismo de sempre.

Por fim, agradeço todas as pessoas não mencionadas aqui, mas que foram importantes para minha formação e no desenvolvimento deste trabalho. Muito Obrigada!

*“We still talk in terms of conquest.
We still haven’t become mature
enough to think in terms of
ourselves as a tiny part of a vast
and incredible universe.”*

(Rachel Carson)

RESUMO

A estimativa da concentração de sedimentos em suspensão (CSS) em bacias hidrográficas é uma importante ferramenta de auxílio à elaboração de projetos de engenharia e na gestão dos recursos hídricos. A natureza complexa verificada nas relações hidrossedimentológicas pode ser modelada por meio de técnicas capazes de ajustar relações altamente não lineares, tais como as redes neurais artificiais (RNA), que são um tipo de inteligência artificial bastante explorado no âmbito das ciências ambientais. Neste estudo, objetivou-se desenvolver diversas RNAs para prever a CSS na bacia do Alto Paraguai, a partir de duas abordagens de modelagem, sendo elas: espacial e temporal, e que deram origem a dois artigos. No primeiro artigo, foi empregada uma abordagem espacial para contornar a escassez de dados observados na bacia do Alto Paraguai, utilizando 23 estações com dados de CSS. Foram testados como entradas do modelo dados de turbidez, vazão, tipo de solo, uso e ocupação do solo, área de drenagem, declividade média da bacia, chuva e médias móveis ponderadas exponencialmente das chuvas passadas (EWMA). O modelo em que nenhuma variável de entrada foi descartada (M01) obteve um coeficiente de Nash-Sutcliffe (NS) igual a 0,835 no treinamento e 0,794 na verificação. O modelo alternativo (M19), porém, em que foram desconsideradas as variáveis cuja correlação com sedimentos não foi significativa, considerando o nível de significância de 5%, obteve o melhor desempenho (NS igual a 0,856 no treinamento e 0,832 na verificação). No segundo artigo, as RNAs foram utilizadas para estimar a CSS, de forma temporal e pontual, na estação fluviométrica de Cuiabá. Utilizou-se como entradas dos modelos dados de níveis da própria estação fluviométrica, dados de chuvas pontuais oriundos da estação pluviométrica de Cuiabá e dados de chuvas totais na bacia, obtidos do produto de precipitações MERGE, que agrega informações de diversos postos pluviométricos, acrescido de informações obtidas por satélites. Todas as variáveis de entrada são diárias, assim, as estimativas da CSS feitas pelos modelos pontuais desenvolvidos também são diárias, possibilitando a obtenção de séries mais longas da CSS na estação fluviométrica de Cuiabá, que, atualmente, dispõe de 80 registros desta variável. A baixa disponibilidade de dados de CSS na estação fluviométrica de Cuiabá inviabiliza o uso da validação cruzada, e, por isso, os modelos de RNA do segundo artigo foram treinados com uma técnica de validação por reamostragem, na qual menos registros são necessários para evitar o superajustamento da rede. Os resultados dos modelos foram satisfatórios, sendo que o melhor modelo, cujas entradas foram selecionadas a partir de um critério de exclusão de variáveis redundantes, baseado nas correlações de Spearman maior que 0,99, obteve o melhor desempenho, com coeficiente de Nash-Sutcliffe de $NS = 0,777$ no treinamento e $NS = 0,776$ na verificação. Verificou-se nesta pesquisa que é possível estabelecer uma relação entre a CSS e as ocorrências recentes de chuvas e de níveis, para uma seção fluvial com dados suficientes. Quando não existem dados suficientes em uma única seção, porém, ainda é possível produzir modelos para a estimativa de CSS, a partir da abordagem regional, desde que se disponha de dados de turbidez, e inserindo características físicas do ponto de interesse.

Palavras-chave: bacia hidrográfica do Alto Paraguai, Pantanal, estimativa regional, estimativa pontual, modelagem hidrossedimentológica

ABSTRACT

The estimation of suspended sediment concentration (SSC) in hydrographic basins is an important tool to support engineering projects and the management of water resources. The complex nature of hydrosedimentological relationships can be modeled by techniques capable of fitting highly nonlinear relationships, such as artificial neural networks (ANNs), which are a type of artificial intelligence that is widely exploited in the environmental sciences. In this study, we aimed to develop several ANNs to predict SSC in the Upper Paraguay basin, based on two modeling approaches: spatial and temporal, which gave rise to two articles. In the first, a spatial approach was used to overcome the scarcity of data observed in the Alto Paraguay River Basin, using 23 stations with CSS data. The variables turbidity, flow rate, soil type, soil use and occupation, drainage area, mean basin slope, rainfall and exponentially weighted moving rainfall averages (EWMA) were tested as inputs of the model. The model in which no input variable was discarded (M01) obtained a Nash-Sutcliffe (NS) coefficient equal to 0.835 in the training and 0.794 in the verification. The alternative model (M19), however, in which the variables whose correlation with sediments was not significant, considering the significance level of 5%, obtained the best performance (NS equal to 0.856 in training and 0.832 in the verification). In the second article, the RNAs were used to estimate the CSS, in a punctual basis, in the fluviometric station of Cuiabá. Considering as input for the models, series of levels of the fluviometric station itself, series of rainfall from Cuiabá pluviometric station and data of total rainfall in the basin, obtained from the MERGE precipitation product, which aggregates information from several pluviometric stations, plus information obtained by satellites. All the input variables are daily, so the CSS estimates made by the developed point models are also daily, making it possible to obtain longer CSS series at the Cuiabá fluviometric station, which currently has 80 records of this variable. The low availability of CSS data in the Cuiabá fluviometric station makes the use of cross validation unfeasible and, therefore, the RNA models of the second article were trained with a resampling validation technique, in which fewer records are needed to avoid network overfitting. The results of the models were satisfactory, and the best model, whose inputs were selected from a redundant variables exclusion criterion, based on Spearman correlations higher than 0.99, obtained the best performance, with Nash-Sutcliffe coefficient of $NS = 0.777$ in training and $NS = 0.766$ in the verification. This research verified that it is possible to establish a relationship between CSS and recent occurrences of rainfall and levels for a fluvial section with sufficient data. When there is not enough data in a single section, however, it is still possible to produce models for the estimation of CSS from the regional approach, if it has turbidity data, and inserting physical characteristics of the point of interest.

Keywords: Upper Paraguay river basin, Pantanal, regional estimation, punctual estimation, hydrosedimentological modeling.

SUMÁRIO

1.	APRESENTAÇÃO	1
1.1.	Introdução	1
1.2.	Hipóteses.....	4
1.3.	Objetivo	5
1.4.	Organização do Trabalho	5
1.5.	Referências Bibliográficas	6
2.	REVISÃO BIBLIOGRÁFICA.....	13
2.1.	Processos Hidrossedimentológicos em Bacias Hidrográficas	13
2.1.1.	Erosão	13
2.1.2.	Transporte e Deposição de Sedimentos.....	16
2.1.3.	Produção de Sedimentos em Bacias Hidrográficas	18
2.2.	Concentração de Sedimentos em Suspensão	19
2.2.1.	Relação entre CSS e Outras Variáveis	19
2.3.	Redes Neurais Artificiais em Aplicações Hidrossedimentológicas.....	22
2.4.	Referências bibliográficas.....	26
3.	REGIONAL ESTIMATION OF SUSPENDED SEDIMENT CONCENTRATION IN THE PANTANAL (BRAZIL) USING ARTIFICIAL NEURAL NETWORKS.....	30
3.1.	Introduction	31
3.2.	Artificial Neural Networks.....	33
3.3.	Materials and Methods	36
3.3.1.	Study area	36
3.3.2.	Data.....	37
3.3.3.	Input and output model variables	40
3.3.4.	Model development	42
3.3.5.	Performance statistics	43
3.4.	Results and Discussion	43
3.4.1.	Analysis of descriptive statistics	43

3.4.2.	Regional estimation of suspended sediment concentration using ANN based models	46
3.5.	Conclusions.....	51
3.6.	References.....	52
4.	ESTIMATIVA TEMPORAL DA CONCENTRAÇÃO DE SEDIMENTOS SUSPENSOS UTILIZANDO REDES NEURAIS ARTIFICIAIS NA BACIA DO RIO CUIABÁ.....	59
4.1.	Introdução	60
4.2.	Modelos de Redes Neurais Artificiais	62
4.3.	Materiais e Métodos.....	65
4.3.1.	Área de Estudo	65
4.3.2.	Dados	69
4.3.3.	Variáveis de Entrada e de Saída dos modelos	71
4.3.4.	Construção do modelo temporal de estimativa da CSS.....	73
4.3.5.	Estatísticas de Desempenho.....	76
4.4.	Resultados e Discussões	77
4.4.1.	Análise das variáveis de entrada.....	77
4.4.2.	Modelos de RNAs para estimativa da CSS na estação de Cuiabá.....	81
4.5.	Conclusões	84
4.6.	Referências Bibliográficas	85
5.	CONSIDERAÇÕES FINAIS DA DISSERTAÇÃO.....	92

1. APRESENTAÇÃO

1.1. Introdução

A água é o motor do ciclo hidrossedimentológico, participando dos processos de intemperismo e erosão do substrato rochoso e pedológico, assim como transportando e depositando os sedimentos por meio do escoamento superficial, sobretudo pelo escoamento fluvial. Por intermédio dos rios, os sedimentos percorrem grandes distâncias, oscilando entre transporte e deposição, conforme variações da energia do escoamento fluvial e o regime sazonal dos diferentes rios, finalizando sua trajetória com a deposição em uma bacia sedimentar continental ou marítima (CARVALHO, 2008).

A erosão do solo é um fenômeno de grande importância para o meio ambiente e os recursos naturais, pois os sedimentos gerados nesse processo podem ocasionar o assoreamento de rios e de reservatórios, o aumento da turbidez nas águas e a redução da qualidade do terreno e da produtividade das culturas, resultando na degradação da terra. Ainda, a presença dos sedimentos pode ser importante para alguns ecossistemas, pois também são responsáveis pelo transporte de nutrientes, importantes para diversos organismos (ESTEVES, 1998).

A ação antrópica altera consideravelmente as taxas de erosão, podendo acarretar, além dos prejuízos ambientais, prejuízos sociais e econômicos a vários quilômetros de distância dos locais de onde os sedimentos foram erodidos (FAGUNDES, 2018; JENSEN, 2009).

O monitoramento da produção de sedimentos no Brasil é realizado a partir do conhecimento da carga de sedimentos transportada pelos rios, que pode ser dividida entre carga de sedimentos do leito e carga de sedimentos em suspensão, sendo esta última mais fácil de ser medida (CARVALHO, 2008). A descarga sólida em suspensão é geralmente calculada a partir dos dados de vazão e concentração de sedimentos em suspensão (CSS) na seção transversal do rio.

Embora a CSS seja mensurada em diversas bacias brasileiras, a frequência de amostragem normalmente é baixa (escala de tempo mensal ou maior) e a distribuição espacial das medições é insuficiente. A baixa disponibilidade espacial e temporal de dados de sedimentos dificulta a descrição quantitativa dos processos hidrossedimentológicos, e prejudica o desenvolvimento de estratégias, em diferentes níveis, para o adequado manejo dos recursos hídricos. Neste sentido, diversos estudos vêm sendo desenvolvidos para melhorar as informações de sedimentos nas

bacias hidrográficas com monitoramento insuficiente (ATIEH et al., 2015; HENG; SUETSUGI, 2013, 2015; SIVAPALAN et al., 2003).

Técnicas de determinação indireta da concentração de sedimentos em suspensão (CSS) são amplamente utilizadas, tais como as curvas-chave de sedimentos, à partir da relação entre descarga líquida e descarga sólida (HENG; SUETSUGI, 2014; ZHANG et al., 2012), relação entre turbidez e CSS (SARI; CASTRO; PEDROLLO, 2017; TANANAEV; DEBOLSKIY, 2014), bem como a partir de abordagens de regionalização, que consiste na transferência de informações de locais monitorados para outros locais de interesse (HENG; SUETSUGI, 2015; MOHAMOUD, 2014; SIVAPALAN et al., 2003; TRENOUTH; GHARABAGHI, 2015; ZHANG; CHIEW, 2009).

A inteligência artificial vem sendo amplamente utilizada no âmbito dos recursos hídricos, a exemplo das redes neurais artificiais (RNA), que consiste em uma poderosa ferramenta da modelagem baseada em dados, capaz de aprender com exemplos, mesmo sem física explícita, e com precisão igual ou maior que abordagens baseadas na física (NOURANI; KALANTARI; BAGHANAM, 2012). Devido a sua elevada capacidade de ajustar relações não lineares, as RNAs vem sendo utilizadas na hidrologia, incluindo a modelagem chuva-vazão (por exemplo, GIUSTOLISI; LAUCELLI, 2005; MINNS; HALL, 1996; NOURANI; KOMASI; MANO, 2009; TOKAR; JOHNSON, 1999), previsão de vazão (CIGIZOGLU, 2003a, 2003b; CIGIZOGLU; KISI, 2006; DORNELLES; GOLDENFUM; PEDROLLO, 2013) e na modelagem de sedimentos (AFAN et al., 2014; ATIEH et al., 2015; BUYUKYILDIZ; KUMCU, 2017; KISI; OZKAN; AKAY, 2012; NOURANI; KALANTARI, 2010; NOURANI; KALANTARI; BAGHANAM, 2012; SINGH et al., 2013).

Esta pesquisa foi desenvolvida na bacia hidrográfica do Alto Paraguai, que é uma das 12 regiões hidrográficas brasileiras. Esta bacia possui grande importância no cenário ambiental em função da presença do bioma Pantanal, onde as extensas planícies inundáveis, a baixa densidade demográfica e a regularidade dos pulsos de cheia favorecem a presença de grande biodiversidade (ALLASIA et al., 2004).

Conforme recomendações da Organização Mundial de Meteorologia (WMO, 2008), regiões montanhosas devem apresentar densidade de estações sedimentométricas igual ou inferior à 6.700 km² de área de drenagem por estação, e regiões de planície igual ou inferior à 8.500 km². Com relação à frequência das medições de sedimentos, não existe uma recomendação específica, pois cada região se comporta de maneira distinta, no entanto, em

geral, a maior parte das bacias produzem mais sedimentos nos períodos chuvosos. Então, estes períodos devem apresentar maior frequência de medições. Mesmo sendo uma importante região hidrográfica, a bacia do Alto Paraguai carece de estações que monitorem a concentração de sedimentos. Além da baixa densidade (44 estações para aproximadamente 360.000 km²), os dados são coletados com frequência mensal ou maior.

A bacia hidrográfica do Alto Paraguai possui uma diversidade de solos, características topográficas e usos da terra que refletem em águas que vão desde transparentes a turvas, a depender da região. Embora, nem sempre a alta concentração de sedimentos culmine em alta turbidez. Naturalmente, as porções altas da bacia contribuem com sedimentos para a planície, mas alguns estudos na bacia apontam um aceleração da entrada de sedimentos, o que culmina em casos de assoreamento do leito, como no rio Taquari (Galdino et al. 2005).

Outro fator que chama a atenção nessa bacia é o crescente aumento de pequenos empreendimentos hidrelétricos na região do planalto. Em 2016, a bacia já apresentava 44 empreendimentos em operação, e mais outros 118 em estágio de licitação (FANTIN-CRUZ et al., 2016).

Reservatórios artificiais criam barreiras à conectividade longitudinal do rio, alterando o regime hidrológico e introduzindo mudanças físicas, químicas e biológicas na água represada, que pode estender-se bem à jusante do reservatório. O transporte fluvial de material particulado e nutrientes associados é, frequentemente, reduzido pela sedimentação do reservatório, causando uma cascata de impactos à jusante, como o aumento da transparência da água, redução da disponibilidade de nutrientes e mudanças na geomorfologia dos canais e várzeas (FANTIN-CRUZ et al., 2016).

A deposição de sedimentos nos rios da bacia hidrográfica do Alto Paraguai com empreendimentos em operação tem sido observada tanto em UHE como em PCH, no entanto, exceto pelos estudos de Fantin-Cruz et al., (2015, 2016); Zeilhofer; Moura (2009), que foram aplicados em empreendimentos hidrelétricos específicos, pouco se sabe sobre os efeitos dessas barragens na qualidade e na quantidade de águas que chegam ao Pantanal, especialmente as muitas represas e os reservatórios menores que tem sido recentemente construídos.

Neste contexto, esta pesquisa buscou oferecer novas contribuições para um melhor entendimento da dinâmica hidrossedimentológica em bacias hidrográficas com baixa disponibilidade de dados de sedimentos, utilizando como área de estudo a bacia hidrográfica do Alto Paraguai, que dispõe, ainda que de forma limitada, de dados de CSS, e que também

desperta grande interesse em gestores sobre o conhecimento da dinâmica hidrossedimentológica desta região, principalmente em função do aumento, ao longo dos últimos anos, do número de empreendimentos hidrelétricos de pequeno porte no Planalto e seus possíveis impactos cumulativos no Pantanal.

As RNA foram aplicadas para estimar a CSS por meio de duas abordagens distintas e complementares: espacial e temporal. A abordagem espacial desenvolvida possibilita a regionalização das informações para trechos de rio sem dados de CSS, a partir de outras variáveis mais frequentes que os sedimentos, como a turbidez, a precipitação, o nível d'água e características físicas do ponto de interesse; e a abordagem temporal desenvolvida permite a obtenção de séries contínuas (diárias) de CSS em postos com poucos dados, a partir de outras variáveis de monitoramento contínuo, como o nível d'água e a precipitação.

1.2. Hipóteses

A primeira hipótese deste trabalho é que a união de dados de CSS de diversas estações sedimentométricas de uma mesma bacia hidrográfica, com baixa frequência amostral, aumenta o número de registros disponíveis, e assim, viabiliza o desenvolvimento de modelos de regionalização da CSS, a partir das RNA, e utilizando variáveis de entrada de ocorrência simultânea, cujas informações estão relacionadas à CSS, como as vazões, os níveis e a turbidez; bem como variáveis que estão relacionadas à erosão da bacia e ao transporte de sedimentos, como as precipitações; e também variáveis físicas que caracterizam a dinâmica hidrossedimentológica da bacia.

A segunda hipótese é que, para um único posto fluviométrico, é possível produzir estimativas eficientes da CSS, em escala temporal diária, a partir de modelos de RNA, utilizando somente variáveis de entrada que são monitoradas diariamente, tais como os níveis d'água e as precipitações.

E a terceira hipótese é que as médias móveis exponencialmente ponderadas de variáveis como as precipitações e os níveis, são capazes de promover uma síntese de informações do passado recente, na forma de um valor representativo, e contribuem para uma melhor estimativa da CSS nos modelos de RNA.

1.3. Objetivo

O objetivo desta pesquisa é verificar o potencial das redes neurais artificiais no desenvolvimento de modelos de estimativa da CSS, dentro da região hidrográfica do Alto Paraguai, em escala de modelagem regional e temporal, tendo como entradas variáveis simultâneas que são correlacionadas com a CSS, como a turbidez e a vazão, além de outras variáveis que afetam a erosão e o transporte de sedimentos, como as precipitações atuais e antecedentes e as variáveis físicas que caracterizam a bacia hidrográfica.

Algumas questões a serem respondidas no decorrer desta pesquisa são:

- 1) É possível fazer uma estimativa da CSS em diversos pontos da bacia do Alto Paraguai, a partir de uma abordagem regional, utilizando RNA?
- 2) Qual a contribuição do uso da turbidez como variável de entrada dos modelos regionais, associada às precipitações atuais e antecedentes e às características físicas da bacia, para a estimativa da CSS?
- 3) O uso de médias móveis ponderadas exponencialmente em dados de chuva e níveis d'água pode produzir melhorias nas estimativas de CSS?
- 4) É possível obter um modelo temporal que estime a CSS em escala diária, utilizando como entrada variáveis que são monitoradas na mesma escala?

Estas questões são respondidas a partir de dois artigos, sendo o primeiro voltado para a modelagem espacial em toda a região hidrográfica do Alto Paraguai, e o segundo voltado para modelagem temporal, em um único posto, na sub-bacia do rio Cuiabá.

1.4. Organização do Trabalho

Após a apresentação da justificativa, hipóteses e objetivos desta pesquisa, o presente documento aborda no segundo Capítulo uma revisão bibliográfica geral, comentando os principais conceitos, fenômenos e literaturas relacionadas ao assunto do trabalho. O Capítulo 3 apresenta o primeiro artigo desta pesquisa, que está escrito em inglês, e refere-se à modelagem com RNA em escala espacial, para estimativa da CSS na bacia do Alto Paraguai. Este artigo foi recentemente submetido na revista *Water Resources Management*. Em seguida, no Capítulo 4, é apresentado o segundo artigo, que trata da modelagem em escala temporal para estimativa diária da CSS na sub-bacia do rio Cuiabá. E no item final, são apresentadas as conclusões gerais da pesquisa.

1.5. Referências Bibliográficas

ADAMOWSKI, Jan; SUN, Karen. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. **Journal of Hydrology**, [s. l.], v. 390, n. 1–2, p. 85–91, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2010.06.033>>

AFAN, Haitham Abdulmohsin et al. ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. **Water Resources Management**, [s. l.], v. 29, n. 4, p. 1231–1245, 2014.

AGARWAL, Avinash et al. Simulation of Runoff and Sediment Yield using Artificial Neural Networks. **Biosystems Engineering**, [s. l.], v. 94, n. 4, p. 597–613, 2006.

AGARWAL, Avinash; SINGH, R. D. Runoff modelling through back propagation artificial neural network with variable rainfall-runoff data. **Water Resources Management**, [s. l.], v. 18, n. 3, p. 285–300, 2004.

ALLASIA, Daniel G. et al. **Modelo Hidrológico da Bacia do Alto Paraguai**. Porto Alegre-RS: Editora Rios Vivos, 2004.

ASCE. Artificial Neural Networks in Hydrology. I: Preliminary Concepts. In: **Journal Of hydrologic engineering**., 2000.

ATIEH, M. et al. Integrative neural networks model for prediction of sediment rating curve parameters for ungauged basins. **Journal of Hydrology**, [s. l.], v. 531, p. 1095–1107, 2015.

BAO, Zhenxin et al. Comparison of regionalization approaches based on regression and similarity for predictions in ungauged catchments under multiple hydro-climatic conditions. **Journal of Hydrology**, [s. l.], v. 466–467, p. 37–46, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.07.048>>

BAYRAM, Adem et al. Prediction of suspended sediment concentration from water quality variables. **Neural Computing and Applications**, [s. l.], v. 24, n. 5, p. 1079–1087, 2014. Disponível em: <<http://link.springer.com/10.1007/s00521-012-1333-3>>

BAYRAM, Adem; KANKAL, Murat; ÖNSOY, Hızir. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. **Environmental Monitoring and Assessment**, [s. l.], v. 184, n. 7, p. 4355–4365, 2012.

BERTONI, Jose; NETO, Francisco Lombardi. Conservação do Solo. In: 8ª ed. [s.l.] : Icone, 2006. p. 360.

BHATTACHARJYA, Rajib Kumar; CHAURASIA, Sandeep. Geomorphology Based Semi-Distributed Approach for Modelling Rainfall-Runoff Process. **Water Resources Management**, [s. l.], v. 27, n. 2, p. 567–579, 2013.

BONAN, Gordon. **Ecological Climatology**. 3. ed. Cambridge: Cambridge University Press, 2016.

BRAVO, J. M. et al. Coupled Hydrologic-Hydraulic Modeling of the Upper Paraguay River

Basin. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 5, p. 635–646, 2012. Disponível em: <<http://ascelibrary.org/doi/10.1061/%28ASCE%29HE.1943-5584.0000494>>

BURROUGH, Peter A.; MCDONNELL, Rachael A. Data models and axioms: formal abstractions of reality. **Principles of geographical information systems**, [s. l.], p. 17–34, 1998. Disponível em: <<http://www.jstor.org/stable/144481?origin=crossref>>

BUYUKYILDIZ, Meral; KUMCU, Serife Yurdagul. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. **Water Resources Management**, [s. l.], v. 31, n. 4, p. 1343–1359, 2017.

CARVALHO, N. **Hidrossedimentologia prática**. 2^a ed. Rio de Janeiro: Interciência, 2008.

CHAI, Soo-See et al. Use of Soil Moisture Variability in Artificial Neural Network Retrieval of Soil Moisture. **Remote Sensing**, [s. l.], v. 2, n. 1, p. 166–190, 2009. Disponível em: <<http://www.mdpi.com/2072-4292/2/1/166/>>

CIGIZOGLU, Hikmet Kerem. Estimation, forecasting and extrapolation of river flows by artificial neural networks. **Hydrological Sciences Journal**, [s. l.], v. 48, n. 3, p. 349–362, 2003. a.

CIGIZOGLU, Hikmet Kerem. Incorporation of ARMA models into flow forecasting by artificial neural networks. **Environmetrics**, [s. l.], v. 14, n. 4, p. 417–427, 2003. b.

CIGIZOGLU, Hikmet Kerem; KISI, Özgür. Methods to improve the neural network performance in suspended sediment estimation. **Journal of Hydrology**, [s. l.], v. 317, n. 3–4, p. 221–238, 2006.

CROWDER, D. W.; DEMISSIE, M.; MARKUS, M. The accuracy of sediment loads when log-transformation produces nonlinear sediment load-discharge relationships. **Journal of Hydrology**, [s. l.], v. 336, n. 3–4, p. 250–268, 2007.

D. N. MORIASI et al. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. **Transactions of the ASABE**, [s. l.], v. 50, n. 3, p. 885–900, 2007.

DORNELLES, Fernando; GOLDENFUM, Joel Avruch; PEDROLLO, Olavo Correa. Artificial Neural Network Methods Applied to Forecasting River Levels. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 18, p. 45–54, 2013.

EMBRAPA. **Monitoramento das alterações da cobertura vegetal e uso do Solo na Bacia do Alto Paraguai – Porção Brasileira – Analysis period: 2012 to 2014**. 2015. Disponível em: <https://d3nehc6yl9qzo4.cloudfront.net/downloads/publicacao_bap_sumarioexecutivo_2012_2014_web.pdf>. Acesso em: 2 abr. 2018.

ESTEVEES, Francisco De Assis. Fundamentos de Limnologia. In: **Interciência**. 2. ed. Rio de Janeiro. p. 226.

FAGUNDES, Hugo de Oliveira. **Modelagem Hidrossedimentológica de Grandes Bacias com Apoio de Dados In Situ e Sensoriamento Remoto**. 2018. Universidade federal do Rio

Grande do Sul, [s. l.], 2018.

FANTIN-CRUZ, Ibraim et al. Historical reconstruction of floodplain inundation in the Pantanal (Brazil) using neural networks. **Journal of Hydrology**, [s. l.], v. 399, n. 3–4, p. 376–384, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2011.01.014>>

FANTIN-CRUZ, Ibraim et al. Effects of a diversion hydropower facility on the hydrological regime of the Correntes River, a tributary to the Pantanal floodplain, Brazil. **Journal of Hydrology**, [s. l.], v. 531, p. 810–820, 2015.

FANTIN-CRUZ, Ibraim et al. Changes in river water quality caused by a diversion hydropower dam bordering the Pantanal floodplain. **Hydrobiologia**, [s. l.], v. 768, n. 1, p. 223–238, 2016.

FASHI, Fereshte Haghghi. Evaluation of adaptive neural-based fuzzy inference system approach for estimating saturated soil water content. **Modeling Earth Systems and Environment**, [s. l.], v. 2, n. 4, p. 1–6, 2016. Disponível em: <<http://link.springer.com/10.1007/s40808-016-0255-y>>

FREEMAN, James A.; SKAPURA, David M. Neural Networks: Algorithms, Applications and Programming Techniques. In: **Addison-Wesley Publishing Company**. California. v. 7p. 89–124.

GIUSTOLISI, O.; LAUCELLI, D. Improving generalization of artificial neural networks in rainfall–runoff modelling. **Hydrological Sciences Journal**, [s. l.], v. 50, n. 3, p. 37–41, 2005.

HAIMANN, Marlene et al. An integrated suspended sediment transport monitoring and analysis concept. **International Journal of Sediment Research**, [s. l.], v. 29, n. 2, p. 135–148, 2014. Disponível em: <[http://dx.doi.org/10.1016/S1001-6279\(14\)60030-5](http://dx.doi.org/10.1016/S1001-6279(14)60030-5)>

HARRINGTON, Seán T.; HARRINGTON, Joseph R. An assessment of the suspended sediment rating curve approach for load estimation on the Rivers Bandon and Owenabue, Ireland. **Geomorphology**, [s. l.], v. 185, p. 27–38, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.geomorph.2012.12.002>>

HASSAN-ESFAHANI, Leila et al. Spatial Root Zone Soil Water Content Estimation in Agricultural Lands Using Bayesian-Based Artificial Neural Networks and High- Resolution Visual, NIR, and Thermal Imagery. **Irrigation and Drainage**, [s. l.], v. 66, n. 2, p. 273–288, 2017.

HASSAN, Muhammad et al. Development of sediment load estimation models by using artificial neural networking techniques. **Environmental Monitoring and Assessment**, [s. l.], v. 187, n. 11, 2015.

HECHT-NIELSEN, Robert. Theory of the Backpropagation Neural Network. **Proceedings Of The International Joint Conference On Neural Networks**, [s. l.], v. 1, p. 593–605, 1989. Disponível em: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=118638>

HENG, Sokchhay; SUETSUGI, Tadashi. Using Artificial Neural Network to Estimate Sediment Load in Ungauged Catchments of the Tonle Sap River Basin, Cambodia. **Journal of Water Resource and Protection**, [s. l.], v. 05, n. 02, p. 111–123, 2013.

HENG, Sokchhay; SUETSUGI, Tadashi. Comparison of regionalization approaches in parameterizing sediment rating curve in ungauged catchments for subsequent instantaneous sediment yield prediction. **Journal of Hydrology**, [s. l.], v. 512, p. 240–253, 2014.

HENG, Sokchhay; SUETSUGI, Tadashi. Regionalization of sediment rating curve for sediment yield prediction in ungauged catchments. **Hydrology Research**, [s. l.], v. 46, n. 1, p. 26–38, 2015.

HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert. Multilayer feedforward networks are universal approximators. **Neural Networks**, [s. l.], v. 2, n. 5, p. 359–366, 1989.

JAIN, Sharad Kumar. Development of integrated sediment rating curves using ANNs. **Journal of hydraulic engineering**, [s. l.], v. 127, n. 1, p. 30–37, 2001.

JENSEN, John R. Sensoriamento remoto do ambiente: In: [s.l: s.n.]. p. 598.

KAKAEI LAFDANI, E.; MOGHADDAM NIA, A.; AHMADI, A. Daily suspended sediment load prediction using artificial neural networks and support vector machines. **Journal of Hydrology**, [s. l.], v. 478, p. 50–62, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.11.048>>

KASABOV, N. K. Foundations of neural networks, fuzzy systems, and knowledge engineering. In: **Massachusetts institute of technology**. Cambridge. p. 251–358.

KISI, Ozgur; OZKAN, Coskun; AKAY, Bahriye. Modeling discharge–sediment relationship using neural networks with artificial bee colony algorithm. **Journal of Hydrology**, [s. l.], v. 428–429, p. 94–103, 2012.

LIBOS, Marcio Inpes. **Modelagem Hidrológica quali-quantitativa: estudo de caso da bacia do rio Manso-MT**. 2008. Universidade Federal do Rio de Janeiro, [s. l.], 2008.

LIMA, Estevão Bernardes. **modelagem Integrada para Gestão da Qualidade da Água na Bacia do Rio Cuiabá**. 2001. Universidade Federal do Rio de Janeiro, [s. l.], 2001.

MINNS, A. W.; HALL, M. J. Artificial neural networks as rainfall-runoff models. **Hydrological Sciences Journal**, [s. l.], v. 41, n. 3, p. 399–417, 1996.

MOHAMOUD, Yusuf M. Time Series Separation and Reconstruction Technique to Estimate Daily Suspended Sediment Concentrations. **Journal of Hydrologic Engineering**, [s. l.], v. 19, n. 2, p. 328–338, 2014.

MOORE, R. J. **Real-time forecasting of flood events using transfer function noise models: report, Part 2**. Wallingford Institute of Hydrology., , 1980.

MUSIS, Carlos Rozante. **caracterização Climatológica da Bacia do Alto Paraguai**. 1997. Universidade Federal de Mato Grosso, [s. l.], 1997.

MUSTAFA, M. R. et al. River suspended sediment prediction using various multilayer perceptron neural network training algorithms-A case study in Malaysia. **Water Resources Management**, [s. l.], v. 26, n. 7, p. 1879–1897, 2012.

NOURANI, Vahid; KALANTARI, Omid. Integrated Artificial Neural Network for

Spatiotemporal Modeling of Rainfall–Runoff–Sediment Processes. **Environmental Engineering Science**, [s. l.], v. 27, n. 5, p. 411–422, 2010.

NOURANI, Vahid; KALANTARI, Omid; BAGHANAM, Aida Hosseini. Two Semidistributed ANN-Based Models for Estimation of Suspended Sediment Load. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 12, p. 1368–1380, 2012.

NOURANI, Vahid; KOMASI, Mehdi; MANO, Akira. A Multivariate ANN-Wavelet Approach for Rainfall–Runoff Modeling. **Water Resources Management**, [s. l.], v. 23, n. 14, p. 2877–2894, 2009.

OLIVEIRA, Marquis Henrique Campos et al. Estimation of soil water content in watershed using artificial neural networks. **Hydrological Sciences Journal**, [s. l.], v. 62, n. 13, p. 2120–2138, 2017. Disponível em: <<https://doi.org/10.1080/02626667.2017.1364844>>

PAES, Rafael Pedrollo. **Análise da translação da onda de cheia efluente do reservatório da UHE Manso na bacia hidrográfica do rio Cuiabá, Mato Grosso**. 2011. Universidade de São Paulo, [s. l.], 2011.

RAJAEI, Taher. Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers. **Science of the Total Environment**, [s. l.], v. 409, n. 15, p. 2917–2928, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.scitotenv.2010.11.028>>

ROMAN, David C.; VOGEL, Richard M.; SCHWARZ, Gregory E. Regional regression models of watershed suspended-sediment discharge for the eastern United States. **Journal of Hydrology**, [s. l.], v. 472–473, p. 53–62, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.09.011>>

ROZANTE, José Roberto et al. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. **American Meteorological Society**, [s. l.], v. 25, n. 3, p. 885–894, 2010. Disponível em: <<http://journals.ametsoc.org/doi/abs/10.1175/2010WAF2222325.1>>

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, [s. l.], v. 323, n. 6088, p. 533–536, 1986.

SALIHA, A. H. et al. Estimation of flow in ungauged catchments by coupling a hydrological model and neural networks: case study. **Hydrology Research**, [s. l.], v. 42, n. 5, p. 386–400, 2011. Disponível em: <<http://hr.iwaponline.com/cgi/doi/10.2166/nh.2011.157>>

SANTOS, Humberto Gonçalves et al. **Brazilian soil classification system**. 2018. Disponível em: <<https://www.embrapa.br/solos/busca-de-publicacoes/-/publicacao/1094001/brazilian-soil-classification-system>>. Acesso em: 7 abr. 2018.

SARI, Vanessa. **Monitoramento e Modelagem da Produção de Sedimentos em uma Bacia hidrográfica no Noroeste do Rio Grande do Sul**. 2017. Universidade Federal do Rio Grande do Sul, [s. l.], 2017.

SARI, Vanessa; CASTRO, Nilza Maria dos Reis; PEDROLLO, Olavo Correa. Estimate of Suspended Sediment Concentration from Monitored Data of Turbidity and Water Level Using Artificial Neural Networks. **Water Resources Management**, [s. l.], v. 31, n. 15, p. 4909–4923,

2017.

SHELLENBARGER, Gregory G.; WRIGHT, Scott A.; SCHOELLHAMER, David H. A sediment budget for the southern reach in San Francisco Bay, CA: Implications for habitat restoration. **Marine Geology**, [s. l.], v. 345, p. 281–293, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.margeo.2013.05.007>>

SHOAIB, Muhammad et al. A Comparative Study of Various Hybrid Wavelet Feedforward Neural Network Models for Runoff Forecasting. **Water Resources Management**, [s. l.], v. 32, n. 1, p. 83–103, 2018.

SILVA, Alexandre Marco; SCHULZ, Harry Edmar; CAMARGO, Plínio Barbosa. Erosão e Hidrossedimentologia em Bacias Hidrográficas. In: 1. ed. [s.l.] : Rima, 2003. p. 140.

SINGH, A. et al. Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. **Agricultural Water Management**, [s. l.], v. 104, p. 113–120, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2011.12.005>>

SINGH, Ajai et al. Comparison of Artificial Neural Network Models for Sediment Yield Prediction at Single Gauging Station of Watershed in Eastern India. **Journal of Hydrologic Engineering**, [s. l.], v. 18, n. 1, p. 115–120, 2013.

SIVAPALAN, M. et al. IAHS Decade on Predictions in Ungauged Basins (PUB), 2003–2012: Shaping an exciting future for the hydrological sciences. **Hydrological Sciences Journal**, [s. l.], v. 48, n. 6, p. 857–880, 2003.

TALEBIZADEH, Mansour et al. Uncertainty analysis in sediment load modeling using ANN and SWAT model. **Water Resources Management**, [s. l.], v. 24, n. 9, p. 1747–1761, 2010.

TANANAIEV, N. I.; DEBOLSKIY, M. V. Turbidity observations in sediment flux studies: Examples from Russian rivers in cold environments. **Geomorphology**, [s. l.], v. 218, p. 63–71, 2014.

TAYFUR, G. Artificial neural networks for sheet sediment transport - ResearchGate. **Hydrological Sciences Journal**, [s. l.], v. 47, n. 6, p. 879–892, 2002.

TAYFUR, G.; GULDAL, V. Artificial neural networks for estimating daily total suspended sediment in natural streams. **Nordic Hydrology**, [s. l.], v. 37, n. Tayfur 2003, p. 69–79, 2006.

TOKAR, By Sezin; JOHNSON, Peggy. Rainfall-Runoff Modeling Using Artificial Neural Networks. **Journal of Hydrologic Engineering**, [s. l.], v. 4, n. 3, p. 232–239, 1999.

TRAMBLAY, Yves et al. Regional estimation of extreme suspended sediment concentrations using watershed characteristics. **Journal of Hydrology**, [s. l.], v. 380, n. 3–4, p. 305–317, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2009.11.006>>

TRENOUTH, William R.; GHARABAGHI, Bahram. Event-based soil loss models for construction sites. **Journal of Hydrology**, [s. l.], v. 524, p. 780–788, 2015.

VOGL, T. P. et al. Accelerating the convergence of the back-propagation method. **Biological Cybernetics**, [s. l.], v. 59, n. 4–5, p. 257–263, 1988.

WIDROW, B.; HOFF, Me. Adaptive switching circuits. **Ire Wescon Convention Record**, [s. l.], n. 4, p. 96–104, 1960.

WMO, The World Meteorological Organization. **Manual on Sediment Management and Measurement**. [s.l: s.n.].

ZEILHOFER, Peter; MOURA, Rubem Mauro. Hydrological changes in the northern Pantanal caused by the Manso dam: Impact analysis and suggestions for mitigation. **Ecological Engineering**, [s. l.], v. 35, n. 1, p. 105–117, 2009.

ZEROUAL, Ayoub; MEDDI, Mohamed; ASSANI, Ali A. Artificial Neural Network Rainfall-Discharge Model Assessment Under Rating Curve Uncertainty and Monthly Discharge Volume Predictions. **Water Resources Management**, [s. l.], v. 30, n. 9, p. 3191–3205, 2016. Disponível em: <<http://dx.doi.org/10.1007/s11269-016-1340-8>>

ZHANG, Wei et al. Estimating suspended sediment loads in the Pearl River Delta region using sediment rating curves. **Continental Shelf Research**, [s. l.], v. 38, p. 35–46, 2012.

ZHANG, Yongqiang; CHIEW, Francis H. S. Relative merits of different methods for runoff predictions in ungauged catchments. **Water Resources Research**, [s. l.], v. 45, n. 7, 2009.

2. REVISÃO BIBLIOGRÁFICA

2.1. Processos Hidrossedimentológicos em Bacias Hidrográficas

Os processos hidrossedimentológicos estão intimamente vinculados ao ciclo hidrológico e compreendem as etapas de deslocamento, de transporte e de deposição de partículas sólidas presentes nas superfícies das bacias hidrográficas (SILVA; SCHULZ; CAMARGO, 2003).

Carvalho, (2008) define sedimento como uma partícula derivada de uma rocha ou de materiais biológicos pela ação de processos físicos ou químicos, sendo transportada, pela água ou pelo vento, do lugar de origem até os rios e os locais de deposição. Segundo o autor, os processos responsáveis pela sedimentação são muito complexos, abrangendo erosão, deslocamento das partículas (por enxurradas ou outros meios) até os rios, transporte de sedimentos nos cursos d'água, deposição na calha dos rios, lagos e reservatórios e sua compactação.

2.1.1. Erosão

Erosão é o fenômeno de desgaste das rochas e dos solos, com desagregação e deslocamento das partículas por ação da água, do vento ou outros agentes. Os processos erosivos são complexos e dependem de vários fatores, sendo eles os agentes erosivos e o tipo de erosão.

De acordo com Carvalho (2008), existem duas formas de erosão do solo:

- Erosão geológica (ou natural), que consiste no desprendimento das partículas ou materiais (solos, formações superficiais e pedras) e o deslocamento, sem intervenção humana;
- Erosão acelerada (ou antrópica), cuja causa se dá em função de ações humanas. A erosão provocada por catástrofes, como terremotos ou grandes enchentes também são incluídas nesse grupo, apesar de não ser de origem antrópica.

O comportamento de uma bacia hidrográfica em relação aos sedimentos é bastante variável, dependendo, sobretudo, dos agentes erosivos envolvidos nos processos. Estes agentes podem ser de caráter passivo ou ativo. Os agentes ativos são aqueles que afetam diretamente a erosão, sendo eles a chuva, a temperatura, a insolação, o vento, o gelo, a neve, ação dos

microrganismos e a ação humana. Já os passivos são compostos pela topografia, gravidade, tipo de solo, cobertura vegetal e formações superficiais (CARVALHO, 2008).

As precipitações afetam consideravelmente a erosão do solo, sendo esta influência diretamente relacionada à intensidade, à duração e à frequência da chuva, e ainda, ao tamanho e velocidade de queda da gota. Estes dois últimos são bastante expressivos, já que determinam a energia cinética das gotas que impactam a superfície do solo. Em ambientes tropicais, este tipo de erosão assume importância muito maior. O processo inicia-se com a precipitação, cujas gotas já têm energia suficiente para quebrar agregados do solo ou até mesmo iniciar o selamento superficial deste. Caso a intensidade de precipitação exceda a capacidade de armazenamento de água no solo, gera-se o principal componente do processo erosivo: o escoamento superficial. Este escoamento promove o transporte das partículas do solo, que, posteriormente, sofrem deposição (WMO, 2003)

A temperatura e a insolação também apresentam relevância nos processos erosivos sendo que a temperatura é muito influenciada pela insolação e ambas provocam dilatações e contrações sucessivas que enfraquecem o solo, facilitando a remoção das partículas (CARVALHO, 2008).

O vento é um importante agente erosivo, sendo responsável pelo transporte de material já desagregado e tem grande importância em terrenos planos, onde não se verifica escoamento, nas regiões áridas, semiáridas e nas superfícies desérticas onde a vegetação não protege o solo adequadamente (CARVALHO, 2008).

A topografia do terreno, em relação ao seu comprimento de rampa e declividade, também exerce grande influência sobre os processos erosivos. Segundo Bertoni e Neto, (2006), o tamanho e a quantidade dos sedimentos em suspensão que são arrastados pela água variam com a velocidade em que ocorre o escoamento superficial, o qual, por sua vez, depende do comprimento de rampa e do valor da declividade do terreno. Grande parcela da erosão e do transporte dos sedimentos ocorre nas partes mais altas da bacia, havendo o seu decréscimo com a diminuição das declividades e da intensidade das chuvas, à medida em que há o distanciamento das regiões mais montanhosas. Portanto, o processo de degradação do solo é predominante na parte alta da bacia, enquanto que a agração prevalece na parte baixa (CARVALHO, 2008).

O tipo de solo também é um agente que está relacionado aos processos erosivos, dependendo da sua estrutura e da textura. A textura representa o tamanho das partículas,

enquanto que a estrutura relaciona-se ao arranjo e ao agrupamento dessas partículas. A presença de matéria orgânica e de argila melhora a estrutura do solo, aumentando sua capacidade de manter-se estruturado, o que, por consequência, reduz a erosão decorrente do impacto das gotas de chuva (WMO, 2003; MELLO, 2006). Baixas taxas de infiltração propiciam maior escoamento e aumentam a possibilidade de erosão, enquanto que as altas taxas geram o contrário. Não obstante, a ocorrência ou não dessa erosão também estará relacionada à estrutura do solo (BONAN, 2002).

Há de se considerar, ainda, que a cobertura vegetal também exerce papel relevante na erosão e na produção de sedimentos, atuando como uma camada protetiva do solo, que minimiza os impactos causados pelas gotas de chuva e os efeitos da ação do vento próximo a sua superfície. Além disso, a vegetação facilita a infiltração da água precipitada e reduz a velocidade do escoamento superficial, possibilitando, ao mesmo tempo, a melhoria das propriedades físicas, químicas e biológicas do solo (BONAN, 2016). No entanto, a magnitude da proteção oferecida pela vegetação varia muito em função de suas características, tais como: espécie, tamanho e índice de área foliar. Assim, uma floresta, por exemplo, apresenta maior eficiência na proteção do solo em comparação a uma vegetação do tipo rasteira (CARVALHO, 2008).

Além de todos os fatores supracitados, as atividades humanas também influenciam o tipo e a intensidade dos processos erosivos, sendo que, de modo geral, a erosão tende a aumentar com o crescimento da população, uma vez que também aumentam o uso do solo e outras causas de erosão antrópica (CARVALHO, 2008).

Em virtude de ações antrópicas, são verificadas consequências tais como: i) perdas de solo, de material orgânico e de nutrientes, provocando a redução da sua fertilidade e da sua profundidade de cultivo e, por consequência, afetando o crescimento das plantas; ii) aumento das cargas de sedimentos nos rios; iii) assoreamento de rios e reservatórios com agravamento dos problemas socioambientais (inundações, racionamento de água, etc.); iv) eutrofização dos lagos; v) diminuição da qualidade das águas; etc. (BONAN, 2016).

Sendo assim, é evidente que o comportamento de uma bacia hidrográfica em relação aos sedimentos é bastante variável, dependendo, sobretudo, do tipo e do uso do solo, da cobertura vegetal, da declividade, do regime de chuvas e das atividades humanas desenvolvidas. De maneira geral, existe maior erosão e transporte de sedimentos no alto da bacia; ocorrendo o seu decréscimo com a diminuição das declividades e da intensidade das chuvas, ou seja, na medida em que há o

distanciamento das regiões mais montanhosas. Assim sendo, a degradação do solo predomina na alta bacia, enquanto que a agradação prevalece na parte baixa (CARVALHO, 2008).

2.1.2. Transporte e Deposição de Sedimentos

Os materiais resultantes do processo de erosão acabam sendo transportados, principalmente pela ação das águas de escoamento superficial, sendo esse fenômeno influenciado pelas condições topográficas do local e pela granulometria dos materiais carreados. O transporte desse material arrancado se dá por fluxo de massa, podendo ocorrer na forma de rolamento e arraste da partícula, ou então por suspensão (VESTANA, 2008).

Os sedimentos que chegam aos cursos d'água podem ser conduzidos nas calhas fluviais por diferentes processos de transporte, de acordo com a sua dimensão, com as condições locais e com o escoamento. As forças que atuam sobre a partícula podem mantê-la em suspensão ou no fundo do rio, saltando do leito para o escoamento, deslizando ao longo do rio. Isso acontece em função do tamanho das partículas, do peso e de sua forma; bem como em função do tipo do escoamento (laminar ou turbulento), velocidade da corrente e de diversas outras funções inter-relacionadas, como declividade do leito, forma do canal, entre outros (VANONI, 1977 *apud* CARVALHO, 2008).

Conforme Subcommittee on Sedimentation (1963), a carga sólida de arrasto é composta pelas partículas que rolam ou escorregam longitudinalmente no curso d'água. Nesse caso, as partículas estão em contato com o leito constantemente. A carga sólida saltante constitui a parcela que pula ao longo do curso d'água, por efeito da correnteza ou devido ao impacto com outras partículas. Já a carga sólida em suspensão é mantida suspensa pelas componentes horizontais da velocidade, sendo de dimensão suficientemente pequena para permanecerem em suspensão, subindo e descendo na corrente acima do leito.

As partículas de arraste e saltante constituem o material do leito e têm seu movimento governado pela capacidade de transporte do escoamento. Já o material em suspensão (partículas de granulometria reduzida, como silte e argila), move-se aproximadamente na mesma velocidade da corrente (NORDIN e McQUIVEY, 1971).

Dentre o material particulado carregado em suspensão, os sedimentos mais finos, que compreendem as frações das classes silte e argila, possuem um padrão da velocidade de deposição distinto em relação a outros grãos maiores, sendo influenciado por fatores intrínsecos como a salinidade, a concentração de sedimentos e a matéria orgânica na coluna d' água, além

da própria composição mineralógica (CARVALHO, 2008)

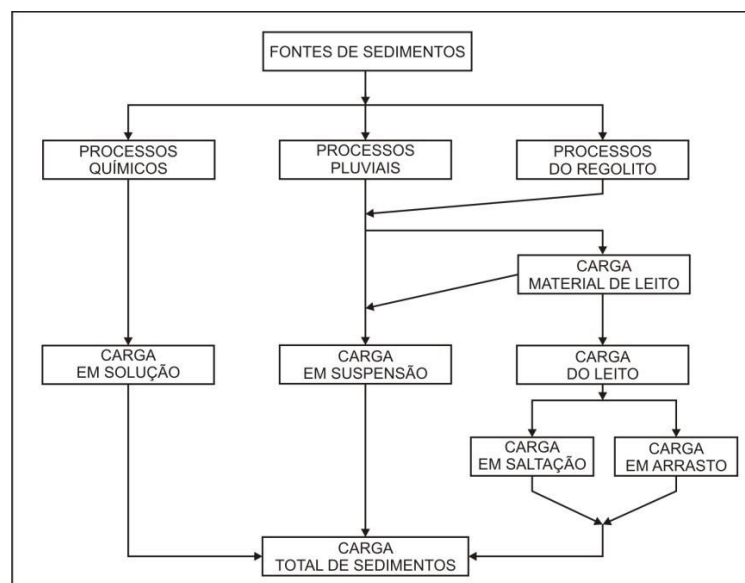
Ward e Trimble (1995) afirmam que a carga em suspensão pode representar mais de 90% do material total transportado. Tal porcentagem também é descrita por Carvalho (2008), ao considerar que a carga em suspensão é predominantemente maior que a do fundo no alto curso (90% a 95%).

Além das formas de transporte sólido apresentadas, existe uma parcela de material que é transportada dissolvida no curso d'água, movimentando-se na mesma velocidade do fluxo. A carga dissolvida compreende, basicamente, os constituintes intemperizados das rochas, que são transportados em solução química pelas águas fluviais e subterrâneas.

A proporção entre os materiais dissolvidos e os materiais particulados varia entre os diferentes cursos d'água. Christofolletti (1981) cita que, para os rios brasileiros, a carga particulada geralmente é bem maior que a carga dissolvida. Além disso, o autor discorre que a composição química das águas fluviais varia conforme a litologia, a vegetação e a utilização do solo na bacia hidrográfica.

O somatório das parcelas de sedimentos carregadas em suspensão, pelo leito e a carga em solução corresponde à carga total de sedimentos transportada pelo curso d'água. A carga total de sedimentos é, em última análise, composta por materiais fornecidos tanto por processos químicos, quanto por processos pluviais e por movimentos de arraste de massa nas vertentes. Na Figura 1 são ilustrados os processos atuantes nesse sistema.

Figura 1- Processos atuantes no transporte de sedimentos



Fonte: Christofolletti (1981).

Quando a força do escoamento se reduz até a condição de não poder continuar a deslocar a partícula, ocorre o processo de deposição. O depósito dos sedimentos geralmente se dá em locais mais baixos, podendo ocorrer em depressões naturais do terreno ou mesmo em encostas de declividade mais suave. Além disso, o material pode adentrar a rede de drenagem, sendo transportado pelos cursos d'água até o oceano ou ainda, ficar retido em reservatórios, nas margens de cheia, em planícies de inundação, deltas e estuários (CARVALHO, 2008).

Alguns sedimentos transportados podem, ainda, ser depositados em determinados locais apenas temporariamente, podendo ser subseqüentemente ressuspensos, sendo novamente movimentados pelo sistema de transporte (FOSTER, 1982).

2.1.3. Produção de Sedimentos em Bacias Hidrográficas

A produção de sedimentos pode ser entendida como a quantidade de partículas erodidas que é transportada pelo curso d'água. Tal produção acontece por meio da associação de eventos naturais e antrópicos que, associados a diversas variáveis, têm maior ou menor produção por área. A produção de sedimentos pode ser expressa em metros cúbicos ou em toneladas, quando referida à área da bacia, podendo ser também expressa como produção específica, em $m^3/km^2/ano$ ou $t/km^2/ano$.

De acordo com Walling (1990), o termo produção de sedimentos representa apenas uma parcela do total de sedimentos produzidos em uma bacia hidrográfica em decorrência dos processos erosivos atuantes, visto que uma quantidade significativa do material erodido é depositada ao longo das vertentes, não sendo, portanto, removida da bacia de drenagem.

De forma geral, nas porções elevadas de uma bacia hidrográfica há maior erosão e transporte de sedimentos, em especial devido à acentuada declividade dessas áreas, que resulta em maiores velocidades de escoamento (KRAMER e MEYER, 1969). A erosão vai diminuindo da alta para a média bacia, na medida em que as declividades decrescem e as chuvas se tornam menos intensas, ao se afastar das regiões montanhosas. Na parte baixa da bacia, há grande formação de depósitos sedimentares, isto é, a maior parte dos sedimentos erodidos se distribui pelos terrenos (FOSTER, 1982).

A estimativa da produção de sedimentos de uma bacia hidrográfica pode ser realizada avaliando-se o desprendimento, o transporte e a deposição de sedimentos, no entanto, comumente as medidas são efetuadas pelo monitoramento da descarga total de sedimentos transportados pelo canal em um dado período de tempo. A produção de sedimentos incorpora

tanto os sedimentos transportados em suspensão como o material de fundo. Entretanto, a maior parte dos estudos avalia apenas a componente dos sedimentos transportados em suspensão, pois, além da questão de economicidade dos projetos, os efeitos das práticas de manejo do solo sobre a erosão estão relacionados com essa faixa granulométrica (MINELLA, 2008).

2.2. Concentração de Sedimentos em Suspensão

A verificação da produção de sedimentos nas bacias hidrográficas é realizada, sobretudo, na seção transversal dos cursos d'água, por meio de amostragem de sedimento, seguida de análises no laboratório e cálculos de obtenção da descarga sólida.

A descarga em suspensão é efetuada para o conhecimento do valor do transporte em suspensão, concentração de sedimentos e da distribuição granulométrica. É a fase predominante das medições de sedimentos, uma vez que, em geral, a maior carga transportada refere-se à fração suspensa. Estima-se que esta parcela representa 90% da carga sólida total em grande parte dos rios. No entanto, existem rios que a descarga de arrasto pode ser maior, sobretudo, em rios com águas límpidas e muito material grosso no leito (CARVALHO, 2008).

A concentração de sedimentos em suspensão é, na maioria das vezes, determinada a partir de coletas de amostras no rio, por meio de amostragem por integração na vertical. Esse tipo de coleta de amostras de sedimentos e posterior análise laboratorial, além de ser onerosa, muitas vezes é perigosa por ser a maior parte dos sedimentos transportados durante eventos de cheia (SARI; PEDROLLO; CASTRO, 2017).

Em virtude disso, atualmente o desenvolvimento de novas tecnologias, que auxiliam no monitoramento contínuo da descarga em suspensão, vem sendo incentivado como uma alternativa interessante para a superação destas limitações. Explorar a determinação indireta da CSS a partir de outras variáveis, mais facilmente monitoradas (como a turbidez, nível d'água e a chuva), pode ser uma forma de se obter a informação sobre o transporte de sedimentos ao longo do tempo.

2.2.1. Relação entre CSS e Outras Variáveis

A dificuldade em se obter longas séries temporais de concentração de sedimentos suspensos tem levado os pesquisadores a buscarem métodos alternativos, que relacionam a CSS com outras variáveis, mais facilmente monitoráveis (BAYRAM et al., 2014; BAYRAM; KANKAL; ÖNSOY, 2012; SARI; CASTRO; PEDROLLO, 2017).

A curva chave de sedimentos, tradicionalmente utilizada para se determinar a CSS, consiste em uma regressão simples, não linear, do tipo $CSS = cQ^d$, em que “c” e “d” são constantes a serem calibradas (GAO e JOSEFSON, 2012; SU et al., 2013; TÓTH e BÓDIS, 2015). Porém, diversos estudos relatam a fraca correlação entre a CSS e a descarga líquida (HASSAN et al., 2015; JAIN, 2001).

De fato, a relação entre a concentração de sedimentos em suspensão e a vazão varia com o tempo e não é constante durante um evento, ocorrendo, frequentemente, o fenômeno da histerese, que consiste no aparecimento de um atraso na evolução de um fenômeno físico em relação a outro (SEEGER et al., 2004). Quando o pico de CSS ocorre depois do pico da vazão, devido à contribuição de áreas não muito próximas, tem-se uma curva de histerese no sentido anti-horário. Já as curvas de sentido horário ocorrem quando os sedimentos são mobilizados rapidamente, com a fonte de sedimentos provenientes de depósitos da calha fluvial (LEFRANCOIS et al., 2007).

Tramblay et al., (2010) demonstraram que a correlação entre a CSS máxima anual e a correspondente descarga, tendo em conta o possível atraso causado por histerese, foi significativa em apenas 92 de 208 rios estudados na América do Norte. Estes resultados sugerem que, para muitos rios, a descarga líquida é uma variável muito limitada para determinar o transporte de sedimentos em suspensão.

Alguns estudos abordam outras tecnologias alternativas de monitoramento como alternativa para estimativa da CSS, como os sensores ópticos, a reflexão acústica, a difração a laser, a diferença de pressão e as análises de imagens digitais (SARI; CASTRO; KOBIYAMA, 2015).

Diversos estudos demonstram que é possível utilizar a turbidez como medida indireta da concentração de sedimentos suspensos (LEWIS, 1996; JONES et al., 2011; HARRINGTON e HARRINGTON, 2013; SARI, PEDROLLO e CASTRO, 2017).

Desde Costa (1977), a turbidez vem sendo estudada como uma medida alternativa para se determinar o material sólido em suspensão. O Autor salienta que as partículas suspensas diminuem a claridade da água, reduzindo a transmitância da luz no meio líquido. Porém, cada manancial representa uma situação específica em virtude do tamanho, da forma e da refletividade das partículas em suspensão. Essas propriedades influenciam nas leituras dos turbidímetros.

Sensores têm sido usados para estimar indiretamente a CSS em rios, tendo por base leituras automáticas e contínuas de turbidez (LEWIS, 2003; SCHOELLHAMER e WRIGHT, 2003; RASMUSSEN et al., 2011). As principais vantagens desta alternativa é a aquisição contínua de dados e o baixo custo operacional. Por outro lado, há algumas limitações no uso de sensores de turbidez, que incluem baixa resolução espacial (medição de ponto único), o acúmulo de resíduos na lente do sensor, bem como as inúmeras características dos sedimentos, como o tamanho, a forma, e a cor, que afetam a maneira pela qual a luz é espalhada, e, portanto, a resposta do sensor (HATCHER et al., 2000).

Sari, Castro e Kobiyama, (2015) destacam que os resultados obtidos na conversão da Turbidez para a CSS são dependentes de uma boa calibração da relação entre o sinal registrado por um sensor óptico e a CSS; sendo essa resposta influenciada por fatores: oriundos do sedimento (CSS, tamanho da partícula de sedimento transportado, forma e rugosidade da partícula de sedimento transportado, cor e composição mineralógica da partícula de sedimento transportado), referentes ao instrumento de monitoramento (características ópticas e geométricas do sensor de monitoramento), e relacionados à qualidade da água e ao fluxo no canal (presença de bolhas, gases e outros componentes e processos de floculação, agregação e turbulência das partículas).

Os autores realizaram uma revisão acerca dos fatores que afetam o sinal de turbidez e concluíram que diversos estudos citam a concentração de sedimentos e o tamanho da partícula transportada pelo escoamento como os dois principais fatores de influência.

Outras pesquisas vêm sugerindo que características das bacias hidrográficas (incluindo a topografia, a geologia, o clima e o uso da terra) estabelecem significativa correlação com o fluxo de sedimentos suspensos, tanto para valores médios, quanto extremos (SLAYMAKER, 1982; BRAY e XIE, 1993; LUDWIG e PROBST, 1998; JARVIE et al., 2002; SIAKEU et al., 2004; DODDS e WHILES, 2004; ROBERTSON et al., 2006; RESTREPO et al., 2006 e TRAMBLAY et al., 2007).

Tamene et al. (2006), por exemplo, analisaram os fatores determinantes da variabilidade da produção de sedimentos no norte da Etiópia, usando regressão múltipla, e relataram que fatores como declividade do terreno, tipo de solo, cobertura superficial e uso e ocupação do solo interferem nos processo de erosão, e devem ser incorporados nos modelos.

2.3. Redes Neurais Artificiais em Aplicações Hidrossedimentológicas

Nos últimos anos, modelos baseados em RNAs ou associados a essas redes têm atraído pesquisadores da área de sedimentologia, evidenciando que essas redes podem ser uma alternativa viável e promissora para a predição da CSS. Na Tabela 1 é apresentada uma descrição de estudos que utilizaram RNA para cálculos hidrossedimentológicos.

Nos estudos de Sari (2017) é apresentada uma revisão de bibliográfica completa para estudos hidrossedimentológicos que utilizaram RNAs. Boa parte das pesquisas são feitas para escala de tempo anual ou mensal, sendo uma pequena parcela destinada à escala de tempo diária, e, em geral, dispõem de longas séries históricas de informações sobre sedimentos.

Tabela 1 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

Autor	Local	Área da Bacia/Área Analisada	Objetivo	Características Modelo	Algoritmo de Treinamento	Variáveis de Entrada	Variáveis de Saída	Período de Dados/Nº de Registros	Intervalo de Tempo	Melhor Desempenho NS/R ² /R
Jain (2001)	2 estações no rio Mississippi (Chester e Thebes)	Chester: 1835276 km ² Thebes: 1847190 km ²	Desenvolver curvas chave nível d'água-vazão-sedimentos	RNA feedforward (3 camadas)	Retropropagativo	Dados diários de nível de água; vazão e concentração de sedimentos	vazão e concentração de sedimentos	Chester: 1985-1987 Thebes: 1990-1991	Diário	R=0,960 para o treinamento e R=0,869 para verificação
Agarwal et al. (2006)	Bacia do rio Vamsadhara (Índia)	7820 km ²	Desenvolver modelo de RNA para simulação do escoamento de sedimentos (diário, semana, 10 dias e mensal)	RNA feedforward (3 camadas)	Retropropagativo	Dados diários de precipitação e escoamento em tempo atual e antecedente	Carga de sedimentos	Treinamento – 1984-1987 Validação – 1988-1989 Verificação 1992-1995	Diário, semanal, 10 dias e mensal	NS=0,87 no treinamento e 0,63 na verificação (diário); NS=0,86 no treinamento e 0,64 na verificação (semanal); NS=0,9 no treinamento e 0,63 na verificação (10 dias); NS=0,92 no treinamento e 0,77 na verificação (mensal)
Cigizoglu e Kisi (2006)	Bacia do rio Schuylkill	-	Estimar quantidades diárias de sedimentos suspensos	RNA feedforward (3 camadas) e range-dependent neural network (RDNN)	Retropropagativo	Dados diários de Vazão e carga de sedimentos suspensos em tempo atual e antecedente	Carga de sedimentos suspensos	Treinamento – 8760 (1952 a 1976); Verificação – 1725 (1976-1981)	Diário	Feedforward – NS=0,854 no treinamento 0,791 na verificação; RDNN – NS=0,849 no treinamento e 0,829 na verificação
Alp e Cigizoglu (2007)	Bacia do rio Juniata (Pennsylvania)	-	Estimar a carga de sedimentos diária	RNA feedforward (3 camadas) e RNA de base radial	Retropropagativo	Dados diários de Precipitação e vazão em tempo atual e antecedente	Carga de sedimentos diária	1500 para treinamento (1983-1988) e 500 para verificação (1988-1989)	Diário	Feedforward – R ² =0,897 na verificação; RNA de base radial – NS=0,921
Kisi (2007)	2 estações (Calleguas e Santa Clara)	Calleguas – 659 km ² Santa Clara – 1660 km ²	Estimar a concentração de sedimentos suspensos	Range-dependent neural networks (RDNN); RNA feedforward (3 camadas)	Levenberg-Marquardt para RNA feedforward	Vazão e Sedimentos suspensos em tempo atual e antecedente	Concentração de sedimentos suspensos	1969-1976 para treinamento e 1977-1978 para verificação	Diário	Calleguas: Feedforward – R ² =0,96 na verificação; RDNN – R ² =0,959 na verificação; Santa Clara: Feedforward – R ² =0,883 na verificação; RDNN – R ² =0,891 na verificação
Kisi (2008)	2 estações (rio Valenciano e Quebrada Blanca) Porto Rico	Valenciano – 43,6 km ² Quebrada Blanca – 863 km ²	Estimar a concentração de sedimentos suspensos	RNA feedforward (3 camadas)	Levenberg-Marquardt, gradiente conjugado e gradiente de descida	Diversas combinações de valores antecedentes de vazão e CSS	Concentração de sedimentos suspensos	01/10/1993 - 30/09/1994 para treinamento e 01/10/1994 - 30/09/1995 para verificação	Diário	Rio Valenciano: R ² =0,869; 0,846 e 0,751 para Levenberg-Marquardt, gradiente conjugado e gradiente de descida durante a verificação; Quebrada Blanca: R ² =0,940; 0,896 e 0,704 para Levenberg-Marquardt, gradiente conjugado e gradiente de descida durante a verificação;

Tabela 2 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos (Continuação)

Autor	Local	Área da Bacia/Área Analisada	Objetivo	Características Modelo	Algoritmo de Treinamento	Variáveis de Entrada	Variáveis de Saída	Período de Dados/Nº de Registros	Intervalo de Tempo	Melhor Cenário Desempenho NS/R ² /R
Nourani (2009)	Estação de Akhule, rio Talkherood, Irã	13853 km ²	Estimativa da carga de sedimentos	Feedforward (3 camadas)	Levenberg-Marquardt	Vazões em tempo atual e antecedentes	Descarga de sedimentos	380 dados de sedimentos (2002-2005)	Diário	NS=0,977 no treinamento e NS=0,935 na verificação
Nourani e Kalantari (2010)	6 estações na bacia do rio Eel, Califórnia, EUA	8051 km ²	Desenvolver modelos para estimar a carga de sedimento suspensos nas estações e em qualquer ponto da bacia	Feedforward (3 camadas)	Levenberg-Marquardt	Precipitações e Vazões em tempo atual e antecedentes	Carga de sedimentos suspensos	1966-1969 para o treinamento e 1969-1970 para verificação	Diário	NS=0,86; 0,78; 0,84; 0,84; 0,82; 0,81 para as estações 1 a 6, na verificação.
Kisi (2012)	2 estações no rio Eel, Califórnia, EUA	1368 km ² e 8063 km ²	Estimar a CSS diária	Máquinas de Vetores de Suporte e RNA Feedforward (3 camadas)	Retropropagativo: Levenberg-Marquardt (LM) e Gradiente Conjugado (GC)	Dados de Vazão de monta de e jusante, em tempos atuais e antecedentes	Concentração de sedimentos suspensos	1966-1973 para o treinamento, 1973-1975 para validação e 1975-1977 para verificação	Diário	Montante: R ² =0,959 para LM e 0,956 para GC; Jusante: R ² =0,964 para LM e 0,954 para GC, durante a verificação
Kisi e Shiri (2012)	Rio Eel, Califórnia, EUA	528 km ²	Estimar a carga diária de sedimentos suspensos	Feedforward (3 camadas)	Levenberg-Marquardt (LM), gradiente conjugado (GC) e gradiente de descida (GD)	Precipitações e Vazões em tempo atual e antecedentes	Carga de sedimentos suspensos	1979-1986 para o treinamento e 1986-1989 para verificação	Diário	NS=0,838 para LM, 0,804 para GC e 0,801 para GD, na verificação
Nourani, Kalantari e Baghanam (2012)	9 estações na bacia do rio Eel, Califórnia, EUA	8051 km ²	Desenvolver modelos para estimar a carga de sedimentos suspensos nas estações e em qualquer ponto da bacia	Feedforward (3 camadas)	Levenberg-Marquardt	Precipitações e Vazões em tempo atual e antecedentes, parâmetros geomorfológicos e hidrometeorológicos	Carga de sedimentos suspensos	1966-1969 para o treinamento e 1969-1970 para verificação	Diário	NS=0,976 no treinamento e 0,882 na verificação
Bayram et al. (2014)	6 estações na bacia de Harsit, Turquia	24077 km ²	Estimar a CSS a partir de variáveis de qualidade da água (turbidez, ferro e cromo)	Feedforward (3 camadas)	Retropropagativo	Concentração total de cromo, concentração total de ferro e Turbidez	Concentração de sedimentos em suspensão	132 dados: 96 para treinamento, 24 para validação e 12 para verificação	Quinzenal	RNA tem bons resultados para estimar a CSS. Erro absoluto médio igual a 11,67 mg/L na verificação, enquanto que com análise de regressão, o erro médio foi de 15,18 mg/L
Afan et al. (2015)	Bacia do rio Johor (Malásia Peninsular)	2286 km ²	Determinar a carga diária de sedimentos, a partir de dados de sedimentos e vazões antecedentes	RNA feedforward (3 camadas) e RNA de base radial	Retropropagativo para a RNA feedforward	Vazão e Carga de sedimentos em tempos atuais e antecedentes	Carga de sedimentos suspensos	1988-1997 para treinamento e 1998-1999 para verificação	Diário	R ² =0,903 para feedforward e R ² =0,909 para a RNA de base radial, ambos na verificação

Tabela 3 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos (Continuação)

Autor	Local	Área da Bacia/Área Analisada	Objetivo	Características Modelo	Algoritmo de Treinamento	Variáveis de Entrada	Variáveis de Saída	Período de Dados/Nº de Registros	Intervalo de Tempo	Melhor Cenário Desempenho NS/R ² /R
Atieh et al. (2015)	Província de Ontario, Canadá	Várias bacias em uma região de mais de 1 milhão de km ²	Prever parâmetros da curva-chave de sedimentos para bacias sem dados, a partir de outras bacias com dados	RNA feedforward (3 camadas) e RNA de base radial	Retropropagativo para a RNA feedforward	Dados topográficos, climáticos, tipo de solo, uso e ocupação do solo e dados hidrométricos (chuva)	Parâmetros alfa e beta da curva-chave de sedimentos	-	Diário	R= 0,92 e 0,86 para alfa e beta, respectivamente, na verificação
Sari, Pedrollo e Castro (2017)	Rio Taboão, Rio Grande do Sul, Brasil	78 km ²	Estimar a CSS a partir de dados de Nível e Turbidez	RNA feedforward (3 camadas)	Retropropagativo com validação cruzada e retropropagativo com validação por reamostragem	Nível e Turbidez	CSS	59 registros de CSS, níveis e turbidez - 04/06/2013 a 20/10/2015	-	NS= 0,788 para validação cruzada e 0,953 para validação por reamostragem, na verificação
Buyukyildize Kumcu (2017)	1 estação no rio Coruh, Turquia	19750 km ²	Estimar a carga de sedimentos suspensos	RNA feedforward (3 camadas)	Retropropagativo	Vazão e Carga de sedimentos em tempos atuais e antecedentes	Carga de sedimentos suspensos	446 registros de sedimentos entre 1969-2011	Diário	NS=0,843 no treinamento e 0,801 na verificação

Fonte: Adaptado de Sari (2017).

A maior parte dos estudos utilizam a vazão em tempos atuais e antecedentes (defasagem) como variável de entrada. Alguns trabalhos utilizam, também, a própria informação do sedimento de dias anteriores, sendo que estes modelos apresentam os melhores resultados. No entanto, dependem de série de dados de sedimentos longa e contínua para sua aplicação. Poucos trabalhos exploram as precipitações como variáveis de entrada, e nenhum deles exploram essa variável com aplicação de filtros temporais, tais como as médias móveis, sendo esta uma lacuna explorada nesta pesquisa.

Face ao exposto, as redes neurais são as candidatas naturais para esta pesquisa, uma vez que não são limitadas às formulações, que são, até então, desconhecidas, e são ferramentas que vem sendo amplamente utilizadas na modelagem hidrossedimentológica, apresentando bons resultados.

2.4. Referências bibliográficas

AFAN, Haitham Abdulmohsin et al. ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. **Water Resources Management**, [s. l.], v. 29, n. 4, p. 1231–1245, 2014.

AGARWAL, Avinash et al. Simulation of Runoff and Sediment Yield using Artificial Neural Networks. **Biosystems Engineering**, [s. l.], v. 94, n. 4, p. 597–613, 2006.

ALP, Murat; CIGIZOGLU, H. Kerem. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. **Environmental Modelling and Software**, [s. l.], v. 22, n. 1, p. 2–13, 2007.

ATIEH, M. et al. Integrative neural networks model for prediction of sediment rating curve parameters for ungauged basins. **Journal of Hydrology**, [s. l.], v. 531, p. 1095–1107, 2015.

BAYRAM, Adem et al. Prediction of suspended sediment concentration from water quality variables. **Neural Computing and Applications**, [s. l.], v. 24, n. 5, p. 1079–1087, 2014.

BAYRAM, Adem; KANKAL, Murat; ÖNSOY, Hızir. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. **Environmental Monitoring and Assessment**, [s. l.], v. 184, n. 7, p. 4355–4365, 2012.

BERTONI, Jose; NETO, Francisco Lombardi. Conservação do Solo. In: 8ª ed. [s.l.] : Icone, 2006. p. 360.

BONAN, Gordon. **Ecological Climatology**. 3. ed. Cambridge: Cambridge University Press, 2016.

BRAY, D.I., XIE, H., 1993. A regression method for estimating suspended sediment yields for ungauged watershed in Atlantic Canada. **Can. Civ. Eng.** 20, 82–87.

BUYUKYILDIZ, Meral; KUMCU, Serife Yurdagul. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. **Water Resources Management**, [s. l.], v. 31, n. 4, p. 1343–1359, 2017.

CARVALHO, N. **Hidrossedimentologia prática**. 2^a ed. Rio de Janeiro: Interciência, 2008.

CIGIZOGLU, Hikmet Kerem; KISI, Özgür. Methods to improve the neural network performance in suspended sediment estimation. **Journal of Hydrology**, [s. l.], v. 317, n. 3–4, p. 221–238, 2006.

COSTA, J. E. Sediment Concentration and duration in stream channels. **Journal of Soil and Water Conservation**, v. 1, p.168-70, 1977.

DODDS, W.K., WHILES, M. Quality and quantity of suspended particles in rivers: continental-scale patterns in the United States. **Environ. Manage.** 33 (3), 355–367. 2004.

HARRINGTON, S.T.; HARRINGTON, J.R. An assessment of the suspended sediment rating curve approach for load estimation on the Rivers Bandon and Owenabue, Ireland. **Geomorphology**, v. 185, p. 27-38, 2013.

HASSAN, Muhammad et al. Development of sediment load estimation models by using artificial neural networking techniques. **Environmental Monitoring and Assessment**, [s. l.], v. 187, n. 11, 2015.

HATCHER, A.; HILL, P.; GRANT, J.; MACPHERSON, P. Spectral optical backscatter of sand in suspension: effects of particle size, composition and colour. **Marine Geology**, v. 168, n. 1-4, p. 115-128, Aug. 2000.

JAIN, Sharad Kumar. Development of integrated sediment rating curves using ANNs. **Journal of hydraulic engineering**, [s. l.], v. 127, n. 1, p. 30–37, 2001.

JARVIE, H.P., OGUCHI, T., NEAL, C. Exploring the linkages between river water chemistry and watershed characteristics using GIS-based catchment and locality analysis. **Reg. Environ. Change** 36, 36–50. 2002.

JONES, A. S; STEVENS, D; HORSBURGH, J. S; MESNER, N. O. Surrogate measures for providing high frequency estimates of total suspended solids and total phosphorus concentrations. **Water Resources Association**; v. 47, p. 239–53, 2011.

KISI, Ozgur. Constructing neural network sediment estimation models using a data-driven algorithm. **Mathematics and Computers in Simulation**, [s. l.], v. 79, n. 1, p. 94–103, 2008.

KIŞI, Ozgur. Development of streamflow-suspended sediment rating curve using a range dependent neural network. **International Journal of Science & Technology**, [s. l.], v. 2, n. 1, p. 49–61, 2007.

KISI, Ozgur; OZKAN, Coskun; AKAY, Bahriye. Modeling discharge–sediment relationship using neural networks with artificial bee colony algorithm. **Journal of Hydrology**, [s. l.], v. 428–429, p. 94–103, 2012.

KISI, Ozgur; SHIRI, Jalal. River suspended sediment estimation by climatic variables

implication: Comparative study among soft computing techniques. **Computers and Geosciences**, [s. l.], v. 43, p. 73–82, 2012.

LEFRANÇOIS, J; GRIMALDI, C; GASCUEL-ODOUX, C; GILLIET, N. Suspended sediment and discharge relationships to identify bank degradation as a main sediment source on small agricultural catchments. **Hydrological Processes**, v. 21, n. 15, p.2923–2933, 2007.

LEWIS, J. Turbidity-controlled suspended sediment sampling for runoff-event load estimation. **Water Resources Research**, v. 32, n. 7, p. 2299-2310, 1996.

LEWIS, J. Turbidity-controlled sampling for suspended sediment load estimation. **IAHS Publ.**, v. 283, p. 13-20, 2003.

LUDWIG, W; PROBST, J. L. River sediment discharge to the oceans: present-day controls and global budgets. **Am. J. Sci.** 298, 265–295. 1998.

NOURANI, Vahid; KALANTARI, Omid. Integrated Artificial Neural Network for Spatiotemporal Modeling of Rainfall–Runoff–Sediment Processes. **Environmental Engineering Science**, [s. l.], v. 27, n. 5, p. 411–422, 2010.

NOURANI, Vahid; KALANTARI, Omid; BAGHANAM, Aida Hosseini. Two Semidistributed ANN-Based Models for Estimation of Suspended Sediment Load. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 12, p. 1368–1380, 2012.

NOURANI, Vahid; KOMASI, Mehdi; MANO, Akira. A Multivariate ANN-Wavelet Approach for Rainfall–Runoff Modeling. **Water Resources Management**, [s. l.], v. 23, n. 14, p. 2877–2894, 2009.

RASMUSSEN, P. P.; GRAY, J. R.; GLYSSON, G. D.; ZIEGLER, A. C. Guidelines and Procedures for Computing Time-Series Suspended-Sediment Concentrations and Loads from In-Stream Turbidity-Sensor and Streamflow Data. [S.l.]: U.S. **Geological Survey. Techniques and Methods**. Book 3, chap. C4. 2011.

RESTREPO, J; KJERFE, B; HERMELIN, M. Factors controlling sediment yield in a major South American drainage basin: the Magdalena River, Colombia. **Journal of Hydrology**. 316, 213–232. 2006.

ROBERTSON, D. M; SAAD, D. A; HEISEY, D. M. A regional classification scheme for estimating reference water quality in streams using land-use-adjusted spatial regression-tree analysis. **Environ. Manage.** V. 32, p. 209–229. 2006.

SARI, Vanessa. **Monitoramento e Modelagem da Produção de Sedimentos em uma Bacia hidrográfica no Noroeste do Rio Grande do Sul**. 2017. Universidade Federal do Rio Grande do Sul, [s. l.], 2017.

SARI, Vanessa; CASTRO, Nilza Maria dos Reis; PEDROLLO, Olavo Correa. Estimate of Suspended Sediment Concentration from Monitored Data of Turbidity and Water Level Using Artificial Neural Networks. **Water Resources Management**, [s. l.], v. 31, n. 15, p. 4909–4923, 2017.

SARI, V; CASTRO, N. M. R; KOBİYAMA, M. Estimativa da concentração de sedimentos

suspensos com sensores ópticos: Revisão. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 4, p. 816-836, 2015.

SCHOELLHAMER, D. H; WRIGHT, S. A. Continuous measurement of suspended-sediment discharge in rivers by use of optical backscatterance sensors. **IAHS Publ.**, v. 283, p. 28-36, 2003.

SEEGER, M. et al. Catchment soil moisture and rainfall characteristic as determinant factor for discharge/ suspended sediment hysteretic loops in a small headwater catchment in the Spanish pyrenees. **Journal of Hydrology**, v.288, p. 299–311, 2004.

SIAKEU, J; OGUCHI, T; AOKI, T; ESAKI, Y; JARVIE, H. P. Change in riverine suspended sediment concentration in central Japan in response to late 20th century human activities. **Catena** **55**, 231–254. 2004.

SILVA, Alexandre Marco; SCHULZ, Harry Edmar; CAMARGO, Plínio Barbosa. Erosão e Hidrossedimentologia em Bacias Hidrográficas. In: 1. ed. [s.l.] : Rima, 2003. p. 140.

SLAYMAKER, O. Land use effects on sediment yield and quality. *Hydrobiologia* 91, 93–109. 1982.

TAMENE, L; PARK, S. J; DIKAU, R; VLEK, P. L. G. Analysis of factors determining sedimentyield variability in the highlands of northern Ethiopia. **Geomorphology**. v. 76(1-2): p. 76-91, 2006.

TRAMBLAY, Yves et al. Regional estimation of extreme suspended sediment concentrations using watershed characteristics. **Journal of Hydrology**, [s. l.], v. 380, n. 3–4, p. 305–317, 2010.

TRAMBLAY, Y; ST-HILAIRE, A; OUARDA, T. B. M. J. Modelling extreme suspended sediment concentrations in North America: frequency analysis and correlations with watershed characteristics. Perugia, Italy. **IAHS Publication**. v. 31. p. 117-129, 2007.

WMO, The World Meteorological Organization. **Manual on Sediment Management and Measurement**. [s.l: s.n.].

3. REGIONAL ESTIMATION OF SUSPENDED SEDIMENT CONCENTRATION IN THE PANTANAL (BRAZIL) USING ARTIFICIAL NEURAL NETWORKS

Este capítulo aborda sobre a modelagem, em escala espacial, desenvolvida a partir das redes neurais artificiais, para estimar a concentração de sedimentos em suspensão em diversos pontos da porção brasileira da bacia do Alto Paraguai. O modelo obtido estima a concentração de sedimentos em suspensão em qualquer ponto dentro da bacia, onde se tenha informações de turbidez, vazão e precipitação, associadas às características relativas à área de drenagem de cada ponto, tais como o tipo de solo, a declividade média, o uso do solo e a cobertura vegetal.

Este capítulo é apresentado na forma de um artigo científico em língua inglesa, que foi submetido recentemente na revista internacional *Water Resources Management*.

Abstract

The estimation of suspended sediment concentration (SSC) in rivers constitutes an important tool for the elaboration of engineering projects and the management of water resources. The complex nature of hydrosedimentological relationships can be modeled by techniques that adjust highly nonlinear relationships, such as artificial neural networks (ANN). In this study, several ANN models were developed to estimate, on a regional basis, the SSC in the Upper Paraguay River Basin (UPRB), the hydrographic region where the Pantanal biome is located. A spatial approach was used to deal with the scarcity of in situ data in the UPRB, situation that is very common in most of the planet's watersheds. SSC data from 23 fluviometric stations with low temporal frequency sampling were used. The variables turbidity, discharge, rainfall, exponentially weighted moving average of past rainfalls (EWMA), soil type, land use and vegetation cover, average slope and drainage area were tested as input, totaling 53 variables. The model in which none of the input variables was discarded (M01) obtained a Nash-Sutcliffe (NS) coefficient equal to 0.794 in the verification. The alternative model (M19), which did not consider the variables whose correlation with the SSC was not significant (considering the significance level of 5%), obtained the best performance (NS = 0.832 at verification). The presence of EWMA of past rainfalls provided gains in models performance, evidencing that these variables can be further explored in sediment estimation models.

Keywords hydrosedimentological regionalization, wetlands modeling, ungauged basins, regional estimation, data-based modeling.

3.1. Introduction

Suspended sediment concentration (SSC) is an important component of water quality that directly influences the biological, physical and chemical processes of water bodies. Monitoring this variable is important for studies of erosive processes in hydrographic basins, for planning and operation of reservoirs or hydroelectric plants and for recovery of degraded aquatic environments.

This monitoring of the suspended load generally consists in the collection of water samples in the field, in previously determined sections, with later laboratory analysis. However, the need for human resources and the high cost of this procedure make it difficult to obtain information that considers the spatial and temporal variations of the SSC (BAYRAM et al., 2014; BAYRAM; KANKAL; ÖNSOY, 2012; SARI; CASTRO; PEDROLLO, 2017).

The lack of long-term and frequent sediment concentration data stimulates the development of indirect estimation methodologies based on the relation of SSC with other variables easier to determine over time, such as discharge with the sediment rating curve (CROWDER; DEMISSIE; MARKUS, 2007; HENG; SUETSUGI, 2014; JAIN, 2001; ZHANG et al., 2012); and turbidity (HAIMANN et al., 2014; HARRINGTON; HARRINGTON, 2013; SARI; CASTRO; PEDROLLO, 2017; SHELLNBARGER; WRIGHT; SCHOELLHAMER, 2013; TANANAIEV; DEBOLSKIY, 2014).

Artificial neural networks (ANNs) have been successfully applied in the field of water resources engineering, because of their high capacity to model nonlinear relationships, even without explicit physics. The ANNs produce fast and satisfactory results, despite its limitation in extrapolating the domains, which can be avoided by selecting a training sample that covers the entire desired domain.

Researchers around the world use the ANN approach for diverse applications, including rainfall-runoff modeling (AGARWAL; SINGH, 2004; BHATTACHARJYA; CHAURASIA, 2013; GIUSTOLISI; LAUCELLI, 2005; MINNS; HALL, 1996; NOURANI; KOMASI; MANO, 2009; SHOAIIB et al., 2018; TOKAR; JOHNSON, 1999; ZEROUAL; MEDDI; ASSANI, 2016), flow forecasting (ADAMOWSKI; SUN, 2010; CIGIZOGLU, 2003a, 2003b; CIGIZOGLU; KISI, 2006; DORNELLES; GOLDENFUM; PEDROLLO, 2013), estimation of soil water content (CHAI et al., 2009; FASHI, 2016; HASSAN-ESFAHANI et al., 2017; OLIVEIRA et al., 2017) as well as hydrosedimentological modeling (AFAN et al., 2014;

AGARWAL et al., 2006; BUYUKYILDIZ; KUMCU, 2017; JAIN, 2001; KAKAEI LAFDANI; MOGHADDAM NIA; AHMADI, 2013; MUSTAFA et al., 2012; NOURANI; KALANTARI, 2010; NOURANI; KALANTARI; BAGHANAM, 2012; RAJAEI, 2011; SINGH et al., 2013, 2012; TALEBIZADEH et al., 2010; TAYFUR, 2002; TAYFUR; GULDAL, 2006).

Jain (2001) developed ANN models to establish a relationship between SSC and discharge at two points on the Mississippi River and compared it with the traditional technique of the sediment-rating curve (SRC). The author has shown that the results of the artificial neural networks are much closer to the observed values than the SRC. Although SRC is widely used in the indirect determination of SSC, other factors such as the hysteresis phenomenon may impair the accuracy of its estimation.

Hassan et al. (2015) developed ANN models to estimate the weekly sediment load, based on data on sediment antecedents, flow and temperature. The study obtained satisfactory results for all training methods tested.

Turbidity can be also used to indirectly determine SSC, because it is less expensive than traditional sediment collection methods. Bayram et al. (2012) estimated SSC using turbidity data through regression techniques (RA) and ANNs. The study was conducted at six stations along the Harsit River in Turkey. The ANN model presented better results than RA, and turbidity was considered as a substitute for the SSC at the evaluated points.

Generally, ANN models for SSC estimation are adjusted for fluvimetric stations with long time series. However, several Brazilian fluvimetric stations do not monitor this variable, and those that monitor do not have the desired frequency. Sari et al. (2017) developed an ANN model that related SSC data with turbidity and water level from the station installed in the basin of the Taboão river (Rio Grande do Sul, Brazil), using a training technique developed by the authors, called resampling validation. Even with few data (59 records of SSC, turbidity and water level), the technique yielded satisfactory results (Nash-Sutcliffe efficiency equals to 0.995 in training and 0.953 in verification).

Atieh et al. (2015) applied ANN models to estimate sediments in ungauged basins of the Ontario, Canada. The authors integrated 94 basins to estimate the parameters of the traditional sediment classification curve. Used input variables physically characterize the basins, as well as the climatic and hydrometric parameters, leading to satisfactory results. This approach allowed the development of sediment rating curves for basins where sediments are not

monitored. On the other hand, the basins used for models calibration and validation had enough data to adjust sediment rating curves.

The present study is conducted in the Upper Paraguay River Basin (UPRB), Brazil, where the Pantanal biome is located, being considered the largest tropical wetland in the world. The low population density, coupled with the extensive floodplains and the seasonality of the floods, favors the great biodiversity. The region lacks enough hydrosedimentological monitoring (with one station every 8,000 km² approximately), with insufficient collection frequency (average of four records per year). The use of the traditional sediment-rating curve becomes infeasible in basin stations due to insufficient SSC data. Turbidity is also monitored at some UPRB stations, more frequently than sediments, and may contribute to improving SSC estimates in the basin.

Therefore, this research aims to develop a regional ANN model to estimate the concentration of suspended sediments in the Upper Paraguay river basin, from related simultaneous variables such as turbidity and flow, as well as variables that affect sediment formation and transport, such as previous precipitation, soil type and land use, and to promote more information on the regional hydrosedimentological dynamics and to subsidize information for the decision making in several rivers of the basin.

3.2. Artificial Neural Networks

ANNs are models inspired by the operation of biological neural networks (human brain), having high non-linear function adjustment capacity, with speed, fault tolerance, intense parallelism and great learning ability. The structure of the artificial neural network consists of successive layers of artificial neurons, wherein the first corresponds to the input nodes, then one or more intermediate layers and the output layer.

Hornik et al. (1989) enunciated a universal approximation theorem with ANNs, stating that any measurable relation can be approximated with a single intermediate layer, with any desired precision, if it is adequately trained and has a compatible number of artificial neurons in that layer. The feedforward ANNs (RUMELHART; HINTON; WILLIAMS, 1986) are commonly used in many hydrological applications, usually with a three-layer structure (Fig. 1).

In the first layer, the input data (explanatory variables) are inserted. In successive layers, each neuron receives the sum of the inputs, weighted by coefficients called synaptic weights; this sum, added to a trend term, goes through a linear or a nonlinear transformation (neuron

activation function), which transforms this sum into an output value of this layer, constituting the output of the network (explained variables). The functioning of a neuron is defined by:

$$O = f(\sum_{i=1}^n w_i I_i + b) \quad (1)$$

where: O is the value of the neuron's response; f is the activation function; w_i are the synaptic weights; I_i are the values of the n entries that will be processed in the neuron and b is the trend or bias.

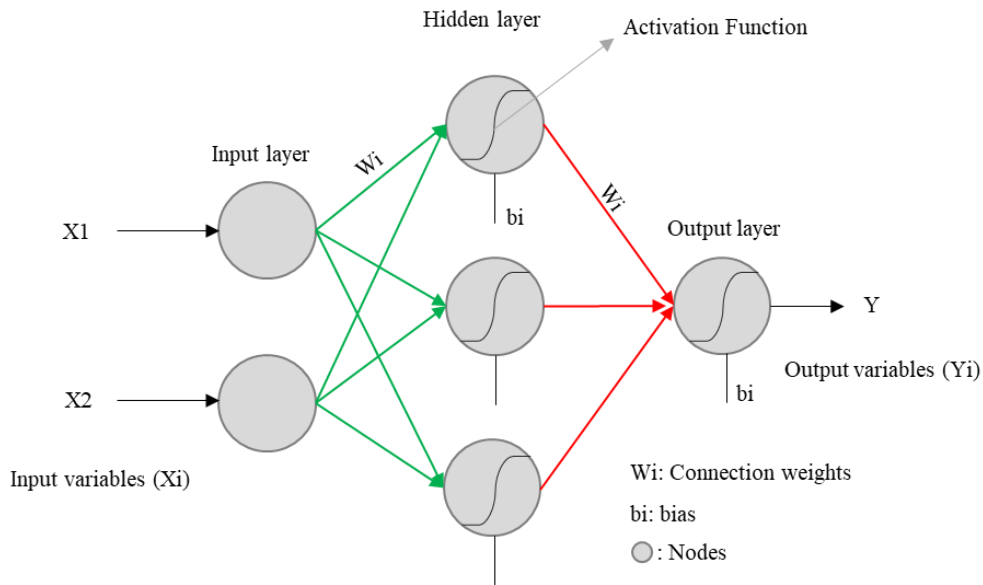


Fig. 1 Representation of a feedforward RNA with three layers

The unipolar sigmoid is the most used function for the activation of the intermediate layer neurons, due to the simplicity of its derivative. An activation function of the linear type can also be used for the neurons of the output layer. However, the use of non-linear functions for output, with later scaling, increases the model's ability to approximate non-linear behavior (FANTIN-CRUZ et al., 2011; OLIVEIRA et al., 2017; SARI; CASTRO; PEDROLLO, 2017). The unipolar sigmoid function and its derivative are defined by:

$$f(\eta) = \frac{1}{1+e^{-\eta}} \quad (2)$$

$$f'(\eta) = f(\eta) * (1 - f(\eta)) \quad (3)$$

where: η is the input of the neuron, defined as the result of $w_i I_i + b$.

During training, the synaptic weights of the connections and the bias are adjusted by a learning rule, whose goal is to minimize some measure of performance, based on the errors between the calculated and observed outputs (ASCE, 2000).

The initial values are chosen randomly (FREEMAN; SKAPURA, 1991; KASABOV, 1998). Several training should ideally be performed from different sets of random weights (with the choice of the final configuration of weights that provided the best performance for the neural network), since each training results in a different network due to the randomness of its initial condition.

The backpropagation algorithm (RUMELHART; HINTON; WILLIAMS, 1986) is a generalization of the Delta Rule (WIDROW; HOFF, 1960). In this algorithm the network is initially executed using the current weights, the errors in the layers, and the respective derivatives of its activation functions; and then, the updating of weights is done using Equation 4, in successive cycles of application of this rule with the set of training samples.

$$w_{k+1} = w_k - \tau e_k \delta_k I_k \quad (4)$$

where, for each layer: w_k are the synaptic weights of neurons; τ is the learning rate; e_k are the errors; δ_k are the derivatives of the activate functions; and I_k are the entries in the layer itself, in cycle k .

Errors in the outer layer are calculated by the difference between the expected values and the calculated values. However, in the inner layers, these errors (e_h) are calculated by equation 5:

$$e_h = \sum(W_{h+1} e_{h+1} \delta_{h+1}) \quad (5)$$

where: e_h is the error in the inner layer considered; W_{h+1} , e_{h+1} and δ_{h+1} are, respectively, the synaptic weights, the errors and the derivatives in the back layer.

ANN overfitting occurs when the number of neurons in the inner layers is excessive (excess degrees of freedom), and when the number of cycles performed is too large, causing excessive training of the network, which is characterized by the adjustment of the randomities present in the training sample (HECHT-NIELSEN, 1989). To prevent overfitting, it is performed a limitation of the ANN structure complexity (number of neurons in the inner layers), or the interruption of the training when stop conditions are reached.

Cross-validation is the most commonly used technique to avoid overfitting for the feedforward ANN. This technique uses a sample not applied in the training, called the validation sample, to perform an evaluation of the error throughout the training. The onset of overfitting occurs in the cycle where the error in the validation series begins to increase while the error in the training series continues to decrease. Thus, cross-validation acts as a determinant of the

ideal stopping point of the training, since training errors statistics are always decreasing (indicating better performance), while the error statistic in the validation series is raised again, indicating that a threshold has been reached. This threshold determines the moment the generalization capacity become compromised, and in which the algorithm must interrupt training. At the end, the trained network is submitted to a verification sample that did not participate in the training stage, to guarantee the generalization capacity of the model (HECHT-NIELSEN, 1989).

3.3. Materials and Methods

3.3.1. Study area

This study was carried out in the Brazilian portion of the Upper Paraguay River Basin (UPRB), covering an area of 362,380 km², where one of the largest wetlands on the planet is inserted: The Pantanal. The region (Fig. 2) is subdivided into two areas, according to distinct topographic and hydrological characteristics, a high-altitude region, denominated Planalto, and a lower and flat region, denominated Pantanal or plain. Pantanal is also the name given to the peculiar biome that forms in the plain.

The Planalto region represents 59 % of the basin area, with lands above 200 m of altitude, reaching more than 1,100 m, mainly in east and north parts. This part of the basin presents deep soils and high slopes, favoring rapid drainage and great sediment production.

The Pantanal plain represents 41% of the basin area. This region presents low, flat and humid lands with altitudes below 200 m. The gentle slope and the low river banks make the drainage system unable to transmit quickly the water received from the Planalto, and extensive areas are flooded, resulting in a complex hydrological and hydrosedimentological dynamics (BRAVO et al., 2012).

According to the Köppen-Geiger climate classification, the predominant climate in the UPRB is the tropical savanna, with rainfall concentrated in the summer. The average annual precipitation of UPRB varies from 1200 mm to 1600 mm, with the highest values occurring in the Planalto. About 80 % of the annual rainfall occurs in the rainy season, which runs from October to April (BRAVO et al., 2012).

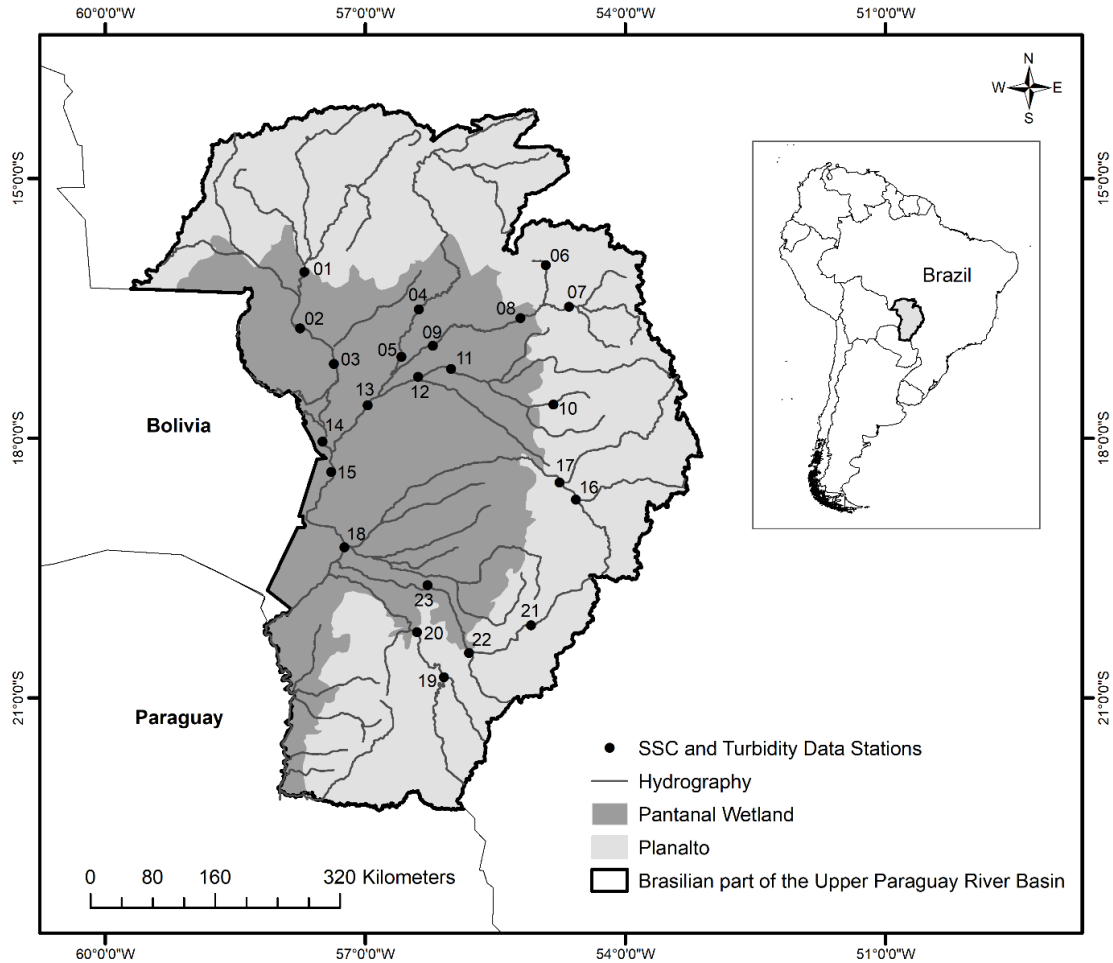


Fig. 2 Localization of the study area, showing the selected stations

3.3.2. Data

For this study, 23 stations with hydrometric data were selected for model construction due to the availability of coincident SSC, turbidity and flow data. The data were provided by the National Water Agency (ANA), in the National Hydrological Information System (Hidroweb) (www.hidroweb.ana.gov.br).

In Table 1, the information of the 23 stations is shown. The data refer to the period between 2009-06-19 and 2017-03-28, with an average of four records per year in each station. Most of the data collection refers to the rainy season (October to April).

The stations located in the Planalto have higher magnitudes of SSC in terms of maximum, mean and median concentrations, than those in the plain. This condition is due to the more sloping land and the properties of the soil types that favor greater sediment production. In addition, the stations of the plain have lower magnitudes of SSC, with some records (minimum)

equal to zero, because of the extremely flat hydrography and saturated soils, which benefit deposition processes.

Table 1 Information about selected stations

	Station Name	River	Drainage Area (Km ²)	SSC (mg/L)					
				Records	Min	Max	Mean	Median	SD
1	Cáceres	Paraguay	32,373	11	9.50	83.50	33.12	31.50	21.95
2	Descalvados	Paraguay	48,179	16	11.50	77.10	32.51	26.00	18.07
3	Porto Conceição	Paraguay	65,879	14	6.57	71.00	32.43	25.73	19.77
4	Porto Cercado	Cuiabá	37,024	14	27.50	182.10	59.31	52.74	39.07
5	Ilha Camargo	Cuiabá	39,006	15	16.10	156.20	64.66	71.00	38.15
6	São Pedro da Cipa	São Lourenço	3,267	16	6.70	1736.00	309.79	158.65	457.50
7	Rondonópolis	Vermelho	12,297	14	19.40	593.20	259.44	282.75	220.00
8	Acima do Córrego Grande	São Lourenço	23,105	18	39.54	481.00	163.27	96.10	136.36
9	São José do Boriréu	São Lourenço	24,844	15	76.00	432.00	201.18	162.80	109.52
10	Estrada BR-163	Correntes	3,969	12	2.00	162.70	23.88	4.17	45.93
11	São Jerônimo	Piquiri	23,315	15	5.50	85.10	21.51	16.60	18.71
12	São José do Piquiri	Piquiri	29,388	16	8.70	25.50	17.90	18.05	4.61
13	Porto do Alegre	Cuiabá	102,580	16	24.60	110.10	48.57	41.25	22.36
14	Amolar	Paraguay	72,642	10	0.00	90.50	34.93	23.48	27.54
15	São Francisco	Paraguay	185,113	10	0.00	57.00	28.12	24.20	19.12
16	Garimpagem	Jauru	6,328	14	98.10	1327.00	475.46	353.20	369.19
17	Coxim	Taquari	27,573	17	11.40	844.00	391.56	330.90	242.54
18	Porto da Manga	Paraguay	261,480	11	7.31	88.70	38.87	34.10	23.13
19	Estrada MT-738	Miranda	11,552	15	12.57	687.00	133.29	79.00	175.41
20	Miranda	Miranda	15,189	13	41.74	210.00	90.64	70.10	52.95
21	Ponte do Grego	Aquidauana	6,318	16	15.00	284.90	120.24	83.72	96.10
22	Aquidauana	Aquidauana	15,707	16	19.33	337.60	116.65	101.41	77.01
23	Porto Ciriaco	Aquidauana	17,190	12	20.70	487.00	104.44	75.96	125.30

The elevation of UPRB (Fig. 3) was obtained from a DEM (digital elevation model) of the SRTM (Shuttle Radar Topography Mission), with spatial resolution of 30 m, made available by the United States Geological Survey (USGS). The Arc Hydro Tools, from ArcGIS 10.3.1, was used to extract drainage area and mean slope data for the selected stations.

The soil classes were extracted from the Brazilian soil type map (with a scale of 1:5,000,000), which follows the Brazilian soil classification system (SiBCS) (SANTOS et al., 2018). Although SiBCS has similarities with other international taxonomic systems, it has been chosen because it aggregates information specific to Brazilian tropical soils, and therefore direct transcription to other systems is not viable. Classifications were used until the third categorical level, totaling 29 classes, including water (Fig. 4). The most frequent soil types in UPRB are the Neossolos Quartzarenicos Orticos, Argissolos Vermelho-Amarelos Distróficos, Latossolos Vermelhos Distróficos and Argissolos Vermelhos Eutróficos.

The land use and vegetation cover were characterized (Fig. 5) from a map of the Brazilian Agricultural Research Corporation, referring to 2014 (EMBRAPA, 2015). The most frequent uses are Pasture, Agriculture, Arborized Savanna and Grassland/Shrub Savanna.

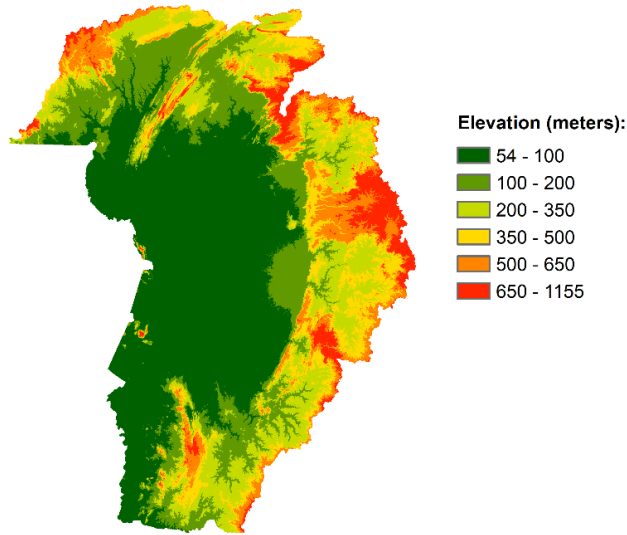


Fig. 3 Digital elevation model from SRTM of the Upper Paraguay River Basin

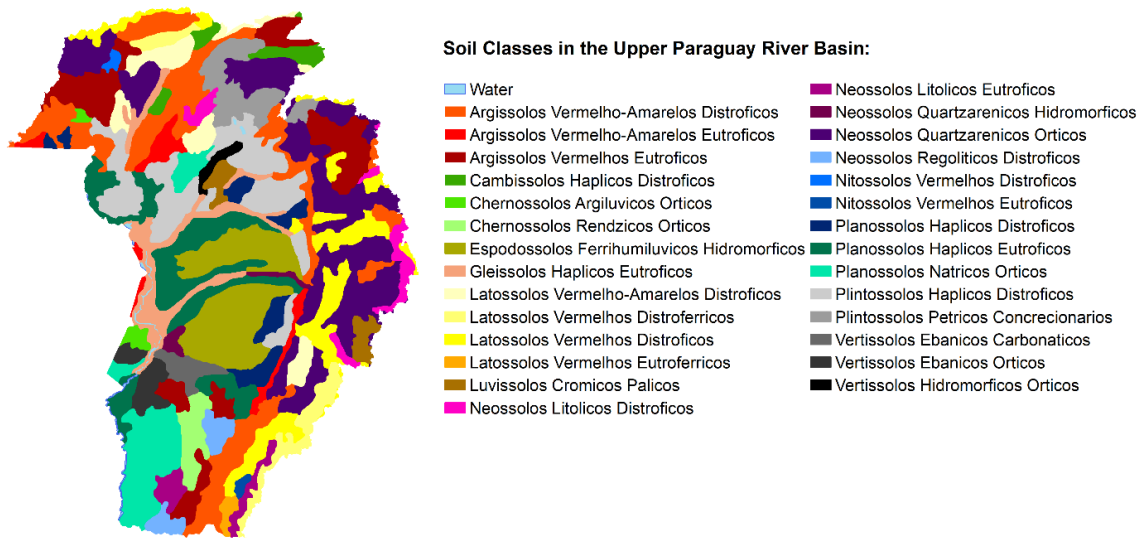


Fig. 4 Soil type in the Upper Paraguay River Basin, according to the new Brazilian soil classification system

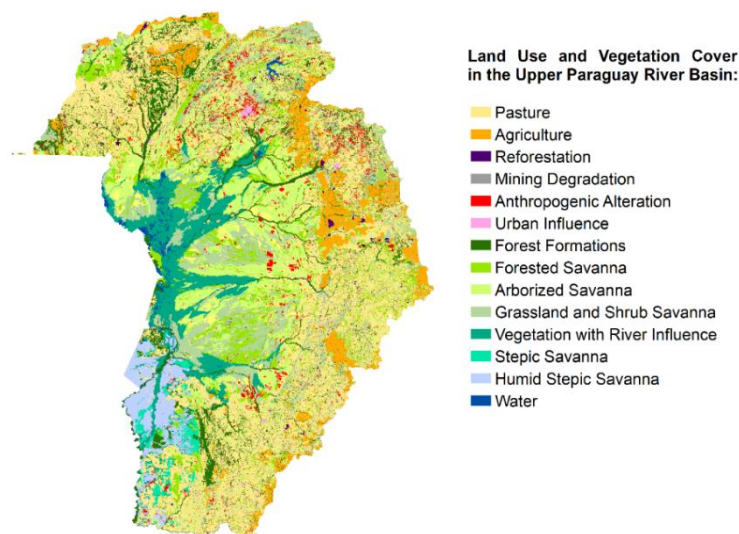


Fig. 5 Land use and vegetation cover type in the Upper Paraguay River Basin

The MERGE product uses estimated rainfall data by remote sensing to fill rainfall information in locations with insufficient *in situ* monitoring. A radius of influence is assigned to the observed data, and from this, the precipitation data estimated through satellite are used to compose the missing information. The estimated rainfall by satellites is obtained from the TRMM-TMPA (Tropical Rainfall Measuring Mission - Multisatellite Precipitation Analysis) for the period 1998 to 2014, and by GPM-IMERG (Global Multisatellite Retrieval Measurement - GPM) for the 2015 to the current time. Further details are found in Rozante et al. (2010).

The data are available in grids of 20 km, whose precipitations are accumulated every 24 hours, from 1998 to the current time. The MERGE product was downloaded for the period from January 2008 to December 2017, which covers the data period of the SSC measurements. The data were extracted for each drainage area and interpolated for the 23 stations using the inverse square distance method (BURROUGH; MCDONNELL, 1998).

3.3.3. Input and output model variables

For the development of the regional SSC estimation model, 326 sediment concentration records were used from the 23 selected stations. The variables turbidity, discharge, drainage area, soil type, land use and vegetation cover, average slope, rainfall and exponentially weighted moving averages of past rainfalls (EWMA) were tested as inputs to the ANN models.

The exponentially weighted moving averages of past rainfalls (EWMA) technique was proposed by Moore (1980) to represent soil moisture conditions in prediction models based on

precipitation series. This resource assigns greater weights to more recent precipitations in the composition of the moving average. This procedure promotes the synthesis of recent precipitation information in the form of a representative value, resulting in more parsimonious models.

Oliveira et al. (2017) estimated the spatial and temporal variation of soil water content in the Taboão river basin (Southern Brazil), applying Artificial Neural Network (ANN) models, using as input the EWMA of past rainfalls, climatic information, physical characteristics of the soil and topographic variables. The use of rainfall EWMA in the models promoted better performance in relation to the models that use isolated or accumulated rainfall data.

The EWMA is applied in time series of precipitation with constant intervals, according to Equation 6.

$$EWMA_t = \sum_{i=0}^{\infty} w_i P_{t-i} \quad (6)$$

where: $w_i = \alpha (1 - \alpha)^i$; P_{t-i} is the precipitation that occurred at time $t-i$; and α is a constant, in units of time.

The constant α relates to a parameter called half-life (h):

$$\alpha = 1 - 0,5^{(1/h)} \quad (7)$$

The half-life represents the amount of time steps, towards the past, in which the sum of the weights for the composition of the moving average is halved. The choice of a half-life (for example, $h = 2$) means that the precipitation that makes up the EWMA has its importance halved ($w_1 = 0.293$ and $w_2 = 0.207$) in two of the previous time intervals. As the half-live gets bigger, the importance given to the past rainfalls increases.

Since the length of the weight series is undefined, it should be truncated from a minimum value toward the past. Therefore, it is more practical to use a recursive equation (equation 8):

$$EWMA_t = (1 - \alpha) EWMA_{t-1} + \alpha P_t \quad (8)$$

The exponentially weighted moving average rainfall filter (EWMA) was applied to the precipitation data obtained from the MERGE product, for the 23 points of analysis, considering the half-life parameters $h = 1, 2, 5, 10, 15, 20, 25$ and 30 days.

3.3.4. Model development

Several models were developed to estimate the SSC, from 53 input variables: Turbidity; Discharge; Rainfall; EWMA of Rainfall with half-life parameters equal to 1, 2, 5, 10, 15, 20, 25 and 30 days; Drainage Area; Average Slope; 26 soil type classes and 14 land use and vegetation cover classes. From a complete model, with all input variables proposed, other models were developed, leaving out one variable each time, to verify its importance.

The back-propagative algorithm (RUMELHART; HINTON; WILLIAMS, 1986), along with training acceleration techniques (VOGL et al., 1988), as well as other needed functions, were programmed in Matlab[®] R2012b environment, for the research of feedforward ANNs models with one intermediate layer and with neurons composed by unipolar sigmoid functions. Overfitting was avoided using the cross-validation technique (HECHT-NIELSEN, 1989).

The complexity of the networks (number of neurons in the intermediate layer) was defined by the architecture search with the lowest possible complexity that still has the same approximation and generalization capacity of a purposely oversized network, which in turn does not present overfitting due to the timely interruption training (cross-validation). Therefore, from an ANN initially oversized, each network was trained by reducing the number of neurons in the intermediate layer until a performance reduction occurs, which results from the lack of degrees of freedom due to insufficient complexity. Then, the previous alternative, with enough degrees of freedom, is chosen.

For cross-validation training, the data were divided into three parts (training, validation and verification), using the systematic sampling method of the domain, so that the data of all the stations are present in the three samples. The validation sampling, besides its usefulness for cross-validation, also served to define the complexity, allowing the comparison of the statistics resulting from its application to those of an initial network, purposely oversized. In this way, the verification sample, when applied, was a sample that did not participate, either in training or in the choice of the neural network architecture. Samples were separated into 196 records for training, 55 records for validation and 75 records for verification. The extreme values (maximum and minimum) of all variables were included in the training samples. The cycles were set at 100,000.

Each cross-validation training performs five repetitions, each with random initiations of the synaptic weights, adopting the repetition weights that resulted, in the validation sampling, the best final performance, to minimize the influence of random initialization on the results.

3.3.5. Performance statistics

The evaluation of the performance of the models was realized based on the statistics of the errors between the output from the network and the observed output. These statistics were the mean absolute error - E_a (Mean), the maximum absolute error - E_a (max), the median absolute error - E_a (50), the 95 % percentile of the absolute errors - E_a (95) and the Nash-Sutcliffe or NS efficiency coefficient (Nash and Sutcliffe 1970). The NS calculation is defined by:

$$NS = 1 - \frac{\sum_{i=1}^N (T_i - Y_i)^2}{\sum_{i=1}^N (T_i - T_{mean})^2} \quad (9)$$

where: T_i are the observed data; T_{mean} is the mean of the observed data; and Y_i are the data calculated by the model. The NS ranges from $-\infty$ to 1, near values of 1 represent good approachability; values \leq zero indicate that the T_{mean} is a better approximation than the calculated values of Y_i .

3.4. Results and Discussion

3.4.1. Analysis of descriptive statistics

Table 2 shows the descriptive statistics of all variables and the Pearson correlation coefficient (R) between the input variables and the SSC. The data were collected at 23 different points of the basin, and therefore the magnitudes of their variables are quite different, according to the characteristics related to their location in the basin. The soil type classes (items 16 to 41) and soil use (items 42 to 55) are presented as percentages of the basin area.

Median equals or close to zero indicate that the variable has many records with values equal to zero, as with the percentages of some soil type classes and land use, which occur only in small portions of the UPRB.

The effect of past rainfalls is observed in the value of EWMA median. For the daily rainfall, the median was equal to zero (indicating that more than 50 % of the rainfall data is zero), but for EWMA of rainfalls it was higher than zero, since even if rainfall is zero, EWMA of rainfall aggregate information that occurred in the days prior to the collection of SSC.

Preliminary analyzes of the relationship between the variables and the SSC were made using the Pearson linear correlation coefficient, calculating the corresponding p-value

(probability of error with rejection of the hypothesis H0, that there is no linear relation), using the Student's distribution for the known transformation of the correlation, and comparing this p-value with significance level of 0.05 (Student 1908).

Table 2 Descriptive statistics of variables used as input and output to the ANN models

	Model input and output variables	Min	Max	Mean	Median	SD	R
1	Turbidity (NTU)	0	1262	76.56	37.50	126.14	0.59
2	Discharge (m ³ /s)	9.08	2488.89	370.96	214.82	454.71	-0.17
3	Daily Rainfall (mm)	0	109.47	3.13	0	9.92	0.06*
4	EWMA of Rainfall h=1 (mm)	0	55.23	3.03	0.79	5.79	0.09*
5	EWMA of Rainfall h=2 (mm)	0	33.61	3.08	1.67	4.29	0.11
6	EWMA of Rainfall h=5 (mm)	0	17.08	3.05	2.37	3.02	0.15
7	EWMA of Rainfall h=10 (mm)	0.01	13.76	3.04	2.55	2.46	0.17
8	EWMA of Rainfall h=15 (mm)	0.03	12.07	3.07	2.68	2.27	0.18
9	EWMA of Rainfall h=20 (mm)	0.08	10.82	3.11	2.78	2.16	0.18
10	EWMA of Rainfall h=25 (mm)	0.18	10.15	3.15	2.83	2.07	0.18
11	EWMA of Rainfall h=30 (mm)	0.28	9.88	3.18	2.79	1.98	0.18
12	Drainage Area (km ²)	3267	261479.74	41764.11	24844.29	54593.27	-0.22
13	Average Slope (%)	3.32	9.50	6.07	5.80	1.63	0.45
14	Argissolos Vermelho-Amarelos Distroficos ¹	0	34.85	13.08	10.90	8.87	-0.33
15	Argissolos Vermelho-Amarelos Eutroficos ¹	0	4.57	0.51	0	1.24	-0.18
16	Argissolos Vermelhos Eutroficos ¹	0	51.07	12.19	10.81	13.73	0.12
17	Cambissolos Haplicos Distroficos ¹	0	7.94	1.70	0	2.62	-0.27
18	Chernossolos Argiluvicos Orticos ¹	0	1.08	0.13	0	0.30	-0.20
19	Chernossolos Rendzicos Orticos ¹	0	7.72	0.47	0	1.65	-0.03*
20	Espodossolos Ferrihumiluvicos Hidromorficos ¹	0	10.92	1.50	0	3.04	-0.24
21	Gleissolos Haplicos Eutroficos ¹	0	5.69	1.80	0.19	2.17	-0.36
22	Latossolos Vermelho-Amarelos Distroficos ¹	0	14.00	2.86	0	4.32	-0.27
23	Latossolos Vermelhos Distroferricos ¹	0	45.69	6.61	0	12.82	-0.06*
24	Latossolos Vermelhos Distroficos ¹	0	61.81	12.41	8.60	12.04	-0.03*
25	Latossolos Vermelhos Eutroferricos ¹	0	5.31	0.41	0	1.34	-0.02*
26	Luvissolos Cromicos Palicos ¹	0	9.58	1.04	0	2.26	0.32
27	Neossolos Litolicos Distroficos ¹	0	13.40	1.98	1.10	3.48	0.48
28	Neossolos Litolicos Eutroficos ¹	0	10.02	1.11	0	2.67	-0.03*
29	Neossolos Quartzarenicos Hidromorficos ¹	0	0.70	0.03	0	0.13	-0.10*
30	Neossolos Quartzarenicos Orticos ¹	0	80.92	25.63	21.60	16.64	0.46
31	Neossolos Regoliticos Distroficos ¹	0	18.24	0.93	0	3.66	-0.04*
32	Nitossolos Vermelhos Distroficos ¹	0	2.39	0.27	0	0.59	-0.21
33	Nitossolos Vermelhos Eutroficos ¹	0	6.45	0.49	0	1.63	-0.02*
34	Planossolos Haplicos Distroficos ¹	0	9.03	1.13	0	2.40	-0.22
35	Planossolos Haplicos Eutroficos ¹	0	7.25	1.17	0	1.99	-0.25
36	Planossolos Natricos Orticos ¹	0	4.02	0.37	0	1.05	-0.17

Table 2 (Continued)

	Model input and output variables	Min	Max	Mean	Median	SD	R
37	Plintossolos Haplicos Distróficos ¹	0	22.7	6.03	0.05	7.70	-0.35
38	Plintossolos Petricos Concrecionarios ¹	0	36.53	5.67	0	10.44	0.05*
39	Vertissolos Ebanicos Carbonaticos ¹	0	0.38	0.02	0	0.07	-0.04*
40	Pasture ²	24.96	67.41	42.18	39.27	13.49	0.28
41	Agriculture ²	0.86	23.21	11.16	10.22	6.08	-0.03*
42	Reforestation ²	0	3.62	0.59	0.42	0.70	-0.12
43	Mining Degradation ²	0	0.23	0.03	0	0.06	0.11
44	Anthropogenic Alteration ²	1.42	8.34	3.78	2.73	2.11	0.01*
45	Urban Influence ²	0.02	0.85	0.33	0.26	0.23	-0.01*
46	Forest Formations ²	0.12	20.75	8.96	8.09	4.31	-0.17
47	Forested Savanna ²	3.34	16.19	7.32	8.16	3.32	0.15
48	Arborized Savanna ²	3.40	26	11.54	8.38	7.30	-0.35
49	Grassland and Shrub Savanna ²	5.15	19.52	11.41	10.89	4.05	0.09*
50	Vegetation with River Influence ²	0	10.11	1.54	0	2.67	-0.24
51	Stepic Savanna ²	0	0.01	0	0	0	-0.08*
52	Humid Stepic Savanna ²	0	0.02	0	0	0	-0.22
53	Water ²	0	1.5	0.37	0.17	0.46	-0.24
54	Suspended Sediment Concentration (mg/L)	0	1736	128.68	51.45	200.59	1

* p-value > 0.05; ¹ Soil type classes, in percentages; ² Land use and vegetation cover classes, in percentages

The turbidity presented the best positive correlation with SSC ($R = 0.59$, $p < 0.05$). The discharge showed a negative correlation ($R = -0.17$, $p < 0.05$), which corroborates the hypothesis that in the stations upstream of the basin (Planalto), where flows are smaller and slopes are steeper, the concentration of suspended sediments is larger, whereas downstream, in the Plain, where the flow rates are higher, and the flat terrain favors deposition, the SSC magnitudes are smaller. The daily rainfall did not present a good correlation with the SSC, but the EWMA of the past rainfalls provides a slight increase in this coefficient.

The soil classes that presented the highest positive correlation with SSC are the Neossolos Litólicos Distróficos ($R=0.48$, $p<0.05$), Neossolos Quartzarenicos Orticos ($R=0.46$, $p<0.05$) and the Luvisolos Cromicos Palicos ($R=0.32$, $p<0.05$), which occur more in the Planalto, and the soil classes that presented the greatest negative correlations were the Gleissolos Haplicos Eutróficos ($R= -0.36$, $p<0.05$), Plintossolos Haplicos Distróficos ($R= -0.35$, $p<0.05$) and the Argissolos Vermelho-Amarelos Distróficos ($R= -0.33$, $p<0.05$), which occur mainly in the Plain.

As for land use and vegetation cover, the class with the highest positive correlation was Pasture ($R = 0.28$, $p < 0.05$), which is more frequent in the Planalto, and the classes with the highest negative correlation were Arborized Savanna ($R = -0.36$, $p < 0.05$), Water ($R = -0.24$,

$p < 0.05$) and Vegetation with River Influence ($R = -0.24$, $p < 0.05$), which is more frequent in the Plain.

Although the mean slope shows a good linear correlation (r) with SSC, the slopes varied between 3.32% and 9.5%, not showing a great variation. This happens because most of the stations are in flatter regions.

3.4.2. Regional estimation of suspended sediment concentration using ANN based models

Table 3 shows the performance statistics for the ANN models developed to estimate the suspended sediments concentration in the Upper Paraguay River Basin. The models were developed initially considering all 53 input variables, including variables without significant linear correlation. From these, other models were tested, leaving variables or groups of variables out, and evaluating the final performance of the network.

The NS efficiency coefficient ranged from 0.499 to 0.835 during training and from 0.382 to 0.832 during the verification, considered to be very satisfactory for most models ($0.75 < NS \leq 1.00$, according to the classification of Moriasi et al. (2007) for sediment models), both in training and in verification.

In the first model (M01), in which were considered all input variables, the verification performance was $NS = 0.794$, $E_a(\text{mean}) = 48.19 \text{ mg/L}$, $E_a(50) = 27.80 \text{ mg/L}$, $E_a(95) = 187.51 \text{ mg/L}$ and $E_a(\text{max}) = 285.01 \text{ mg/L}$. In Fig. 6, the error distribution and the approximation of observed and simulated data for the M01 model in the training and verification are shown.

In the model M02, in which the turbidity was left out, it was observed a considerable reduction in the network performance in relation to M01, both in training and in verification, showing that turbidity is a very important variable for the main model. However, in the simpler models, in which only the turbidity was used as input (M20), or turbidity and discharge (M21), the performance was also not satisfactory. This shows that the assertiveness of the model is the result of the combination of several variables, not only turbidity.

Turbidity is an easier variable to obtain than SSC, and therefore, there is a wide acceptance of its use as an indirect representative of the suspended sediment concentration. However, the transformation of turbidity readings into SSC depends on some factors such as size, shape, color, refractive index, density and mineralogical composition of the sediment

particle (Sari et al. 2015). As the model data are from different parts of the basin, the other attributes inserted (mainly soil type classes) give the models that include these variables the ability to differentiate these factors.

Table 3 Statistical performance of ANN models, showing statistics based on errors and NS, in the training and final verification

Model	nh ¹	J ²	Variables excluded	Training					Verification				
				E _a (mean)	E _a (50)	E _a (95)	E _a (max)	NS	E _a (mean)	E _a (50)	E _a (95)	E _a (max)	NS
M01	5	530	None	50.22	27.89	161.69	528.69	0.835	48.19	27.80	187.51	285.01	0.794
M02	4	130	Turbidity	72.98	32.05	299.16	1330.54	0.599	78.14	32.00	278.31	406.87	0.519
M03	4	241	Discharge	51.10	27.47	183.53	543.38	0.822	49.70	29.77	183.01	277.57	0.789
M04	5	332	Rainfall	51.41	27.58	182.01	535.59	0.825	49.24	29.96	181.96	278.09	0.793
M05	4	224	EWMA of Rainfall h=1	52.34	27.53	177.60	540.05	0.815	49.81	31.16	178.30	279.63	0.792
M06	4	183	EWMA of Rainfall h=2	52.12	27.05	176.21	539.03	0.816	50.30	29.03	179.63	271.77	0.788
M07	4	281	EWMA of Rainfall h=5	51.44	27.28	174.94	538.27	0.821	50.35	30.43	187.03	289.83	0.781
M08	4	248	EWMA of Rainfall h=10	51.57	26.85	179.23	536.70	0.820	50.88	31.99	183.37	272.78	0.781
M09	4	257	EWMA of Rainfall h=15	51.75	27.36	180.34	536.30	0.819	50.87	32.49	183.38	267.69	0.781
M10	4	322	EWMA of Rainfall h=20	50.82	28.05	177.01	537.58	0.826	49.81	28.99	178.10	280.93	0.785
M11	4	277	EWMA of Rainfall h=25	51.07	26.05	177.76	539.38	0.822	50.27	29.86	187.76	285.07	0.783
M12	4	272	EWMA of Rainfall h=30	51.53	27.24	182.83	539.00	0.820	50.29	29.46	176.82	284.36	0.785
M13	3	484	All EWMA of Rainfall	54.16	29.99	167.92	528.02	0.803	54.16	30.00	170.59	298.57	0.769
M14	4	238	Drainage area	52.58	26.92	177.23	537.85	0.813	51.01	30.03	187.54	272.40	0.783
M15	4	169	Average slope	51.77	26.47	181.25	540.59	0.818	50.84	30.56	182.08	257.75	0.781
M16	3	545	Soil type classes	49.88	26.58	168.79	584.05	0.828	49.20	33.98	148.03	341.63	0.772
M17	4	323	Land use classes	50.93	27.46	192.54	536.88	0.819	49.91	29.73	182.92	283.43	0.774
M18	3	887	Soil type and land use classes	63.16	33.44	193.48	621.93	0.748	63.99	44.07	222.62	418.31	0.628
M19	5	487	All with p>0.05	50.29	28.57	175.97	565.13	0.826	42.21	23.85	160.74	280.06	0.832
M20	2	450	All, except Turbidity	87.70	53.12	258.33	876.98	0.511	81.55	54.83	284.88	597.17	0.382
M21	2	562	All, except Turbidity and Discharge	84.66	52.25	258.47	863.13	0.519	79.96	59.25	268.93	582.02	0.404

¹ Number of nodes in hidden layer; ² Number of cycles needed for the best model result, without overtraining occurrence

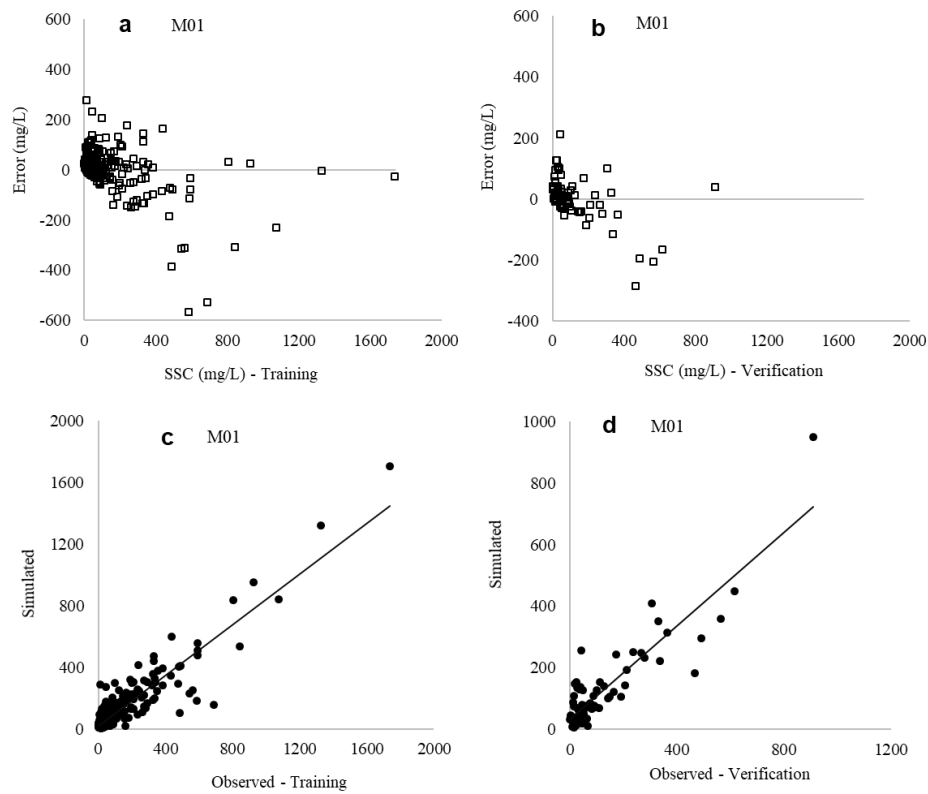


Fig. 6 Verified error between the calculated and observed SSC values (a, b) and observed and calculated SSC in relation to the ideal fit (c, d), from model M01

The models M03 to M17 presented similar performance statistics in the verification, with a very satisfactory NS ($NS > 0.75$). The exclusion of a variable or group of variables caused a slight reduction in the performance of the models in the verification process, in relation to the complete model (M01).

The performance statistics of M04 are very similar to M01, showing that rainfall has no great influence on SSC estimation. However, EWMA of past rainfalls were proved to be important. Exclusion of EWMA, both individually (M05 to M12) and jointly (M13), reduced the performance (increase in statistics based on errors and reductions in NS coefficient), relative to M01. Generally, rainfall is more monitored than SSC in watersheds, evidencing the potential of using EWMA of past rainfalls in SSC estimation and forecasting models.

The models M14 and M15 also presented a small reduction in the performance in relation to the complete model, indicating that the average slope of the basin and drainage area are attributes that contribute positively to the estimation of the SSC. However, the models without these variables still presented very satisfying results (NS of the verification equal to 0.783 for M14 and 0.781 for M15). Although slope is a characteristic that presents a high positive

correlation with SSC, its insertion in the model was not significant since most of the stations used were in flat areas of the basin, making this variable not so relevant in this application.

Soil type and land use classes were also important in SSC estimation. The models M16 and M17 (NS of 0.772 and 0.774 in the verification) presented a reduction in the performance in relation to the M01; and for the model M18, in which the two sets of classes were excluded, the performance worsened even more (NS of 0.628 in the verification).

A model (M19) was tested disregarding all input variables that presented p -value > 0.05 , that is, variables whose correlation with sediments is more than 5 % chance of being random (rainfall, EWMA of past rainfall with $h = 1$, and some classes of soil type and land use, according to Table 2). The M19 model obtained the best performance among all the tests performed, presenting an NS of 0.832 in the verification, and lower error statistics. The evaluated statistics were E_a (mean) = 42.21 mg/L, E_a (50) = 23.85 mg/L, E_a (95) = 160.74 mg/L and E_a (max) = 280.06 mg/L. In Fig. 7, the error distribution and the approximation of observed and simulated data for the training and verification of the M19 model is shown.

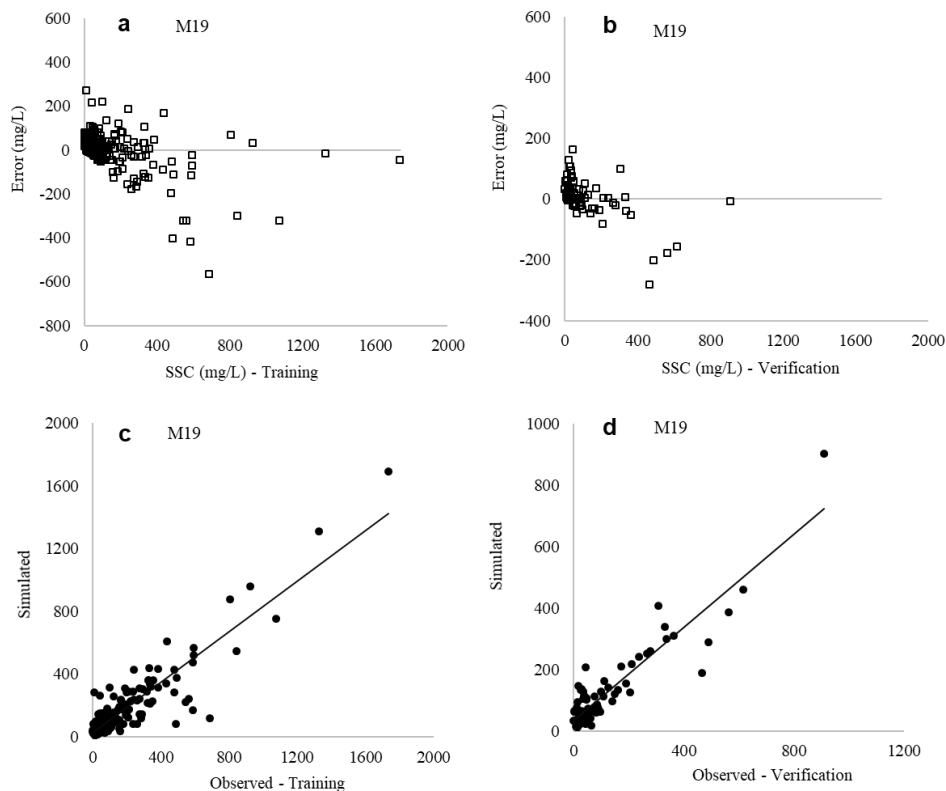


Fig. 7 Verified error between the calculated and observed SSC values (a, b) and observed and calculated SSC in relation to the ideal fit (c, d), from model M19

Although most models require large data manipulation to select the input variables, the performance is quite satisfactory in most of the tests presented, indicating that it was possible to establish a regional estimation of SSC in the Upper Paraguay River Basin, even with the scarcity of data observed in this region. The joint use of the EWMA of past rainfalls improved the models, as well as the insertion of classes of soil type and land use with correlations above the limit of the established significance.

3.5. Conclusions

Several models for the estimation of suspended sediment concentration were developed for the Upper Paraguay River Basin, the hydrographic region where the largest tropical wetland of the planet (Pantanal) is located, using the technique of artificial neural networks, with a performance considered very satisfying for sediments. All models presented resulted from a minimum complexity analysis, conditioned by the absence of loss in generalization, compared with a preliminary model, purposely oversized.

The complete model (M01), in which all input variables considered were used, presented a very satisfying performance ($NS = 0.794$ on verification), however, an alternative model (M19), in which variables whose p-value was greater than 0.05 were disregarded, presented the best performance ($NS = 0.832$ on verification).

In relation to the input variables, turbidity was more important in the model composition, followed by soil type, land use and EWMA of past rainfalls. The insertion of the exponentially weighted moving averages of the past rainfalls improved the performance of the model, evidencing that these variables can be more exploited in sediment estimation models.

The results obtained in this research show that a regional estimation model of SSC was developed for the Upper Paraguay River Basin, despite the scarcity of data observed. However, limitations on data domain extrapolations should be analyzed in future applications.

Much of the hydrosedimentological modeling studies with ANNs are focused on a single fluvimetric station, which usually has a higher frequency of suspended sediment data. However, the reality of most of the hydrographic basins on the planet is of low sampling frequency of this variable, making difficult calibration and validation of models.

The union of SSC data from several fluviometric stations with low sampling frequency provided an increase in the number of records for modeling, allowing the training of ANNs. This approach appears to be a potential tool in SSC estimation in ungauged basins.

3.6. References

ADAMOWSKI, Jan; SUN, Karen. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. **Journal of Hydrology**, [s. l.], v. 390, n. 1–2, p. 85–91, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2010.06.033>>

AFAN, Haitham Abdulmohsin et al. ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. **Water Resources Management**, [s. l.], v. 29, n. 4, p. 1231–1245, 2014.

AGARWAL, Avinash et al. Simulation of Runoff and Sediment Yield using Artificial Neural Networks. **Biosystems Engineering**, [s. l.], v. 94, n. 4, p. 597–613, 2006.

AGARWAL, Avinash; SINGH, R. D. Runoff modelling through back propagation artificial neural network with variable rainfall-runoff data. **Water Resources Management**, [s. l.], v. 18, n. 3, p. 285–300, 2004.

ALLASIA, Daniel G. et al. **Modelo Hidrológico da Bacia do Alto Paraguai**. Porto Alegre-RS: Editora Rios Vivos, 2004.

ASCE. Artificial Neural Networks in Hydrology. I: Preliminary Concepts. In: **Journal Of hydrologic engineering**., 2000.

ATIEH, M. et al. Integrative neural networks model for prediction of sediment rating curve parameters for ungauged basins. **Journal of Hydrology**, [s. l.], v. 531, p. 1095–1107, 2015.

BAO, Zhenxin et al. Comparison of regionalization approaches based on regression and similarity for predictions in ungauged catchments under multiple hydro-climatic conditions. **Journal of Hydrology**, [s. l.], v. 466–467, p. 37–46, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.07.048>>

BAYRAM, Adem et al. Prediction of suspended sediment concentration from water quality variables. **Neural Computing and Applications**, [s. l.], v. 24, n. 5, p. 1079–1087, 2014. Disponível em: <<http://link.springer.com/10.1007/s00521-012-1333-3>>

BAYRAM, Adem; KANKAL, Murat; ÖNSOY, Hızir. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. **Environmental Monitoring and Assessment**, [s. l.], v. 184, n. 7, p. 4355–4365, 2012.

BERTONI, Jose; NETO, Francisco Lombardi. Conservação do Solo. In: 8ª ed. [s.l.] : Icone, 2006. p. 360.

BHATTACHARJYA, Rajib Kumar; CHAURASIA, Sandeep. Geomorphology Based Semi-Distributed Approach for Modelling Rainfall-Runoff Process. **Water Resources Management**, [s. l.], v. 27, n. 2, p. 567–579, 2013.

BONAN, Gordon. **Ecological Climatology**. 3. ed. Cambridge: Cambridge University Press, 2016.

BRAVO, J. M. et al. Coupled Hydrologic-Hydraulic Modeling of the Upper Paraguay River Basin. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 5, p. 635–646, 2012. Disponível em: <<http://ascelibrary.org/doi/10.1061/%28ASCE%29HE.1943-5584.0000494>>

BURROUGH, Peter A.; MCDONNELL, Rachael A. Data models and axioms: formal abstractions of reality. **Principles of geographical information systems**, [s. l.], p. 17–34, 1998. Disponível em: <<http://www.jstor.org/stable/144481?origin=crossref>>

BUYUKYILDIZ, Meral; KUMCU, Serife Yurdagul. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. **Water Resources Management**, [s. l.], v. 31, n. 4, p. 1343–1359, 2017.

CARVALHO, N. **Hidrossedimentologia prática**. 2^a ed. Rio de Janeiro: Interciência, 2008.

CHAI, Soo-See et al. Use of Soil Moisture Variability in Artificial Neural Network Retrieval of Soil Moisture. **Remote Sensing**, [s. l.], v. 2, n. 1, p. 166–190, 2009. Disponível em: <<http://www.mdpi.com/2072-4292/2/1/166/>>

CIGIZOGLU, Hikmet Kerem. Estimation, forecasting and extrapolation of river flows by artificial neural networks. **Hydrological Sciences Journal**, [s. l.], v. 48, n. 3, p. 349–362, 2003. a.

CIGIZOGLU, Hikmet Kerem. Incorporation of ARMA models into flow forecasting by artificial neural networks. **Environmetrics**, [s. l.], v. 14, n. 4, p. 417–427, 2003. b.

CIGIZOGLU, Hikmet Kerem; KISI, Özgür. Methods to improve the neural network performance in suspended sediment estimation. **Journal of Hydrology**, [s. l.], v. 317, n. 3–4, p. 221–238, 2006.

CROWDER, D. W.; DEMISSIE, M.; MARKUS, M. The accuracy of sediment loads when log-transformation produces nonlinear sediment load-discharge relationships. **Journal of Hydrology**, [s. l.], v. 336, n. 3–4, p. 250–268, 2007.

D. N. MORIASI et al. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. **Transactions of the ASABE**, [s. l.], v. 50, n. 3, p. 885–900, 2007.

DORNELLES, Fernando; GOLDENFUM, Joel Avruch; PEDROLLO, Olavo Correa. Artificial Neural Network Methods Applied to Forecasting River Levels. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 18, p. 45–54, 2013.

EMBRAPA. **Monitoramento das alterações da cobertura vegetal e uso do Solo na Bacia do Alto Paraguai – Porção Brasileira – Analysis period: 2012 to 2014**. 2015. Disponível

em:

<https://d3nehc6yl9qzo4.cloudfront.net/downloads/publicacao_bap_sumarioexecutivo_2012_2014_web.pdf>. Acesso em: 2 abr. 2018.

ESTEVES, Francisco De Assis. Fundamentos de Limnologia. In: **Interciência**. 2. ed. Rio de Janeiro. p. 226.

FAGUNDES, Hugo de Oliveira. **Modelagem Hidrossedimentológica de Grandes Bacias com Apoio de Dados In Situ e Sensoriamento Remoto**. 2018. Universidade federal do Rio Grande do Sul, [s. l.], 2018.

FANTIN-CRUZ, Ibraim et al. Historical reconstruction of floodplain inundation in the Pantanal (Brazil) using neural networks. **Journal of Hydrology**, [s. l.], v. 399, n. 3–4, p. 376–384, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2011.01.014>>

FANTIN-CRUZ, Ibraim et al. Effects of a diversion hydropower facility on the hydrological regime of the Correntes River, a tributary to the Pantanal floodplain, Brazil. **Journal of Hydrology**, [s. l.], v. 531, p. 810–820, 2015.

FANTIN-CRUZ, Ibraim et al. Changes in river water quality caused by a diversion hydropower dam bordering the Pantanal floodplain. **Hydrobiologia**, [s. l.], v. 768, n. 1, p. 223–238, 2016.

FASHI, Fereshte Haghghi. Evaluation of adaptive neural-based fuzzy inference system approach for estimating saturated soil water content. **Modeling Earth Systems and Environment**, [s. l.], v. 2, n. 4, p. 1–6, 2016. Disponível em: <<http://link.springer.com/10.1007/s40808-016-0255-y>>

FREEMAN, James A.; SKAPURA, David M. Neural Networks: Algorithms, Applications and Programming Techniques. In: **Addison-Wesley Publishing Company**. California. v. 7p. 89–124.

GIUSTOLISI, O.; LAUCELLI, D. Improving generalization of artificial neural networks in rainfall–runoff modelling. **Hydrological Sciences Journal**, [s. l.], v. 50, n. 3, p. 37–41, 2005.

HAIMANN, Marlene et al. An integrated suspended sediment transport monitoring and analysis concept. **International Journal of Sediment Research**, [s. l.], v. 29, n. 2, p. 135–148, 2014. Disponível em: <[http://dx.doi.org/10.1016/S1001-6279\(14\)60030-5](http://dx.doi.org/10.1016/S1001-6279(14)60030-5)>

HARRINGTON, Seán T.; HARRINGTON, Joseph R. An assessment of the suspended sediment rating curve approach for load estimation on the Rivers Bandon and Owenabue, Ireland. **Geomorphology**, [s. l.], v. 185, p. 27–38, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.geomorph.2012.12.002>>

HASSAN-ESFAHANI, Leila et al. Spatial Root Zone Soil Water Content Estimation in Agricultural Lands Using Bayesian-Based Artificial Neural Networks and High- Resolution Visual, NIR, and Thermal Imagery. **Irrigation and Drainage**, [s. l.], v. 66, n. 2, p. 273–288, 2017.

HASSAN, Muhammad et al. Development of sediment load estimation models by using artificial neural networking techniques. **Environmental Monitoring and Assessment**, [s. l.],

v. 187, n. 11, 2015.

HECHT-NIELSEN, Robert. Theory of the Backpropagation Neural Network. **Proceedings Of The International Joint Conference On Neural Networks**, [s. l.], v. 1, p. 593–605, 1989. Disponível em: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=118638>

HENG, Sokchhay; SUETSUGI, Tadashi. Using Artificial Neural Network to Estimate Sediment Load in Ungauged Catchments of the Tonle Sap River Basin, Cambodia. **Journal of Water Resource and Protection**, [s. l.], v. 05, n. 02, p. 111–123, 2013.

HENG, Sokchhay; SUETSUGI, Tadashi. Comparison of regionalization approaches in parameterizing sediment rating curve in ungauged catchments for subsequent instantaneous sediment yield prediction. **Journal of Hydrology**, [s. l.], v. 512, p. 240–253, 2014.

HENG, Sokchhay; SUETSUGI, Tadashi. Regionalization of sediment rating curve for sediment yield prediction in ungauged catchments. **Hydrology Research**, [s. l.], v. 46, n. 1, p. 26–38, 2015.

HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert. Multilayer feedforward networks are universal approximators. **Neural Networks**, [s. l.], v. 2, n. 5, p. 359–366, 1989.

JAIN, Sharad Kumar. Development of integrated sediment rating curves using ANNs. **Journal of hydraulic engineering**, [s. l.], v. 127, n. 1, p. 30–37, 2001.

JENSEN, John R. Sensoriamento remoto do ambiente: In: [s.l: s.n.]. p. 598.

KAKAEI LAFDANI, E.; MOGHADDAM NIA, A.; AHMADI, A. Daily suspended sediment load prediction using artificial neural networks and support vector machines. **Journal of Hydrology**, [s. l.], v. 478, p. 50–62, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.11.048>>

KASABOV, N. K. Foundations of neural networks, fuzzy systems, and knowledge engineering. In: **Massachusetts institute of technology**. Cambridge. p. 251–358.

KISI, Ozgur; OZKAN, Coskun; AKAY, Bahriye. Modeling discharge–sediment relationship using neural networks with artificial bee colony algorithm. **Journal of Hydrology**, [s. l.], v. 428–429, p. 94–103, 2012.

LIBOS, Marcio Inpes. **Modelagem Hidrológica quali-quantitativa: estudo de caso da bacia do rio Manso-MT**. 2008. Universidade Federal do Rio de Janeiro, [s. l.], 2008.

LIMA, Estevão Bernardes. **modelagem Integrada para Gestão da Qualidade da Água na Bacia do Rio Cuiabá**. 2001. Universidade Federal do Rio de Janeiro, [s. l.], 2001.

MINNS, A. W.; HALL, M. J. Artificial neural networks as rainfall-runoff models. **Hydrological Sciences Journal**, [s. l.], v. 41, n. 3, p. 399–417, 1996.

MOHAMOUD, Yusuf M. Time Series Separation and Reconstruction Technique to Estimate Daily Suspended Sediment Concentrations. **Journal of Hydrologic Engineering**, [s. l.], v. 19, n. 2, p. 328–338, 2014.

MOORE, R. J. **Real-time forecasting of flood events using transfer function noise models: report, Part 2.** Wallingford Institute of Hydrology., , 1980.

MUSIS, Carlos Rozante. **caracterização Climatológica da Bacia do Alto Paraguai.** 1997. Universidade Federal de Mato Grosso, [s. l.], 1997.

MUSTAFA, M. R. et al. River suspended sediment prediction using various multilayer perceptron neural network training algorithms-A case study in Malaysia. **Water Resources Management**, [s. l.], v. 26, n. 7, p. 1879–1897, 2012.

NOURANI, Vahid; KALANTARI, Omid. Integrated Artificial Neural Network for Spatiotemporal Modeling of Rainfall–Runoff–Sediment Processes. **Environmental Engineering Science**, [s. l.], v. 27, n. 5, p. 411–422, 2010.

NOURANI, Vahid; KALANTARI, Omid; BAGHANAM, Aida Hosseini. Two Semidistributed ANN-Based Models for Estimation of Suspended Sediment Load. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 12, p. 1368–1380, 2012.

NOURANI, Vahid; KOMASI, Mehdi; MANO, Akira. A Multivariate ANN-Wavelet Approach for Rainfall–Runoff Modeling. **Water Resources Management**, [s. l.], v. 23, n. 14, p. 2877–2894, 2009.

OLIVEIRA, Marquis Henrique Campos et al. Estimation of soil water content in watershed using artificial neural networks. **Hydrological Sciences Journal**, [s. l.], v. 62, n. 13, p. 2120–2138, 2017. Disponível em: <<https://doi.org/10.1080/02626667.2017.1364844>>

PAES, Rafael Pedrollo. **Análise da translação da onda de cheia efluente do reservatório da UHE Manso na bacia hidrográfica do rio Cuiabá, Mato Grosso.** 2011. Universidade de São Paulo, [s. l.], 2011.

RAJAEI, Taher. Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers. **Science of the Total Environment**, [s. l.], v. 409, n. 15, p. 2917–2928, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.scitotenv.2010.11.028>>

ROMAN, David C.; VOGEL, Richard M.; SCHWARZ, Gregory E. Regional regression models of watershed suspended-sediment discharge for the eastern United States. **Journal of Hydrology**, [s. l.], v. 472–473, p. 53–62, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.09.011>>

ROZANTE, José Roberto et al. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. **American Meteorological Society**, [s. l.], v. 25, n. 3, p. 885–894, 2010. Disponível em: <<http://journals.ametsoc.org/doi/abs/10.1175/2010WAF2222325.1>>

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, [s. l.], v. 323, n. 6088, p. 533–536, 1986.

SALIHA, A. H. et al. Estimation of flow in ungauged catchments by coupling a hydrological model and neural networks: case study. **Hydrology Research**, [s. l.], v. 42, n. 5, p. 386–400, 2011. Disponível em: <<http://hr.iwaponline.com/cgi/doi/10.2166/nh.2011.157>>

SANTOS, Humberto Gonçalves et al. **Brazilian soil classification system**. 2018. Disponível em: <<https://www.embrapa.br/solos/busca-de-publicacoes/-/publicacao/1094001/brazilian-soil-classification-system>>. Acesso em: 7 abr. 2018.

SARI, Vanessa. **Monitoramento e Modelagem da Produção de Sedimentos em uma Bacia hidrográfica no Noroeste do Rio Grande do Sul**. 2017. Universidade Federal do Rio Grande do Sul, [s. l.], 2017.

SARI, Vanessa; CASTRO, Nilza Maria dos Reis; PEDROLLO, Olavo Correa. Estimate of Suspended Sediment Concentration from Monitored Data of Turbidity and Water Level Using Artificial Neural Networks. **Water Resources Management**, [s. l.], v. 31, n. 15, p. 4909–4923, 2017.

SHELLENBARGER, Gregory G.; WRIGHT, Scott A.; SCHOELLHAMER, David H. A sediment budget for the southern reach in San Francisco Bay, CA: Implications for habitat restoration. **Marine Geology**, [s. l.], v. 345, p. 281–293, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.margeo.2013.05.007>>

SHOAIB, Muhammad et al. A Comparative Study of Various Hybrid Wavelet Feedforward Neural Network Models for Runoff Forecasting. **Water Resources Management**, [s. l.], v. 32, n. 1, p. 83–103, 2018.

SILVA, Alexandre Marco; SCHULZ, Harry Edmar; CAMARGO, Plínio Barbosa. Erosão e Hidrossedimentologia em Bacias Hidrográficas. In: 1. ed. [s.l.] : Rima, 2003. p. 140.

SINGH, A. et al. Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. **Agricultural Water Management**, [s. l.], v. 104, p. 113–120, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2011.12.005>>

SINGH, Ajai et al. Comparison of Artificial Neural Network Models for Sediment Yield Prediction at Single Gauging Station of Watershed in Eastern India. **Journal of Hydrologic Engineering**, [s. l.], v. 18, n. 1, p. 115–120, 2013.

SIVAPALAN, M. et al. IAHS Decade on Predictions in Ungauged Basins (PUB), 2003–2012: Shaping an exciting future for the hydrological sciences. **Hydrological Sciences Journal**, [s. l.], v. 48, n. 6, p. 857–880, 2003.

TALEBIZADEH, Mansour et al. Uncertainty analysis in sediment load modeling using ANN and SWAT model. **Water Resources Management**, [s. l.], v. 24, n. 9, p. 1747–1761, 2010.

TANANAIEV, N. I.; DEBOLSKIY, M. V. Turbidity observations in sediment flux studies: Examples from Russian rivers in cold environments. **Geomorphology**, [s. l.], v. 218, p. 63–71, 2014.

TAYFUR, G. Artificial neural networks for sheet sediment transport - ResearchGate. **Hydrological Sciences Journal**, [s. l.], v. 47, n. 6, p. 879–892, 2002.

TAYFUR, G.; GULDAL, V. Artificial neural networks for estimating daily total suspended sediment in natural streams. **Nordic Hydrology**, [s. l.], v. 37, n. Tayfur 2003, p. 69–79, 2006.

TOKAR, By Sezin; JOHNSON, Peggy. Rainfall-Runoff Modeling Using Artificial Neural Networks. **Journal of Hydrologic Engineering**, [s. l.], v. 4, n. 3, p. 232–239, 1999.

TRAMBLAY, Yves et al. Regional estimation of extreme suspended sediment concentrations using watershed characteristics. **Journal of Hydrology**, [s. l.], v. 380, n. 3–4, p. 305–317, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2009.11.006>>

TRENOUTH, William R.; GHARABAGHI, Bahram. Event-based soil loss models for construction sites. **Journal of Hydrology**, [s. l.], v. 524, p. 780–788, 2015.

VOGL, T. P. et al. Accelerating the convergence of the back-propagation method. **Biological Cybernetics**, [s. l.], v. 59, n. 4–5, p. 257–263, 1988.

WIDROW, B.; HOFF, Me. Adaptive switching circuits. **Ire Wescon Convention Record**, [s. l.], n. 4, p. 96–104, 1960.

WMO, The World Meteorological Organization. **Manual on Sediment Management and Measurement**. [s.l: s.n.].

ZEILHOFER, Peter; MOURA, Rubem Mauro. Hydrological changes in the northern Pantanal caused by the Manso dam: Impact analysis and suggestions for mitigation. **Ecological Engineering**, [s. l.], v. 35, n. 1, p. 105–117, 2009.

ZEROUAL, Ayoub; MEDDI, Mohamed; ASSANI, Ali A. Artificial Neural Network Rainfall-Discharge Model Assessment Under Rating Curve Uncertainty and Monthly Discharge Volume Predictions. **Water Resources Management**, [s. l.], v. 30, n. 9, p. 3191–3205, 2016. Disponível em: <<http://dx.doi.org/10.1007/s11269-016-1340-8>>

ZHANG, Wei et al. Estimating suspended sediment loads in the Pearl River Delta region using sediment rating curves. **Continental Shelf Research**, [s. l.], v. 38, p. 35–46, 2012.

ZHANG, Yongqiang; CHIEW, Francis H. S. Relative merits of different methods for runoff predictions in ungauged catchments. **Water Resources Research**, [s. l.], v. 45, n. 7, 2009.

4. ESTIMATIVA TEMPORAL DA CONCENTRAÇÃO DE SEDIMENTOS SUSPENSOS UTILIZANDO REDES NEURAIIS ARTIFICIAIS NA BACIA DO RIO CUIABÁ

Esta segunda etapa da pesquisa corresponde ao segundo artigo, em que foi explorada uma abordagem de estimativa da concentração de sedimentos em suspensão em escala temporal. O modelo desenvolvido nesta etapa estima a CSS na estação fluviométrica de Cuiabá (um único ponto) a partir de dados de nível, chuva pontual e o somatório da chuva total na bacia. Estas variáveis de entrada estudadas são, tipicamente, monitoradas diariamente nas estações brasileiras, e por este motivo, o modelo temporal é capaz de estimar concentração de sedimentos em suspensão em escala diária.

Este capítulo também é apresentado na forma de um artigo científico, que será, posteriormente, submetido em uma revista científica.

Resumo

A carga de sedimentos transportada pelos rios constitui-se em um dos fenômenos hidrológicos mais complexos devido a elevada não linearidade entre os fatores que determinam este processo. Nesta pesquisa, diversas redes neurais artificiais (RNA), que são ferramentas inspiradas nas redes neurais biológicas, capazes de modelar relações altamente não lineares, foram desenvolvidas para estimar a concentração de sedimentos em suspensão (CSS) no trecho do rio Cuiabá, que passa pela zona urbana da cidade de mesmo nome. Utilizou-se como entrada dos modelos os dados de níveis da própria estação fluviométrica de Cuiabá, dados de chuvas pontuais oriundos da estação pluviométrica de Cuiabá, e dados de chuvas totais na bacia obtidos do produto de precipitações MERGE, que agrega informações de diversos postos pluviométricos, acrescido de informações obtidas por satélites. Todas as variáveis de entrada são diárias, assim, as estimativas da CSS feitas pelos modelos desenvolvidos também são diárias, possibilitando a obtenção de séries mais longas da CSS na estação fluviométrica de Cuiabá, que atualmente, dispõe de 80 registros desta variável. A baixa disponibilidade de dados de CSS na estação fluviométrica de Cuiabá inviabiliza o uso da validação cruzada, e, por isso, os modelos de RNA foram treinados com uma técnica de validação por reamostragem, na qual menos registros são necessários para evitar o superajustamento da rede. Os resultados dos modelos foram satisfatórios, sendo que o modelo M08, cujas entradas foram escolhidas com base num critério de seleção de entradas a partir de análises de correlações e exclusão de variáveis de entrada com elevada correlação entre si, obteve o melhor desempenho, com coeficiente de Nash-Sutcliffe de $NS = 0,777$ no treinamento e $NS = 0,776$ na verificação. Os modelos desenvolvidos foram capazes de predizer a CSS a partir de variáveis de entrada de fácil aquisição, e que são monitoradas diariamente nas bacias hidrográficas.

Palavras-chave redes neurais artificiais, produção de sedimentos, validação por reamostragem, modelagem hidrossedimentológica.

4.1. Introdução

A modelagem hidrológica em bacias com baixa ou nenhuma disponibilidade de dados tem sido considerada um dos principais desafios das ciências hidrológicas (SALIHA et al., 2011; SIVAPALAN et al., 2003). No Brasil, assim como em diversos países do mundo, a dificuldade de acesso em algumas regiões, bem como os altos custos para o monitoramento, favorece a escassez de dados nas bacias hidrográficas.

Considerando dados de sedimentos, a situação é ainda mais crítica. O conhecimento desta variável geralmente é realizado a partir da coleta de amostras de água no campo, tratando-se de um procedimento caro, que exige elevados recursos financeiros e humanos, tornando difícil a obtenção de informações para todos os pontos de interesse em uma bacia hidrográfica (HENG; SUETSUGI, 2014; SARI; CASTRO; PEDROLLO, 2017).

Embora a carga de sedimentos seja mensurada em algumas áreas, a frequência de amostragem é baixa (escala de tempo mensal ou maior) e, comumente, somente a carga suspensa é mensurada, negligenciando as frações do fundo do leito. Há de se considerar, entretanto, que a parte suspensa é, em geral, a carga predominante, representando, na maioria dos casos, cerca de 90% da carga total transportada (CARVALHO, 2008; SINGH et al., 2012).

Conseqüentemente, diversas pesquisas vêm sendo desenvolvidas para melhorar as informações de sedimentos nas bacias hidrográficas com monitoramento insuficiente (ATIEH et al., 2015; HENG; SUETSUGI, 2013, 2015; SIVAPALAN et al., 2003). Técnicas de determinação indireta da concentração de sedimentos em suspensão (CSS) são amplamente utilizadas, tais como as curvas-chave de sedimentos, à partir da relação entre descarga líquida e descarga sólida (HENG; SUETSUGI, 2014; ZHANG et al., 2012), a relação entre turbidez e CSS (SARI; CASTRO; PEDROLLO, 2017; TANANAIEV; DEBOLSKIY, 2014), bem como a partir de abordagens de regionalização, que consiste na transferência de informações de locais monitorados para outros locais de interesse (HENG; SUETSUGI, 2015; MOHAMOUD, 2014; SIVAPALAN et al., 2003; TRENOUTH; GHARABAGHI, 2015; ZHANG; CHIEW, 2009).

A rede neural artificial (RNA) é uma poderosa ferramenta de modelagem baseada em dados, que provou ser útil na modelagem de processos hidrológicos complexos ou ainda, em sistemas não-lineares como o transporte de sedimentos (AFAN et al., 2014; BUYUKYILDIZ; KUMCU, 2017; CIGIZOGLU; KISI, 2006; HASSAN et al., 2015; KISI; OZKAN; AKAY, 2012; NOURANI; KALANTARI, 2010; SINGH et al., 2013). No entanto, devido à grande escassez de dados de sedimentos, poucos estudos tem sido desenvolvidos em locais com deficiência de monitoramento, e, geralmente, são realizados em escala de tempo mensal ou anual (ATIEH et al., 2015; BAO et al., 2012; HENG; SUETSUGI, 2013, 2015; ROMAN; VOGEL; SCHWARZ, 2012).

Os modelos de RNAs possuem uma limitação quanto à extrapolação dos dados do seu domínio, que é contornada selecionando-se uma amostra de treinamento que cubra toda a amplitude desejada. Parte das amostras, que não participaram do treinamento, são reservadas para a verificação da capacidade de generalização. Esta última característica frequentemente limita a aplicação das RNAs, uma vez que requer uma grande quantidade de registros de dados, uma condição impraticável para os locais onde o monitoramento não resulta em grande quantidade de amostras.

A escassez de dados hidrossedimentológicos é muito comum em várias regiões brasileiras, e por este motivo, esta pesquisa explora uma metodologia de treinamento de RNAs que necessita de menor número de dados para o seu treinamento, contemplando estudos em locais com poucos dados. Esta técnica, denominada de validação por reamostragem, foi apresentada anteriormente em Sari et al., (2017), em que os autores treinaram modelos de RNAs para estimar a CSS a partir de dados de nível de água e turbidez, dispondo de 59 registros de CSS. Mesmo com poucos dados, os modelos apresentaram bons desempenhos (coeficiente de eficiencia de Nash-Sutcliffe igual a 0.995 no treinamento e 0.953 na verificação).

O objetivo desta pesquisa é estimar a concentração de sedimentos em suspensão em uma estação fluviométrica com baixa disponibilidade de dados, em escala de tempo diária, utilizando modelos de redes neurais artificiais. Utilizou-se dados hidrológicos diários (fluviométricos, representados pelos níveis de água, e pluviométricos), sem uso de outras variáveis medidas na estação fluviométrica, sabidamente correlacionadas com a CSS, como, por exemplo, a turbidez, pois a mesma não é mensurada diariamente. Uma vez que a CSS, para determinada seção, resulta da erosão e do transporte das partículas erodidas, principalmente oriundas de origem

hidrológica, espera-se que as informações que representem esta dinâmica (níveis de água e precipitações) sejam boas variáveis de entrada em modelos de simulação de sua ocorrência.


4.2. Modelos de Redes Neurais Artificiais

As RNAs são modelos inspirados no funcionamento das redes neurais biológicas (cérebro humano), e apresentam elevada capacidade de ajuste de funções não-lineares, possuindo rapidez, tolerância a falhas, paralelismo intenso e grande capacidade de aprendizado. São constituídas por unidades de processamento chamadas de neurônios, que recebem e modificam os sinais recebidos entre as entradas e as saídas, e os transmitem, sucessivamente, por meio de conexões que possuem pesos associados a elas, representando a força da conexão (ASCE, 2000).

A rede aprende a relação entre uma amostra de observações de entrada e suas respectivas saídas, e generaliza o aprendizado (treinamento), apresentando capacidade de resposta a situações ainda não encontradas durante o processo de aprendizagem (verificação da rede). A capacidade de generalização da RNA é influenciada pelo tamanho da amostra de treinamento, pela representatividade dos registros, pela arquitetura da rede, e pela complexidade física do problema a ser determinado (ASCE, 2000).

Em aplicações hidroambientais, as RNAs do tipo *feedforward* (progressiva) (RUMELHART, HINTON e WILLIAMS, 1986), as quais possuem uma estrutura com os neurônios agrupados em camadas, são comumente utilizadas, em geral com uma estrutura de três camadas. A Figura 1 ilustra uma rede neural artificial *feedforward* com três camadas.

Figura 1 - Representação de uma RNA feedforward com três camadas.



Fonte: Matos et al., (2014).

Na primeira camada são inseridos os dados de entrada (variáveis explicativas). Nas camadas sucessivas, cada neurônio recebe a soma, ponderada por coeficientes chamados de pesos sinápticos das entradas, enviadas pelos neurônios da camada anterior, adicionadas a um termo de tendência (*bias*). Esse valor passa por uma transformação linear ou não linear (função de ativação do neurônio), que transforma esta soma em um valor de saída desta camada, para constituir a saída da rede (variáveis explicadas). A Equação 1 define o funcionamento de um neurônio:

$$O = f(\sum_{i=1}^n w_i I_i + b) \quad (1)$$

em que: O é o valor da resposta do neurônio; f é a função de ativação; w_i são os pesos sinápticos; I_i são os valores das n entradas que serão processadas no neurônio e b é a tendência ou *bias*.

A função sigmoide unipolar é a mais utilizada para ativação dos neurônios da camada intermediária, em função da simplicidade de sua derivada. Também pode ser utilizada a função sigmoide bipolar. Pode-se ainda utilizar para os neurônios da camada de saída, uma função de ativação do tipo linear. No entanto, o uso de funções não lineares (sigmóides) para a saída, com escalonamento posterior (FANTIN-CRUZ et al., 2011; OLIVEIRA et al., 2017; SARI; CASTRO; PEDROLLO, 2017), aumenta a capacidade do modelo para aproximar comportamentos não-lineares. A Equação 2 apresenta o formato da função sigmoide unipolar e a Equação 3 representa a derivada desta função:

$$f(\eta) = \frac{1}{1+e^{-\eta}} \quad (2)$$

$$f'(\eta) = f(\eta) * (1 - f(\eta)) \quad (3)$$

em que: η é a entrada líquida do neurônio, definida como o resultado de $w_i I_i + b$.

Na etapa de treinamento da rede, os pesos sinápticos das conexões e o *bias* são ajustados a partir de uma regra de aprendizado, cujo o objetivo final é, normalmente, minimizar alguma medida de desempenho baseada nos erros entre as saídas calculadas e observadas (ASCE, 2000). Os valores iniciais são escolhidos aleatoriamente (FREEMAN; SKAPURA, 1991; KASABOV, 1998). Também devem ser feitas diversas iterações do treinamento, a partir de pesos aleatórios diferentes (escolhendo a configuração de pesos que apresentou o melhor desempenho) pois, devido a essa aleatoriedade, cada treinamento resulta em uma rede diferente.

Para a aplicação da regra delta (algoritmo retropropagativo) executa-se a rede, com os pesos atuais, calculando os erros, pela comparação com os resultados esperados e das derivadas da função de ativação, e a atualização dos pesos segundo a Equação 4, em ciclos sucessivos de aplicação da regra com o conjunto de amostras disponibilizadas para o treinamento.

$$w_{k+1} = w_k - \tau e_k \delta_k I_k \quad (4)$$

em que: w_k são os pesos sinápticos dos neurônios; τe_k é a taxa de aprendizagem; δ_k é a derivada das funções ativação; e I_k são as entradas na própria camada, no ciclo k .

É necessário, também, o conhecimento dos erros (e_h) nas camadas internas, calculados pela Equação 5.

$$e_h = \sum (W_{h+1} e_{h+1} \delta_{h+1}) \quad (5)$$

em que: e_h é o erro na camada interna considerada; W_{h+1} , e_{h+1} e δ_{h+1} são, respectivamente, os pesos sinápticos, os erros e as derivadas na camada posterior

O superajustamento da RNA pode acontecer quando o número de neurônios na camada intermediária for excessivo, ou ainda, quando o número de ciclos executados é muito grande, ocorrendo assim o treinamento excessivo da rede, caracterizado pelo ajuste também das aleatoriedades presentes na amostra de treinamento (HECHT-NIELSEN, 1989). Para evitar que isso aconteça, realiza-se uma limitação da complexidade do modelo (número de neurônios nas camadas internas), ou também a interrupção oportuna do treinamento no momento em que condições suficientes de finalização são alcançadas.

A validação cruzada é, atualmente, o recurso mais utilizado para se evitar o superajustamento da RNA do tipo *feedforward* (HECHT-NIELSEN, 1989). Esta técnica utiliza uma amostra não usada no treinamento, para executar uma avaliação do erro, ao longo do treinamento. O início do superajustamento ocorre no ciclo no qual o erro da série de validação começa a aumentar, enquanto o erro da série de treinamento continua a diminuir. Assim, a validação cruzada funciona como um determinante do momento ideal de parada do treinamento, já que a estatística de erros do treinamento vai sempre diminuindo (indicando desempenho melhor), enquanto que a estatística de erros da série de validação, a partir de determinado ciclo, volta a elevar-se, indicando que um limiar foi atingido. Esse limiar determina o momento a partir do qual a capacidade de generalização fica comprometida, devendo-se, nesse ponto, interromper o treinamento (HECHT-NIELSEN, 1989).

Em diversas aplicações, o pequeno número de dados disponíveis inviabiliza o uso da validação cruzada. Assim, um método alternativo foi apresentado em Sari, Pedrollo e Castro (2017), em que o número de registros necessários é inferior ao que é requerido pela validação cruzada. A amostra total disponível é subdividida em apenas dois conjuntos, ou seja, a amostra de treinamento e a amostra de verificação. A validação é realizada por meio da técnica de reamostragem, que consiste no uso de partições do número total de N registros de treinamento, de forma que cada um dos n treinamentos seja realizado alternadamente com partições $n-1$, e o restante é usado como amostra de validação.

Para a aplicação das RNAs, é necessário escalonar as variáveis de entrada e saída, possibilitando a igualdade de importância das diferentes entradas, durante o processo de treinamento da RNA, evitando a convergência mais rápida junto aos nós com dados de maior magnitude (KASABOV, 1998). Essas transformações comumente constituem simples transferências lineares de escala, já que a complexidade das relações não lineares é aproximada pela própria RNA.

Após determinadas as características da rede e executado o treinamento com validação cruzada ou validação por reamostragem, a RNA deverá passar por um processo de teste (verificação), com utilização de uma série ainda não usada no treinamento (conforme já mencionado anteriormente), para identificação de sua capacidade de generalização.

4.3. Materiais e Métodos

4.3.1. Área de Estudo

A bacia hidrográfica do rio Cuiabá está situada no centro sul do Estado de Mato Grosso, entre os paralelos $14^{\circ}12'$ e $16^{\circ}10'$ e meridianos $54^{\circ}40'$ e $56^{\circ}56'$, e possui área total de aproximadamente 29.000 km^2 , considerando até o seu encontro com a Baía de Chacororé, em Barão de Melgaço-MT. Essa bacia faz parte da região hidrográfica do Alto Paraguai, sendo a região mais urbanizada, e, conseqüentemente, mais monitorada da mesma (Figura 2).

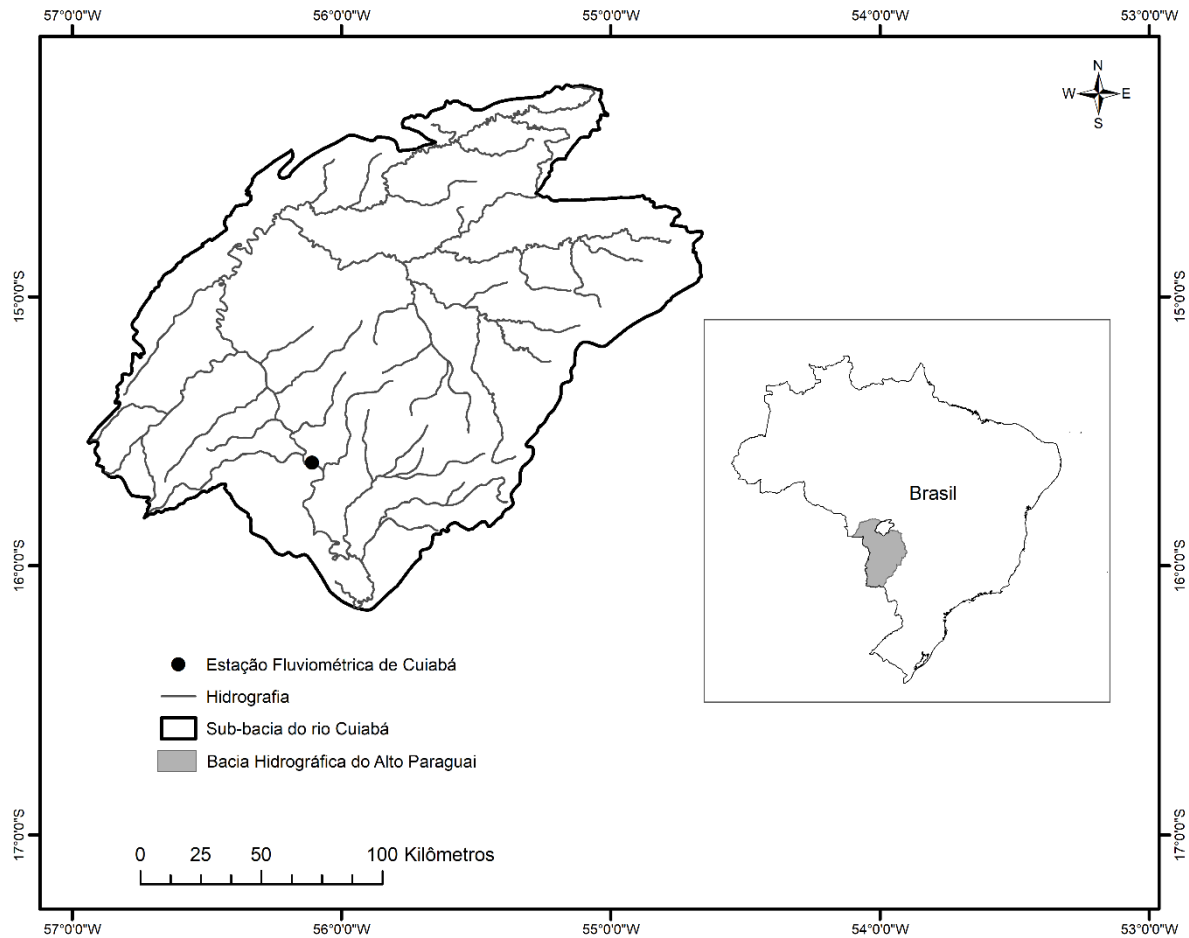
A BHC é constituída por duas grandes formações naturais, com características bióticas e abióticas definidas e próprias: a planície do Pantanal e as áreas de planalto e serras circunvizinhas. Dessa forma, a bacia do rio Cuiabá apresenta três regiões, conforme segue (PAES, 2011):

- Alto Cuiabá – que compreende as nascentes dos formadores do rio Cuiabá; caracteriza-se pela presença de vegetação típica de cerrado; pouca presença de urbanização; agricultura baseada na monocultura, principalmente soja, milho e arroz; ocorre ainda, exploração mineral de diamante e calcário;
- Médio Cuiabá – região que atravessa a baixada Cuiabana, compreendendo a transição entre as partes mais altas do planalto e o início da planície de inundação; nesta região ocorre uma intensificação dos impactos ambientais sobre o rio Cuiabá, oriundos da concentração de atividades industriais e dos lançamentos de esgoto doméstico; no médio-norte da bacia, a ocupação apresenta-se também na forma de pastagens em áreas de solos pobres;
- Baixo Cuiabá - esse trecho é constituído de planícies de inundação (área pantaneira), em que a integridade ecológica depende principalmente da dinâmica das terras altas;

Ao total, treze municípios fazem parte total ou parcialmente da BHC, e integram a região metropolitana do Vale do Rio Cuiabá, segundo a Lei Complementar nº 359 de 2009 (MATO GROSSO, 2009). Entre os que estão sob maior influência do rio Cuiabá e seus afluentes, destacam-se Rosário Oeste, Nobres, Chapada dos Guimarães, Acorizal, Santo Antônio do Leverger, Barão de Melgaço, Cuiabá e Várzea Grande, sendo os dois últimos os principais núcleos urbanos mato-grossenses. O Censo do IBGE, divulgado em 2010, indica que as duas maiores cidades de Mato Grosso somam pouco mais de 800 mil habitantes, com crescimento populacional de 1,3%.

O clima incidente na BHC, é o clima tropical de savana, também conhecido por clima savânico, clima tropical com estação seca, clima tropical de estações úmida e seca ou ainda clima tropical semi-úmido. É um tipo de clima que corresponde às categorias "Aw" e "As" de classificação climática de Köppen-Geiger. A principal característica desse regime térmico é a presença constante de temperaturas elevadas, registrando média anual em torno de 22 a 25°C, enquanto a mínima anual oscila entre 17 e 20°C, e a máxima média anual assume valores entre 29 e 32°C (MUSIS, 1997).

Figura 2 – Localização da Área de Estudo.



Fonte: O Autor.

De acordo com Lima (2001), a precipitação média anual varia em torno de 800 mm a 1500 mm, com regime sazonal tipicamente tropical. O período chuvoso vai de outubro a abril, e o período seco vai de maio a setembro. O trimestre mais chuvoso corresponde aos meses de dezembro, janeiro e fevereiro, concentrando 60% da precipitação anual, com o mês de janeiro apresentando o maior índice pluviométrico, com valores superiores a 200 mm. O trimestre mais seco corresponde aos meses de junho, julho e agosto, quando se verifica precipitação média de 26 mm, com o mês de agosto apresentando o menor índice pluviométrico, com valores inferiores a 10 mm. Lima (2001) comenta que as chuvas prevalentes nessa região são convectivas de mesoescala, bastante localizadas, com abrangência espacial de 2 a 50 km.

A sazonalidade entre os períodos seco e chuvoso é bem definida, interferindo na vazão do rio Cuiabá e de todos os seus tributários. Conforme Lima (2001), nos meses de maior volume

de chuva (janeiro, fevereiro e março), um registro de vazões de 480 m³/s a 1000 m³/s na estação fluviométrica localizada no perímetro urbano da cidade de Cuiabá. A partir dos meses de abril e maio, quando as chuvas se tornam mais esparsas, começa a ocorrer um decréscimo das vazões, que chegam a atingir níveis críticos, abaixo de 100 m³/s, nos meses de maior seca (agosto e setembro).

A rede de drenagem é constituída pelo rio Cuiabá e seus formadores, o rio Cuiabá da Larga e o Cuiabá do Bonito, todos de águas perenes, assim como os seus principais tributários, que são, pela margem esquerda, os rios: Marzagão, Manso, Acorizal e Coxipó-Açu; e pela margem direita Chiqueirão, Jangada, Espinheiro e Pari.

Os terrenos da bacia hidrográfica situam-se entre as cotas altimétricas de 100 e 900 m, sendo predominantes entre 200 m e 300 m na Depressão Cuiabana e no Planalto do Casca, e acima de 600 m na Chapada dos Guimarães.

De acordo com a classificação apresentada por Libos (2008), o uso e a ocupação do solo na BHC são compostos por: savana – 57,4%; pasto – 20,3%; solo exposto – 8,4%; mata ciliar – 8,1%; agricultura – 2,8%; água – 0,9% e urbanização – 0,6%. A classificação foi baseada nas imagens digitais do satélite Landsat 7.

A vegetação predominante na bacia hidrográfica do rio Cuiabá é a savana, ou cerrado, que pode ser subdividido em diversas tipologias, de acordo com a constituição local. As características principais do cerrado são a formação de gramíneas espalhadas e de árvores relativamente baixas, espaçadas entre si, de corpo lenhoso e retorcido, variando a estrutura da savana, conforme o tipo de solo, profundidade do nível d'água subterrâneo e da rocha matriz.

Em relação à pedologia, de acordo com o mapa de tipos de solo do Brasil, que foi classificado com base no sistema brasileiro de classificação dos solos – SiBCS (SANTOS et al., 2018), nas partes altas e planas da bacia do rio Cuiabá há o predomínio dos Neossolos Quartzarênicos, Neossolos Litóticos, Latossolos Vermelhos, Latossolos Vermelho-Amarelos e os Cambissolos. Já ao sul da bacia predominam os Plintossolos Pétricos, Argissolos Vermelho-Amarelos, e Planossolos na região de entrada para o Pantanal. Os Latossolos e os Neossolos Quartzarênicos podem ser classificados como solos profundos, de baixo potencial de escoamento superficial, enquanto que os Cambissolos, Neossolos Litóticos, Argissolos e os Planossolos possuem alto potencial de escoamento superficial.

4.3.2. Dados

Para o desenvolvimento do modelo, foram utilizados dados de concentração de sedimentos em suspensão e níveis oriundos da estação fluviométrica de Cuiabá (código ANA 66260001), que se localiza na zona urbana deste município, e cobre uma área de drenagem de 23.500 km² da bacia.

Os dados de chuva foram obtidos de duas fontes: A estação pluviométrica de Cuiabá (código ANA 1556001) e o produto de precipitações denominado MERGE, que é uma combinação de dados observados de chuva e informações de satélites, disponibilizados pelo Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE), para toda a América do Sul.

Os dados de chuva foram utilizados seguindo duas abordagens distintas: chuva pontual e chuva total na bacia. Chuva pontual refere-se à série histórica de precipitações obtidas junto à estação pluviométrica de Cuiabá, enquanto que a chuva total na bacia refere-se aos dados obtidos do produto MERGE, para diversos pontos dentro de toda a área de drenagem da BHC.

Devido ao caráter isolado e concentrado das chuvas típicas desta região, a chuva pontual foi considerada visando representar um possível efeito local da intensidade das precipitações na concentração de sedimentos do ponto estudado, devido a uma maior desagregação das partículas do solo, em escala local. E os dados de chuva total na bacia foram levantados com o objetivo de considerar o efeito, em maior escala, das precipitações na dinâmica hidrossedimentológica da bacia como um todo.

No produto MERGE, os dados de precipitação estimada por sensoriamento remoto são usados para preencher informações de chuva em locais com monitoramento *in situ* insuficiente. É atribuído um raio de influência para os dados observados, e a partir deste, os dados de precipitação estimada por satélite passam a compor a informação faltante. A parcela de precipitação estimada por satélites é realizada a partir dos dados do TRMM-TMPA (Tropical Rainfall Measuring Mission - Multisatellite Precipitation Analysis), para o período de 1998 a 2014, e pelo GPM-IMERG (Global Precipitation Measurement - Integrated Multisatellite Retrievals for GPM), de 2015 até o tempo atual (com atraso de um dia). Os dados do TRMM-TMPA são produzidos em modo de operação, com resolução temporal e horizontal de 3 horas e 0.25°. Na versão do MERGE gerado a partir dos dados do TRMM-TMPA, os dados são disponibilizados em formato binário, com resolução de 20 km. As saídas são diárias (acumulado

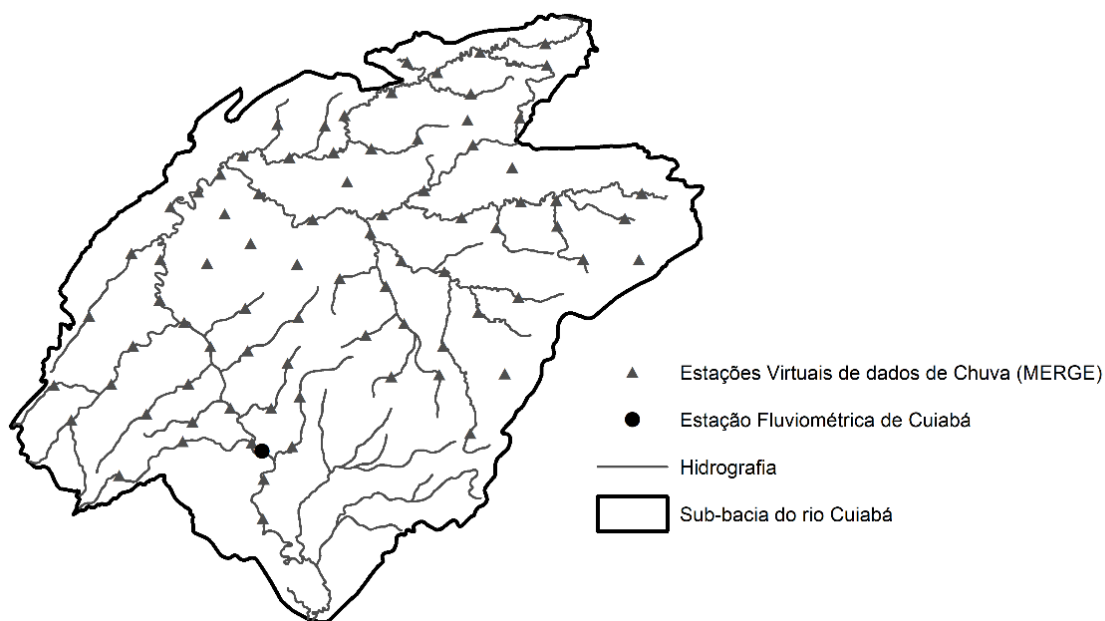
em 24 horas) cobrindo toda a América do Sul. Os dados do GPM-IMERG são disponibilizados com resolução temporal de 30 minutos e resolução horizontal de 0.1° graus. Na versão do MERGE gerado com o GPM-IMERG, são disponibilizados dados tanto diários quanto horários, em formato binário, com resolução horizontal de 5 km (ROZANTE et al., 2010).

Os dados do produto MERGE podem ser encontrados em: <ftp://ftp.cptec.inpe.br/modelos/io/produtos/MERGE/YYYY>, onde YYYY refere-se ao ano (dados a partir de 1998).

Para a determinação da chuva total na bacia, cada pixel da grade do produto MERGE, que cobre a área de estudo, foi considerado como uma estação virtual, e em cada estação virtual, foram extraídas as séries de chuva, que por fim, foram somadas, dando origem ao dado de chuva total na bacia. Na Figura 3 são ilustradas as estações virtuais criadas para a extração dos dados do MERGE.

Ao total, foram utilizados 80 registros de CSS, que correspondem ao período de 13/09/1999 até 21/10/2016. Os dados de níveis, chuva pontual e chuva total da bacia são diários e foram adquiridos para o período de 01/01/1998 até 31/12/2016, abrangendo todo o período dos dados de CSS.

Figura 3 – Estações virtuais criadas para extração dos dados do MERGE



Fonte: O Autor.

4.3.3. Variáveis de Entrada e de Saída dos modelos

Foram realizadas as extrações dos registros de níveis, chuvas pontuais e chuvas totais na bacia, correspondentes às mesmas datas dos 80 registros de CSS. Em seguida, aplicou-se filtros de defasagens e médias móveis exponencialmente ponderadas (EWMA) nos dados de entrada.

A defasagem corresponde a um deslocamento dos dados diários, no tempo atual (definido como tempo t) em direção ao passado, permitindo a inserção de informações do passado recente dentro dos modelos. O uso de defasagens é bastante comum em modelos hidrológicos de previsão baseados em dados. Foram selecionadas defasagens de até 5 dias, tanto para níveis, quanto para as chuvas pontuais e totais na bacia.

As EWMA foram propostas inicialmente por Moore (1980) para promover uma síntese de informações recentes, na forma de um valor representativo, gerando bons resultados e modelos mais parcimoniosos, com menos variáveis de entrada. Este recurso foi utilizado por Moore (1980) para melhor representar as condições de umidade do solo em função das precipitações recentes, mas ainda não se verificou nenhum estudo que utilize este recurso na modelagem de sedimentos. A transformação é aplicada em séries temporais de precipitação com intervalos constantes, de acordo com a Equação 6.

$$EWMA_t = \sum_{i=0}^{\infty} w_i P_{t-i} \quad (6)$$

onde: $w_i = \alpha (1 - \alpha)^i$; P_{t-i} é a precipitação que ocorreu no tempo $t-i$; e α é uma constante temporal, em unidade de tempo.

A Constante α está relacionada a um parâmetro chamado de meia-vida (h):

$$\alpha = 1 - 0,5^{(1/h)} \quad (7)$$

O decaimento exponencial das EWMA é, portanto, ponderado em função do parâmetro da meia-vida (h). Quanto maior a meia vida, maior é a importância que se dá às chuvas que ocorreram no passado.

Uma vez que o comprimento da série de pesos é indefinido, devendo ser truncado a partir de um valor mínimo em direção ao passado, é mais prático o uso de uma equação recursiva (Equação 8):

$$EWMA_t = (1 - \alpha) EWMA_{t-1} + \alpha P_t \quad (8)$$

Foram analisados valores inteiros do parâmetro de meia-vida (h), variando de 1 a 30 dias, para todos os dados (chuvas e também níveis na estação fluviométrica), e selecionou-se valores cujas correlações foram mais elevadas.

No total, considerando defasagens e médias móveis ponderadas exponencialmente, foram selecionadas inicialmente 37 variáveis de entrada, sendo elas: nível no tempo t até t-5, chuva pontual no tempo t até t-5, chuva total na bacia no tempo t até t-5, EWMA's dos níveis com h variando de 1 até 5, EWMA's das chuvas pontuais com h = 1, 2, 5, 9, 10, 12 e 17, e EWMA's das chuvas totais na bacia com h = 1, 2, 3, 4, 5, 9 e 10.

A pesquisa exaustiva de todas as combinações possíveis das 37 variáveis de entrada, para treinar os modelos de RNAs, é impraticável, e por isso, grupos de variáveis de entrada foram selecionados com base em um critério de exclusão de variáveis de entrada com elevada correlação entre si, para evitar o excesso de redundância. Foram utilizadas as correlações de Pearson, bem como a de Spearman, com limiares de exclusão (representados pelas intercorrelações calculadas) iguais a 0,8; 0,9; 0,95; e 0,99. O critério utilizado considera a combinação de correlações importantes com a CSS, e excluindo-se variáveis com elevada correlação entre si. No caso, são excluídas, entre as que se correlacionam entre si, as menos correlacionadas com a CSS. Conforme Oliveira et al. (2017), variáveis de entrada muito correlacionadas e, portanto, com informações redundantes, resultam em menor desempenho nos modelos de RNA.

A correlação de Pearson é calculada pela Equação 9:

$$r = \frac{\sum(x_i - x_{méd})(y_i - y_{méd})}{\sqrt{(\sum(x_i - x_{méd})^2)(\sum(y_i - y_{méd})^2)}} \quad (9)$$

onde: r é o coeficiente de correlação de Pearson; x_i é a variável observada; $x_{méd}$ é a média da variável observada; y_i é a variável calculada; e $y_{méd}$ é a média da variável calculada. O coeficiente de Pearson (r) varia entre -1 e 1, em que os valores próximos de 1 indicam correlação linear positiva, valores próximos de zero indicam ausência de relação e valores próximos de -1 indicam correlação linear negativa.

A correlação de Spearman (ρ) também pode ser calculada pela Equação 9. Neste caso, a correlação entre uma variável e outra é calculada pela mesma fórmula que o coeficiente de Pearson, porém, usando seus postos (número de ordem dos dados). Quando não existem registros repetidos, a correlação de Spearman pode ser calculada conforme a Equação 10:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2-1)} \quad (10)$$

onde: ρ é o coeficiente de correlação de Spearman; $d_i =$ (postos de x_i dentre os valores de x) - (postos de y_i dentre os valores de y); n é o número de pares (x_i, y_i) . O coeficiente ρ de Spearman também varia entre -1 e 1, no entanto, nos casos em que os dados não formam uma nuvem “bem comportada”, com alguns pontos muito afastados dos demais, ou em que parece existir uma relação crescente ou decrescente em formato de curva (relações monotônicas), o coeficiente ρ de Spearman é mais apropriado.

Além deste critério, alguns grupos de variáveis de entrada foram selecionados de forma a possibilitar a análise da contribuição do uso das EWMA e das defasagens nos modelos de estimativa da concentração de sedimentos suspensos.

4.3.4. Construção do modelo temporal de estimativa da CSS

Diversos modelos de Redes Neurais Artificiais para estimar a concentração de sedimentos em suspensão no posto fluviométrico de Cuiabá foram desenvolvidos. Os recursos foram programados em Matlab® R2012b, lançando mão das RNAs do tipo *feedforward*, de três camadas, sendo uma camada de entrada, uma camada intermediária e uma camada de saída. Utilizou-se o algoritmo retropropagativo (RUMELHART; HINTON; WILLIAMS, 1986), juntamente com técnicas de aceleração de treinamento (VOGL et al., 1988), e a função sigmoide unipolar em todos os neurônios.

Devido ao pequeno número de registro de CSS disponíveis na estação de Cuiabá (80 registros), não é possível utilizar a tradicional técnica de validação cruzada para evitar o superajustamento da rede, uma vez que não se pode dividir uma amostra tão pequena em três partes (treinamento, validação e verificação), sem provocar redução no desempenho em função da insuficiência de dados. Sendo assim, outra técnica alternativa, apresentada anteriormente em Sari, Castro e Pedrollo (2017), foi utilizada.

Esta técnica, denominada de validação por reamostragem (*resampling validation*), requer a divisão dos dados em apenas duas partes, uma para o treinamento e outra para verificação, tornando factível o treinamento de modelos de RNAs com relativamente poucos dados.

Neste método, diversos treinamentos são realizados, sendo que um grupo diferente de registros é deixado de fora, a cada vez, e para o qual são calculados os resultados da rede neural treinada com os demais registros. O número de registros de cada grupo que é deixado fora do treinamento depende do critério adotado de que o número de registros efetivamente utilizado no procedimento de treinamento seja pelo menos 30. Assim, se a amostragem total (L) disponibilizada for menor que 32, o número de partições é o número de amostras, resultando L grupos, de um registro cada, significando que apenas um registro ficará de fora de cada procedimento de treinamento. Da mesma forma, se o número total de registros de treinamento e validação, L , for maior que 90, o número de partições será 3, resultando grupos de 30 registros.

Uma vez que o critério de finalização do treinamento das redes neurais, para que não haja superajustamento, utilizado na validação cruzada (o ponto de inflexão, a partir do qual é verificada a ocorrência do superajustamento, na amostra de validação), não é possível, pois somente saber-se-á o desempenho na validação após os treinamentos com a exclusão de cada um dos grupos de registros, foi preciso formular uma alternativa, que dependesse, unicamente, da amostra de treinamento.

O critério de finalização formulado foi a adoção de um limite de proximidade, correspondente ao erro médio admitido na amostra de treinamento. Se o treinamento avança obtendo aproximação além deste limite, ocorrerá o superajustamento. Porém, não se sabe, a priori, qual é este limite. A solução encontrada foi a pesquisa, realizando-se o procedimento de reamostragem para cada um de diversos limites de proximidade a serem experimentados, e verificando-se as estatísticas dos erros na validação (ou seja, com os grupos sucessivos que foram excluídos de cada treinamento, e que, em seu conjunto, a cada limite de proximidade experimentado, constituem a totalidade dos registros disponibilizados para treinamento e validação). O limite de proximidade que resulta menos erros na validação é a proximidade máxima admitida sem que ocorra superajustamento.

Devido à variabilidade esperada dos resultados do treinamento, como consequência da aleatoriedade das condições iniciais deste, o método também utiliza repetições, para cada proximidade experimentada, adotando, para a decisão do limite de proximidade, o menor erro médio de validação, entre as repetições realizadas, considerando que os demais resultados correspondem, simplesmente, a repetições que não foram tão bem sucedidas. Alternativamente, pode ser adotada a mediana dos erros médios de cada repetição, por constituir também um

resultado representativo. Finalmente, toda a amostra de treinamento e validação é utilizada para o treinamento final da rede neural, com uso do limite de proximidade resultante da pesquisa.

Na Figura 4 é apresentada a descrição do procedimento, em linguagem estruturada:

Figura 4 – Procedimento, em linguagem estruturada, da Validação por Reamostragem

```
Definição do número de partições.
Para cada limite de proximidade a ser testado, faz:
    Para cada repetição, faz:
        Para cada grupo de registros a ser excluído, faz:
            Treina a rede neural com os registros não excluídos.
            Calcula os erros da validação, com os registros excluídos.
        Fim cada grupo.
        Calcula o erro médio de validação (grupos excluídos) da repetição.
    Fim cada repetição.
    Calcula o erro mínimo dos erros médios de cada repetição, para a proximidade pesquisada.
Fim das proximidades pesquisadas.
Decisão pelo limite de proximidade a ser adotado, pela comparação do mínimo dos erros médios
obtido em cada uma das proximidades pesquisadas.
Treinamento final do modelo, utilizando como critério o limite de proximidade resultante.
```

Fonte: O Autor.

A pesquisa da complexidade mínima, que consiste em definir qual o menor número de neurônios na camada intermediária, sem que haja perda da capacidade de generalização do modelo em função da ausência de graus de liberdade, foi realizada, nesta pesquisa, com a execução de diversos treinamentos, com redução progressiva do número de neurônios da camada interna, utilizando a técnica de reamostragem descrita anteriormente. Por fim, a escolha da complexidade adequada recai sobre a configuração que ainda não apresentou redução da capacidade de aproximação, avaliada pelo desempenho obtido na validação, em relação a um modelo inicial, propositalmente superdimensionado.

Os valores extremos máximos e mínimos de todas as variáveis foram sempre incluídos nas amostras de treinamento, e os ciclos foram fixados em 100.000. Os 80 registros foram, de acordo com o próprio método, divididos em duas partes, sendo 48 registros para o treinamento

e 32 registros para a verificação. A divisão dos registros para o treinamento e a verificação foi feita utilizando-se a técnica de amostragem sistemática, resultando praticamente as mesmas distribuições de frequência, a não ser pelo fato de que os registros com dados extremos são selecionados para a amostragem de treinamento, para que a rede resultante possa ser utilizada em todo o domínio das amostras existentes.

Os limites de proximidade pesquisados, segundo a escala reduzida da variável de saída, variaram de 0,1 a 0,06, o número de repetições de treinamento foi 30 e o critério para a escolha entre repetições sucessivas foi a adoção do erro médio mínimo entre estas.

A amostra de verificação não participa de nenhuma etapa do treinamento ou da escolha da complexidade mínima da rede, sendo reservada somente para a avaliação final da eficiência dos modelos de RNAs.

4.3.5. Estatísticas de Desempenho

Para avaliar o desempenho dos modelos desenvolvidos, utilizou-se estatísticas com base nos erros na saída da rede, sendo elas: erro absoluto médio - Ea (Mean), o erro absoluto máximo - Ea (max), o erro absoluto mediano - Ea (50), o viés percentual (PBias) e o coeficiente de eficiência de Nash-Sutcliffe (Nash and Sutcliffe, 1970) ou NS.

O viés percentual (PBias) é calculado pela Equação 11, e o NS pela Equação 12:

$$PBias = \frac{\sum_{i=1}^N (X_i - Y_i) * (100)}{\sum_{i=1}^N (X_i)} \quad (11)$$

$$NS = 1 - \frac{\sum_{i=1}^N (X_i - Y_i)^2}{\sum_{i=1}^N (X_i - X_{méd})^2} \quad (12)$$

onde: X_i são os dados observados; $X_{méd}$ é a média dos dados observados; e Y_i são os dados calculados pelo modelo.

O viés percentual mostra a tendência média dos dados simulados em ser subestimados ou superestimados em relação aos dados observados. O valor ideal do PBias é 0, com valores de baixa magnitude indicando simulação sem viés. Valores positivos indicam viés de subestimação do modelo e valores negativos indicam viés de superestimação do modelo (Gupta et al., 1999).

O NS, que representa a proporção da variância dos dados que é explicada pelo modelo, varia de $-\infty$ até 1, valores próximos de 1 representam capacidade grande de aproximação; valores \leq zero indicam que o valor médio de Y é uma melhor aproximação do que os valores calculados de Y_i .

4.4. Resultados e Discussões

4.4.1. Análise das variáveis de entrada

A Tabela 1 apresenta os valores máximos, mínimos, médios, medianos, desvio padrão, bem como os coeficientes de correlação de Pearson (r) e de Spearman (ρ) entre todas as variáveis de entrada e a concentração de sedimentos em suspensão.

Observou-se que, na maioria das variáveis, a correlação não linear é ligeiramente maior que a linear. Nos dados de nível e suas defasagens, as entradas Nível t e Nível $t-1$ apresentaram as maiores correlações, no entanto, todas as defasagens selecionadas para representar a dinâmica temporal dos níveis apresentaram correlações significativas.

Para as médias móveis ponderadas exponencialmente dos níveis, a entrada EWMA Nível $h=1$ e $h=2$ apresentaram as maiores correlações, em concordância com as correlações das defasagem Nível t e Nível $t-1$. Como as correlações diminuíram, à medida que aumentou o valor de h , os níveis do passado mais recente são mais significativos na estimativa da CSS, na estação fluviométrica de Cuiabá.

Para as chuvas pontuais, as EWMA's apresentaram correlações lineares e não lineares com a CSS bem maiores que as suas respectivas defasagens. O mesmo comportamento é verificado nas EWMA's das chuvas totais na bacia, evidenciando o potencial deste recurso quando aplicado na série de precipitações. À medida que se aumenta o parâmetro h , a EWMA das chuvas pontuais e totais na bacia ficam mais fortemente correlacionada com a CSS. No entanto, valores muito elevados de h perdem o sentido físico, e por isso não foram utilizados.

Tabela 1 – Estatística descritiva das variáveis de entrada previamente selecionadas

ID	Model input and output variables	Min	Max	Mean	Median	SD	r	ρ
1	Níveis	-2,00	643,00	104,85	66,00	118,45	0,59	0,63
2	Níveis t-1	-6,00	617,00	108,49	68,50	121,70	0,60	0,64
3	Níveis t-2	-4,00	666,00	103,41	62,50	115,96	0,53	0,61
4	Níveis t-3	-5,00	655,00	102,34	64,00	116,25	0,52	0,59
5	Níveis t-4	-5,00	646,00	105,65	60,00	117,39	0,51	0,59
6	Níveis t-5	-5,00	650,00	105,96	72,50	114,33	0,45	0,55
7	EWMA Níveis h=1	-3,63	640,08	105,50	65,10	116,49	0,59	0,64
8	EWMA Níveis h=2	-4,18	635,29	105,38	67,62	113,22	0,56	0,64
9	EWMA Níveis h=3	-4,28	618,90	105,22	68,34	110,24	0,55	0,62
10	EWMA Níveis h=4	-4,18	598,99	105,08	66,17	107,88	0,53	0,61
11	EWMA Níveis h=5	-3,97	579,95	105,01	66,63	106,14	0,52	0,59
12	Chuva Pontual t	0,00	56,20	2,76	0,00	7,98	0,18	0,38
13	Chuva Pontual t-1	0,00	43,00	4,49	0,00	9,68	0,41	0,46
14	Chuva Pontual t-2	0,00	32,00	2,20	0,00	5,76	0,25	0,50
15	Chuva Pontual t-3	0,00	36,20	2,83	0,00	6,78	0,29	0,22
16	Chuva Pontual t-4	0,00	40,80	2,05	0,00	5,69	0,37	0,45
17	Chuva Pontual t-5	0,00	65,00	3,83	0,00	10,39	0,28	0,45
18	EWMA Chuva Pontual h=1	0,00	31,23	3,14	0,98	5,10	0,42	0,59
19	EWMA Chuva Pontual h=2	0,00	20,53	3,21	1,85	4,16	0,51	0,62
20	EWMA Chuva Pontual h=5	0,00	13,53	3,36	2,65	3,46	0,57	0,63
21	EWMA Chuva Pontual h=9	0,00	13,53	3,36	2,65	3,46	0,57	0,63
22	EWMA Chuva Pontual h=10	0,03	12,23	3,41	2,81	3,03	0,59	0,64
23	EWMA Chuva Pontual h=12	0,05	11,89	3,43	3,27	2,93	0,59	0,64
24	EWMA Chuva Pontual h=17	0,12	11,08	3,47	3,35	2,71	0,59	0,65
25	Chuva total na bacia	0,00	530,96	81,26	27,06	117,54	0,50	0,62
26	Chuva total na bacia t-1	0,00	892,84	117,69	20,52	189,78	0,54	0,67
27	Chuva total na bacia t-2	0,00	683,00	88,03	18,75	136,17	0,66	0,71
28	Chuva total na bacia t-3	0,00	514,11	85,12	17,41	119,80	0,53	0,53
29	Chuva total na bacia t-4	0,00	875,33	96,76	11,06	172,24	0,70	0,66
30	Chuva total na bacia t-5	0,00	688,98	108,20	20,10	153,18	0,47	0,54
31	EWMA Chuva total na bacia h=1	0,00	390,17	92,75	59,82	105,78	0,72	0,71
32	EWMA Chuva total na bacia h=2	0,03	359,70	95,91	70,48	101,67	0,77	0,74
33	EWMA Chuva total na bacia h=3	0,15	347,48	97,58	76,27	97,32	0,78	0,76
34	EWMA Chuva total na bacia h=4	0,20	332,82	98,49	73,99	93,79	0,78	0,75
35	EWMA Chuva total na bacia h=5	0,33	319,81	99,05	79,09	90,99	0,78	0,76
36	EWMA Chuva total na bacia h=9	1,03	286,00	100,24	89,06	83,87	0,76	0,77
37	EWMA Chuva total na bacia h=10	1,29	282,74	100,45	92,92	82,61	0,76	0,76
38	CSS (mg/L)	6,00	240,00	65,04	45,65	52,29	1,00	1,00

Tabela 2 – Grupos de variáveis de entrada selecionados para cada modelo

Modelo	Critério de Exclusão	Variáveis de Entrada - ID	Total
M01	Correlação de Pearson maior que 0,8	2, 14, 15, 16, 17, 26, 27, 28, 29, 30 e 34	11 variáveis
M02	Correlação de Pearson maior que 0,9	2, 12, 13, 14, 15, 16, 17, 25, 26, 27, 28, 29, 30 e 34	14 variáveis
M03	Correlação de Pearson maior que 0,95	2, 12, 13, 14, 15, 16, 17, 19, 23, 25, 26, 27, 28, 29, 30 e 34	16 variáveis
M04	Correlação de Pearson maior que 0,99	1, 2, 3, 4, 5, 6, 12, 13, 14, 15, 16, 17, 18, 19, 23, 24, 25, 26, 27, 28, 29, 30, 31, 34, e 36	25 variáveis
M05	Correlação de Spearman maior que 0,8	8, 12, 13, 14, 15, 16, 17, 30 e 36	09 variáveis
M06	Correlação de Spearman maior que 0,9	8, 12, 13, 14, 15, 16, 17, 25, 26, 27, 28, 29, 30 e 36	14 variáveis
M07	Correlação de Spearman maior que 0,95	6, 8, 12, 13, 14, 15, 16, 17, 24, 25, 26, 27, 28, 29, 30 e 36	16 variáveis
M08	Correlação de Spearman maior que 0,99	3, 4, 5, 6, 8, 12, 13, 14, 16, 17, 18, 19, 22, 24, 25, 26, 27, 28, 29, 30, 31, 33 e 36	23 variáveis
M09	Análise pessoal com base nas correlações de Pearson	1, 2, 3, 4, 5, 6, 8, 12, 13, 14, 15, 17, 19, 23, 24, 25, 26, 27, 28, 29, 30, 31, 34 e 36	24 variáveis
M10	Análise pessoal com base nas correlações de Spearman	1, 2, 3, 4, 5, 6, 8, 12, 13, 14, 15, 16, 17, 18, 22, 24, 25, 26, 27, 28, 29, 30, 31, 33 e 36	25 variáveis
M11	Exclusão de defasagens	1, 8, 12, 18, 19, 22, 23, 24, 25, 31, 33, 34 e 36	13 variáveis
M12	Exclusão de EWMA's	1, 2, 3, 4, 5, 6, 12, 13, 14, 15, 16, 17, 25, 26, 27, 28, 29 e 30	18 variáveis
M13	Nenhuma variável foi excluída	1 até 37	37 variáveis

Dentre todas as variáveis de entrada selecionadas, as relativas às chuvas totais na bacia, que são extraídas do produto MERGE, apresentaram as maiores correlações, tanto linear, quanto não linear.

Na Tabela 2 são apresentados os grupos de variáveis de entrada selecionados para compor cada modelo, bem como o critério de exclusão utilizado. Ao total, foram separados 13 grupos de variáveis distintos, que deram origem a 13 modelos de RNAs.

Observa-se que, para o limiar de exclusão igual a 0,8, com ambos os coeficientes de correlação, os modelos de RNAs ficaram com menores configurações de variáveis de entrada. Isso acontece, pois, muitas variáveis de entrada possuem elevada correlação entre si.

Ao aumentar o limiar de exclusão, gradativamente, os grupos de variáveis vão ganhando mais representantes. No entanto, mesmo com o limiar de 0,99, diversas variáveis de entrada, oriundas da seleção prévia, são deixadas de lado. Observa-se que o Modelo M04, cujo critério de exclusão foi correlações de Pearson maiores que 0,99, resultou em 25 variáveis de entrada, ou seja, 12 das 37 variáveis de entrada foram deixadas de fora.

Nota-se também que, para os mesmos limiares, o critério de exclusão de correlações de Spearman acaba sendo mais rigoroso em relação às correlações de Pearson, excluindo mais variáveis de entrada.

Para a seleção das variáveis dos modelos M09 e M10, além do conhecimento das correlações, foi considerado o conhecimento pessoal relativo às variáveis de entrada, bem como experimentações. Nestes dois modelos, todas as defasagens foram mantidas, com uma pequena diferença na escolha das EWMA's, em que no M09 selecionou-se as EWMA's com maiores correlações de Pearson (linear), enquanto que no M10 selecionou-se as EWMA's cujas correlações de Spearman (não linear) eram maiores.

O modelo M11 não considerou as defasagens, com a finalidade de avaliar se as EWMA's conseguem ser boas substitutas destas; o Modelo M12 não considerou a inclusão de EWMA's; e por fim, no modelo M13 não foi excluída nenhuma variável de entrada previamente selecionada.

O modelo M11 não considerou as defasagens, com a finalidade de avaliar se as EWMA's conseguem ser boas substitutas destas; o Modelo M12 não considerou a inclusão de EWMA's;

e por fim, no modelo M13 não foi excluída nenhuma variável de entrada previamente selecionada.

4.4.2. Modelos de RNAs para estimativa da CSS na estação de Cuiabá

Os 13 modelos desenvolvidos para estimar, de forma temporal e pontual, a concentração de sedimentos em suspensão na estação fluviométrica de Cuiabá, são apresentados na Tabela 4.

A complexidade dos modelos variou de 9 a 18 neurônios na camada intermediária, em que se observou uma relação diretamente proporcional entre estes e a quantidade de variáveis de entrada. Os modelos com menos variáveis de entrada, tais como o M01, M05 e M11, apresentaram as menores complexidades, enquanto que os modelos M08, M09, M10 e M13, que possuem maior quantidade de variáveis de entrada, apresentaram as maiores complexidades.

O desempenho dos modelos variou, em termos de coeficiente de Nash-Sutcliffe, de 0,72 a 0,78 no treinamento, e 0,71 a 0,78 na verificação. Com relação ao viés percentual (PBias), as variações foram de -0,50 a 4,93% no treinamento, e 8,28 a 15,30% na verificação.

Em geral, todos os modelos apresentam resultados satisfatórios, sendo que a maior parte dos modelos são considerados muito bons ($NS > 0,75$ e $PBias < \pm 15\%$), de acordo com a classificação de Moriasi et al., (2007) para modelos de sedimentos.

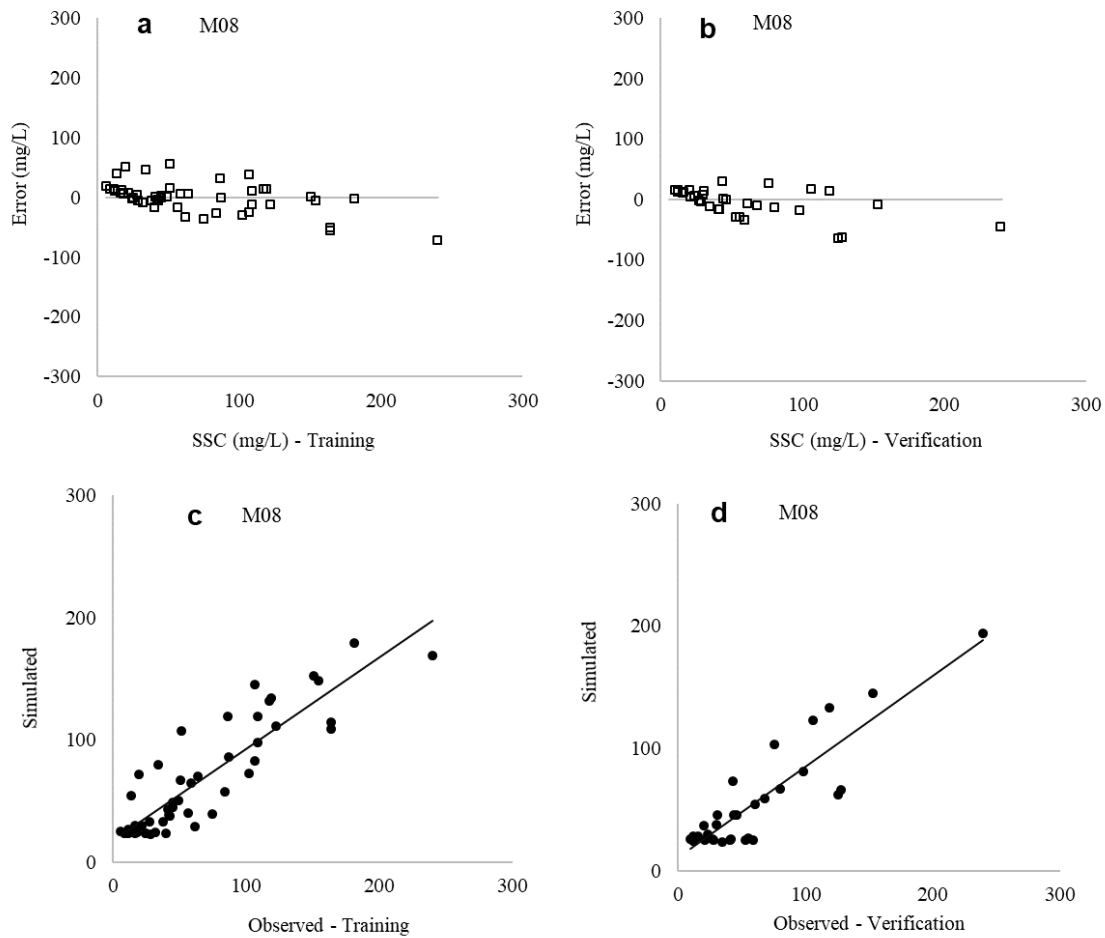
Tabela 4 – Performance estatística os modelos de RNAs para estimativa temporal da CSS

Model	nh ¹	J ²	Imprecisão	Training					Verification				
				Ea(mean)	Ea(50)	Ea(max)	Pbias	NS	Ea(mean)	Ea(50)	Ea(max)	Pbias	NS
M01	10	361	0,084	20,99	14,06	73,56	0,472	0,730	19,43	13,20	85,69	15,3	0,708
M02	12	182	0,075	18,49	11,68	76,33	1,500	0,770	17,92	13,13	73,16	12,3	0,755
M03	16	226	0,072	17,80	11,16	73,93	3,540	0,777	18,19	12,37	73,18	13,0	0,753
M04	17	128	0,072	17,77	10,90	74,19	2,190	0,775	18,03	13,15	68,03	11,4	0,765
M05	10	812	0,072	18,89	10,94	106,98	1,090	0,749	22,35	15,67	56,54	7,69	0,719
M06	16	113	0,072	17,92	9,96	76,38	-0,316	0,773	17,52	12,36	67,65	11,9	0,766
M07	16	109	0,072	17,78	9,48	67,60	0,431	0,779	17,48	11,85	69,98	13,0	0,761
M08	18	113	0,071	17,82	11,33	71,28	-0,503	0,777	17,86	14,19	63,25	8,28	0,776
M09	18	123	0,074	17,83	12,16	70,86	0,042	0,767	17,83	14,95	63,66	9,71	0,774
M10	18	127	0,075	18,25	9,99	63,32	4,930	0,773	18,12	12,05	69,78	14,0	0,76
M11	9	491	0,078	19,38	11,36	89,02	0,936	0,723	20,70	14,36	70,02	8,33	0,732
M12	11	208	0,081	17,64	10,37	66,08	-0,149	0,731	19,55	14,29	83,38	7,08	0,714
M13	18	153	0,072	17,62	9,93	74,34	1,010	0,779	18,56	15,77	64,70	8,90	0,762

Os modelos M01 a M04 (modelos em que se utilizou limiares de exclusão baseados nas correlações de Pearson) apresentaram desempenhos um pouco inferiores aos dos modelos M05 a M08 (que utilizam limiares baseados nas correlações de Spearman) quando se compara cada limiar individualmente.

O modelo M08, cujas entradas foram selecionadas por meio do limiar de exclusão de 0,99 com correlações de Spearman, apresentou o melhor desempenho na verificação, com coeficiente de Nash-Sutcliffe de $NS = 0,776$. Na Figura 5 é apresentada a distribuição dos erros e a aproximação dos dados observados e simulados do M08, para o treinamento e para a verificação. Os Modelos 09 e M10 apresentaram desempenho muito próximos ao do M08, no entanto, com a necessidade de maior número de variáveis de entrada.

Figura 5 – Erro verificado entre os valores de CSS calculados e observados durante o treinamento (a) e verificação (b); e a relação linear entre os dados calculados e observados, durante o treinamento (c) e verificação (d).



Fonte: O Autor.

Os modelos M11 e M12 são classificados como bons, de acordo com Moriasi et al., (2007), com coeficiente de Nash-Sutcliffe dentro do intervalo de $0,65 \leq NS \leq 0,75$. No modelo M11, as defasagens não foram consideradas, e o seu desempenho foi ligeiramente superior ao modelo M12, onde as EWMA's não foram inseridas. Esse resultado comprova que a inserção das médias móveis ponderadas exponencialmente produz benefícios aos modelos de RNAs para sedimentos.

No modelo M13, nenhuma variável selecionada previamente foi excluída. O desempenho dele é considerado muito bom, no entanto, parte dos modelos que utilizaram critérios de eliminação de variáveis redundantes ficaram melhores que este modelo completo, ou seja, a presença de variáveis com pronunciada redundância ocasiona redução no desempenho do modelo, sendo muito importante a análise de correlações das variáveis de entrada entre si, e delas com a variável de saída.

Embora a maior parte dos modelos necessitem do cálculo de médias móveis ponderadas exponencialmente, e seleção de defasagens, ou seja, demandam pronunciada manipulação de dados previamente à utilização do modelo, o desempenho final é bastante satisfatório nos testes executados, indicando que foi possível estabelecer uma estimativa temporal e pontual da concentração de sedimentos suspensos para o posto fluviométrico de Cuiabá.

Os dados de entrada selecionados para todos os modelos (níveis, precipitações e seus derivados) são monitorados diariamente, o que permite uma estimativa diária da CSS na estação de Cuiabá, a partir do uso dos modelos.

4.5. Conclusões

Diversos modelos de redes neurais artificiais foram desenvolvidos para estimar, de forma temporal e pontual, a concentração de sedimentos em suspensão na estação fluviométrica de Cuiabá. Os dados de entrada utilizados são todos diários, permitindo, então, uma estimativa diária da CSS nesta estação, com desempenho considerado satisfatório.

Os modelos desenvolvidos contornam a dificuldade resultante da pequena quantidade de dados de sedimentos disponíveis na estação fluviométrica selecionada (80 registros), utilizando a validação por reamostragem, que evita o superajustamento da rede a partir de uma

combinação de treinamentos, não sendo necessária a separação de uma amostra específica de validação.

Dentre as variáveis de entrada previamente selecionadas, as chuvas totais na bacia, seguida dos níveis, foram as variáveis que melhor se correlacionaram com a CSS. As chuvas totais na bacia foram obtidas do produto MERGE, mostrando a utilidade e a funcionalidade das estimativas de precipitação por sensoriamento remoto.

O cálculo de médias móveis ponderadas exponencialmente das variáveis nível e precipitação aumentou as correlações com a CSS, mostrando que este recurso é importante e produz melhorias nas estimativas dos modelos, superando, inclusive, as tradicionais defasagens, amplamente utilizadas em modelos de previsão.

Da mesma forma, o método de exclusão de variáveis com pronunciada redundância se mostrou eficiente no auxílio da escolha das variáveis de entrada, proporcionando aos modelos em que este recurso foi aplicado, uma considerável redução na quantidade de variáveis de entrada, e preservando o desempenho satisfatório, na maioria dos casos testados.

Os modelos de redes neurais aqui desenvolvidos foram capazes de reconhecer a relação de causa e efeito entre a dinâmica das precipitações, níveis e as variações de CSS, fornecendo estimativas diárias dessa variável. Em geral, os desempenhos (NS) apresentados pelos modelos foi superior a 0,75 no treinamento e na verificação, com viés percentual menor do que $\pm 15\%$, sendo, portanto, considerados muito bons nas classificações mais usuais de desempenho, estabelecidas para modelos hidrológicos e de qualidade da água.

4.6. Referências Bibliográficas

ADAMOWSKI, Jan; SUN, Karen. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. **Journal of Hydrology**, [s. l.], v. 390, n. 1–2, p. 85–91, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2010.06.033>>

AFAN, Haitham Abdulmohsin et al. ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. **Water Resources Management**, [s. l.], v. 29, n. 4, p. 1231–1245, 2014.

AGARWAL, Avinash et al. Simulation of Runoff and Sediment Yield using Artificial Neural Networks. **Biosystems Engineering**, [s. l.], v. 94, n. 4, p. 597–613, 2006.

AGARWAL, Avinash; SINGH, R. D. Runoff modelling through back propagation artificial neural network with variable rainfall-runoff data. **Water Resources Management**, [s. l.], v. 18, n. 3, p. 285–300, 2004.

ALLASIA, Daniel G. et al. **Modelo Hidrológico da Bacia do Alto Paraguai**. Porto Alegre-RS: Editora Rios Vivos, 2004.

ASCE. Artificial Neural Networks in Hydrology. I: Preliminary Concepts. In: **Journal Of hydrologic engineering**, 2000.

ATIEH, M. et al. Integrative neural networks model for prediction of sediment rating curve parameters for ungauged basins. **Journal of Hydrology**, [s. l.], v. 531, p. 1095–1107, 2015.

BAO, Zhenxin et al. Comparison of regionalization approaches based on regression and similarity for predictions in ungauged catchments under multiple hydro-climatic conditions. **Journal of Hydrology**, [s. l.], v. 466–467, p. 37–46, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.07.048>>

BAYRAM, Adem et al. Prediction of suspended sediment concentration from water quality variables. **Neural Computing and Applications**, [s. l.], v. 24, n. 5, p. 1079–1087, 2014. Disponível em: <<http://link.springer.com/10.1007/s00521-012-1333-3>>

BAYRAM, Adem; KANKAL, Murat; ÖNSOY, Hızir. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. **Environmental Monitoring and Assessment**, [s. l.], v. 184, n. 7, p. 4355–4365, 2012.

BERTONI, Jose; NETO, Francisco Lombardi. Conservação do Solo. In: 8ª ed. [s.l.] : Icone, 2006. p. 360.

BHATTACHARJYA, Rajib Kumar; CHAURASIA, Sandeep. Geomorphology Based Semi-Distributed Approach for Modelling Rainfall-Runoff Process. **Water Resources Management**, [s. l.], v. 27, n. 2, p. 567–579, 2013.

BONAN, Gordon. **Ecological Climatology**. 3. ed. Cambridge: Cambridge University Press, 2016.

BRAVO, J. M. et al. Coupled Hydrologic-Hydraulic Modeling of the Upper Paraguay River Basin. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 5, p. 635–646, 2012. Disponível em: <<http://ascelibrary.org/doi/10.1061/%28ASCE%29HE.1943-5584.0000494>>

BURROUGH, Peter A.; MCDONNELL, Rachael A. Data models and axioms: formal abstractions of reality. **Principles of geographical information systems**, [s. l.], p. 17–34, 1998. Disponível em: <<http://www.jstor.org/stable/144481?origin=crossref>>

BUYUKYILDIZ, Meral; KUMCU, Serife Yurdagul. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. **Water Resources Management**, [s. l.], v. 31, n. 4, p. 1343–1359, 2017.

CARVALHO, N. **Hidrossedimentologia prática**. 2ª ed. Rio de Janeiro: Interciência, 2008.

CHAI, Soo-See et al. Use of Soil Moisture Variability in Artificial Neural Network Retrieval of Soil Moisture. **Remote Sensing**, [s. l.], v. 2, n. 1, p. 166–190, 2009. Disponível em: <<http://www.mdpi.com/2072-4292/2/1/166/>>

CIGIZOGLU, Hikmet Kerem. Estimation, forecasting and extrapolation of river flows by artificial neural networks. **Hydrological Sciences Journal**, [s. l.], v. 48, n. 3, p. 349–362, 2003. a.

CIGIZOGLU, Hikmet Kerem. Incorporation of ARMA models into flow forecasting by artificial neural networks. **Environmetrics**, [s. l.], v. 14, n. 4, p. 417–427, 2003. b.

CIGIZOGLU, Hikmet Kerem; KISI, Özgür. Methods to improve the neural network performance in suspended sediment estimation. **Journal of Hydrology**, [s. l.], v. 317, n. 3–4, p. 221–238, 2006.

CROWDER, D. W.; DEMISSIE, M.; MARKUS, M. The accuracy of sediment loads when log-transformation produces nonlinear sediment load-discharge relationships. **Journal of Hydrology**, [s. l.], v. 336, n. 3–4, p. 250–268, 2007.

D. N. MORIASI et al. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. **Transactions of the ASABE**, [s. l.], v. 50, n. 3, p. 885–900, 2007.

DORNELLES, Fernando; GOLDENFUM, Joel Avruch; PEDROLLO, Olavo Correa. Artificial Neural Network Methods Applied to Forecasting River Levels. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 18, p. 45–54, 2013.

EMBRAPA. **Monitoramento das alterações da cobertura vegetal e uso do Solo na Bacia do Alto Paraguai – Porção Brasileira – Analysis period: 2012 to 2014**. 2015. Disponível em: <https://d3nehc6yl9qzo4.cloudfront.net/downloads/publicacao_bap_sumarioexecutivo_2012_2014_w eb.pdf>. Acesso em: 2 abr. 2018.

ESTEVES, Francisco De Assis. Fundamentos de Limnologia. In: **Interciência**. 2. ed. Rio de Janeiro. p. 226.

FAGUNDES, Hugo de Oliveira. **Modelagem Hidrossedimentológica de Grandes Bacias com Apoio de Dados In Situ e Sensoriamento Remoto**. 2018. Universidade federal do Rio Grande do Sul, [s. l.], 2018.

FANTIN-CRUZ, Ibraim et al. Historical reconstruction of floodplain inundation in the Pantanal (Brazil) using neural networks. **Journal of Hydrology**, [s. l.], v. 399, n. 3–4, p. 376–384, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2011.01.014>>

FANTIN-CRUZ, Ibraim et al. Effects of a diversion hydropower facility on the hydrological regime of the Correntes River, a tributary to the Pantanal floodplain, Brazil. **Journal of Hydrology**, [s. l.], v. 531, p. 810–820, 2015.

FANTIN-CRUZ, Ibraim et al. Changes in river water quality caused by a diversion hydropower dam bordering the Pantanal floodplain. **Hydrobiologia**, [s. l.], v. 768, n. 1, p. 223–238, 2016.

FASHI, Fereshte Haghghi. Evaluation of adaptive neural-based fuzzy inference system approach for estimating saturated soil water content. **Modeling Earth Systems and Environment**, [s. l.], v. 2, n. 4, p. 1–6, 2016. Disponível em: <<http://link.springer.com/10.1007/s40808-016-0255-y>>

FREEMAN, James A.; SKAPURA, David M. Neural Networks: Algorithms, Applications and Programming Techniques. In: **Addison-Wesley Publishing Company**. California. v. 7p. 89–124.

GIUSTOLISI, O.; LAUCELLI, D. Improving generalization of artificial neural networks in rainfall-runoff modelling. **Hydrological Sciences Journal**, [s. l.], v. 50, n. 3, p. 37–41, 2005.

HAIMANN, Marlene et al. An integrated suspended sediment transport monitoring and analysis concept. **International Journal of Sediment Research**, [s. l.], v. 29, n. 2, p. 135–148, 2014. Disponível em: <[http://dx.doi.org/10.1016/S1001-6279\(14\)60030-5](http://dx.doi.org/10.1016/S1001-6279(14)60030-5)>

HARRINGTON, Seán T.; HARRINGTON, Joseph R. An assessment of the suspended sediment rating curve approach for load estimation on the Rivers Bandon and Owenabue, Ireland. **Geomorphology**, [s.

l.], v. 185, p. 27–38, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.geomorph.2012.12.002>>

HASSAN-ESFAHANI, Leila et al. Spatial Root Zone Soil Water Content Estimation in Agricultural Lands Using Bayesian-Based Artificial Neural Networks and High- Resolution Visual, NIR, and Thermal Imagery. **Irrigation and Drainage**, [s. l.], v. 66, n. 2, p. 273–288, 2017.

HASSAN, Muhammad et al. Development of sediment load estimation models by using artificial neural networking techniques. **Environmental Monitoring and Assessment**, [s. l.], v. 187, n. 11, 2015.

HECHT-NIELSEN, Robert. Theory of the Backpropagation Neural Network. **Proceedings Of The International Joint Conference On Neural Networks**, [s. l.], v. 1, p. 593–605, 1989. Disponível em: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=118638>

HENG, Sokchhay; SUETSUGI, Tadashi. Using Artificial Neural Network to Estimate Sediment Load in Ungauged Catchments of the Tonle Sap River Basin, Cambodia. **Journal of Water Resource and Protection**, [s. l.], v. 05, n. 02, p. 111–123, 2013.

HENG, Sokchhay; SUETSUGI, Tadashi. Comparison of regionalization approaches in parameterizing sediment rating curve in ungauged catchments for subsequent instantaneous sediment yield prediction. **Journal of Hydrology**, [s. l.], v. 512, p. 240–253, 2014.

HENG, Sokchhay; SUETSUGI, Tadashi. Regionalization of sediment rating curve for sediment yield prediction in ungauged catchments. **Hydrology Research**, [s. l.], v. 46, n. 1, p. 26–38, 2015.

HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert. Multilayer feedforward networks are universal approximators. **Neural Networks**, [s. l.], v. 2, n. 5, p. 359–366, 1989.

JAIN, Sharad Kumar. Development of integrated sediment rating curves using ANNs. **Journal of hydraulic engineering**, [s. l.], v. 127, n. 1, p. 30–37, 2001.

JENSEN, John R. Sensoriamento remoto do ambiente: In: [s.l: s.n.]. p. 598.

KAKAEI LAFDANI, E.; MOGHADDAM NIA, A.; AHMADI, A. Daily suspended sediment load prediction using artificial neural networks and support vector machines. **Journal of Hydrology**, [s. l.], v. 478, p. 50–62, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.11.048>>

KASABOV, N. K. Foundations of neural networks, fuzzy systems, and knowledge engineering. In: **Massachusetts institute of technology**. Cambridge. p. 251–358.

KISI, Ozgur; OZKAN, Coskun; AKAY, Bahriye. Modeling discharge–sediment relationship using neural networks with artificial bee colony algorithm. **Journal of Hydrology**, [s. l.], v. 428–429, p. 94–103, 2012.

LIBOS, Marcio Inpes. **Modelagem Hidrológica quali-quantitativa: estudo de caso da bacia do rio Manso-MT**. 2008. Universidade Federal do Rio de Janeiro, [s. l.], 2008.

LIMA, Estevão Bernardes. **modelagem Integrada para Gestão da Qualidade da Água na Bacia do Rio Cuiabá**. 2001. Universidade Federal do Rio de Janeiro, [s. l.], 2001.

MINNS, A. W.; HALL, M. J. Artificial neural networks as rainfall-runoff models. **Hydrological Sciences Journal**, [s. l.], v. 41, n. 3, p. 399–417, 1996.

MOHAMOUD, Yusuf M. Time Series Separation and Reconstruction Technique to Estimate Daily

Suspended Sediment Concentrations. **Journal of Hydrologic Engineering**, [s. l.], v. 19, n. 2, p. 328–338, 2014.

MOORE, R. J. **Real-time forecasting of flood events using transfer function noise models: report, Part 2.** Wallingford Institute of Hydrology., , 1980.

MUSIS, Carlos Rozante. **caracterização Climatológica da Bacia do Alto Paraguai.** 1997. Universidade Federal de Mato Grosso, [s. l.], 1997.

MUSTAFA, M. R. et al. River suspended sediment prediction using various multilayer perceptron neural network training algorithms-A case study in Malaysia. **Water Resources Management**, [s. l.], v. 26, n. 7, p. 1879–1897, 2012.

NOURANI, Vahid; KALANTARI, Omid. Integrated Artificial Neural Network for Spatiotemporal Modeling of Rainfall–Runoff–Sediment Processes. **Environmental Engineering Science**, [s. l.], v. 27, n. 5, p. 411–422, 2010.

NOURANI, Vahid; KALANTARI, Omid; BAGHANAM, Aida Hosseini. Two Semidistributed ANN-Based Models for Estimation of Suspended Sediment Load. **Journal of Hydrologic Engineering**, [s. l.], v. 17, n. 12, p. 1368–1380, 2012.

NOURANI, Vahid; KOMASI, Mehdi; MANO, Akira. A Multivariate ANN-Wavelet Approach for Rainfall–Runoff Modeling. **Water Resources Management**, [s. l.], v. 23, n. 14, p. 2877–2894, 2009.

OLIVEIRA, Marquis Henrique Campos et al. Estimation of soil water content in watershed using artificial neural networks. **Hydrological Sciences Journal**, [s. l.], v. 62, n. 13, p. 2120–2138, 2017. Disponível em: <<https://doi.org/10.1080/02626667.2017.1364844>>

PAES, Rafael Pedrollo. **Análise da translação da onda de cheia efluente do reservatório da UHE Manso na bacia hidrográfica do rio Cuiabá, Mato Grosso.** 2011. Universidade de São Paulo, [s. l.], 2011.

RAJAEI, Taher. Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers. **Science of the Total Environment**, [s. l.], v. 409, n. 15, p. 2917–2928, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.scitotenv.2010.11.028>>

ROMAN, David C.; VOGEL, Richard M.; SCHWARZ, Gregory E. Regional regression models of watershed suspended-sediment discharge for the eastern United States. **Journal of Hydrology**, [s. l.], v. 472–473, p. 53–62, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2012.09.011>>

ROZANTE, José Roberto et al. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. **American Meteorological Society**, [s. l.], v. 25, n. 3, p. 885–894, 2010. Disponível em: <<http://journals.ametsoc.org/doi/abs/10.1175/2010WAF2222325.1>>

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, [s. l.], v. 323, n. 6088, p. 533–536, 1986.

SALIHA, A. H. et al. Estimation of flow in ungauged catchments by coupling a hydrological model and neural networks: case study. **Hydrology Research**, [s. l.], v. 42, n. 5, p. 386–400, 2011. Disponível em: <<http://hr.iwaponline.com/cgi/doi/10.2166/nh.2011.157>>

SANTOS, Humberto Gonçalves et al. **Brazilian soil classification system.** 2018. Disponível em: <<https://www.embrapa.br/solos/busca-de-publicacoes/-/publicacao/1094001/brazilian-soil->

classification-system>. Acesso em: 7 abr. 2018.

SARI, Vanessa. **Monitoramento e Modelagem da Produção de Sedimentos em uma Bacia hidrográfica no Noroeste do Rio Grande do Sul**. 2017. Universidade Federal do Rio Grande do Sul, [s. l.], 2017.

SARI, Vanessa; CASTRO, Nilza Maria dos Reis; PEDROLLO, Olavo Correa. Estimate of Suspended Sediment Concentration from Monitored Data of Turbidity and Water Level Using Artificial Neural Networks. **Water Resources Management**, [s. l.], v. 31, n. 15, p. 4909–4923, 2017.

SHELLENBARGER, Gregory G.; WRIGHT, Scott A.; SCHOELLHAMER, David H. A sediment budget for the southern reach in San Francisco Bay, CA: Implications for habitat restoration. **Marine Geology**, [s. l.], v. 345, p. 281–293, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.margeo.2013.05.007>>

SHOAI, Muhammad et al. A Comparative Study of Various Hybrid Wavelet Feedforward Neural Network Models for Runoff Forecasting. **Water Resources Management**, [s. l.], v. 32, n. 1, p. 83–103, 2018.

SILVA, Alexandre Marco; SCHULZ, Harry Edmar; CAMARGO, Plínio Barbosa. Erosão e Hidrossedimentologia em Bacias Hidrográficas. In: 1. ed. [s.l.] : Rima, 2003. p. 140.

SINGH, A. et al. Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. **Agricultural Water Management**, [s. l.], v. 104, p. 113–120, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2011.12.005>>

SINGH, Ajai et al. Comparison of Artificial Neural Network Models for Sediment Yield Prediction at Single Gauging Station of Watershed in Eastern India. **Journal of Hydrologic Engineering**, [s. l.], v. 18, n. 1, p. 115–120, 2013.

SIVAPALAN, M. et al. IAHS Decade on Predictions in Ungauged Basins (PUB), 2003–2012: Shaping an exciting future for the hydrological sciences. **Hydrological Sciences Journal**, [s. l.], v. 48, n. 6, p. 857–880, 2003.

TALEBIZADEH, Mansour et al. Uncertainty analysis in sediment load modeling using ANN and SWAT model. **Water Resources Management**, [s. l.], v. 24, n. 9, p. 1747–1761, 2010.

TANANAEV, N. I.; DEBOLSKIY, M. V. Turbidity observations in sediment flux studies: Examples from Russian rivers in cold environments. **Geomorphology**, [s. l.], v. 218, p. 63–71, 2014.

TAYFUR, G. Artificial neural networks for sheet sediment transport - ResearchGate. **Hydrological Sciences Journal**, [s. l.], v. 47, n. 6, p. 879–892, 2002.

TAYFUR, G.; GULDAL, V. Artificial neural networks for estimating daily total suspended sediment in natural streams. **Nordic Hydrology**, [s. l.], v. 37, n. 1, p. 69–79, 2006.

TOKAR, By Sezin; JOHNSON, Peggy. Rainfall-Runoff Modeling Using Artificial Neural Networks. **Journal of Hydrologic Engineering**, [s. l.], v. 4, n. 3, p. 232–239, 1999.

TRAMBLAY, Yves et al. Regional estimation of extreme suspended sediment concentrations using watershed characteristics. **Journal of Hydrology**, [s. l.], v. 380, n. 3–4, p. 305–317, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.jhydrol.2009.11.006>>

TRENOUTH, William R.; GHARABAGHI, Bahram. Event-based soil loss models for construction sites. **Journal of Hydrology**, [s. l.], v. 524, p. 780–788, 2015.

VOGL, T. P. et al. Accelerating the convergence of the back-propagation method. **Biological Cybernetics**, [s. l.], v. 59, n. 4–5, p. 257–263, 1988.

WIDROW, B.; HOFF, Me. Adaptive switching circuits. **Ire Wescon Convention Record**, [s. l.], n. 4, p. 96–104, 1960.

WMO, The World Meteorological Organization. **Manual on Sediment Management and Measurement**. [s.l: s.n.].

ZEILHOFER, Peter; MOURA, Rubem Mauro. Hydrological changes in the northern Pantanal caused by the Manso dam: Impact analysis and suggestions for mitigation. **Ecological Engineering**, [s. l.], v. 35, n. 1, p. 105–117, 2009.

ZEROUAL, Ayoub; MEDDI, Mohamed; ASSANI, Ali A. Artificial Neural Network Rainfall-Discharge Model Assessment Under Rating Curve Uncertainty and Monthly Discharge Volume Predictions. **Water Resources Management**, [s. l.], v. 30, n. 9, p. 3191–3205, 2016. Disponível em: <<http://dx.doi.org/10.1007/s11269-016-1340-8>>

ZHANG, Wei et al. Estimating suspended sediment loads in the Pearl River Delta region using sediment rating curves. **Continental Shelf Research**, [s. l.], v. 38, p. 35–46, 2012.

ZHANG, Yongqiang; CHIEW, Francis H. S. Relative merits of different methods for runoff predictions in ungauged catchments. **Water Resources Research**, [s. l.], v. 45, n. 7, 2009.

5. CONSIDERAÇÕES FINAIS DA DISSERTAÇÃO

A presente pesquisa explorou as abordagens de modelagem espacial e temporal para a simulações da CSS em bacias com monitoramento insuficiente desta variável, na forma de dois artigos.

No capítulo 3, onde é apresentado o artigo referente à abordagem de simulação da CSS em escala espacial, a união de dados de diversas estações sedimentométricas com baixa frequência amostral tornou possível o uso das redes neurais artificiais. Em relação às variáveis de entrada, a turbidez se mostrou mais relevante na composição do modelo, seguida pelas classes de tipo de solo, o uso e ocupação do solo e as EWMA das chuvas. Os modelos desenvolvidos nesta etapa podem ser utilizados em outras estações fluviométricas que monitoram a turbidez, dentro da bacia do Alto Paraguai, ampliando as informações de sedimentos nesta bacia.

No modelo espacial, a turbidez revelou-se indispensável para a obtenção de bons resultados. Observou-se também que os modelos melhoraram com a exclusão das variáveis com correlações cujo p-value seja > 0.05 (correlações menores com a CSS), pois reduz-se a redundância de informações já contidas em outras variáveis.

A exclusão das vazões, do modelo espacial, foi menos prejudicial do que a exclusão das EWMA das chuvas, segundo os NS de verificação. Neste caso, é possível utilizar modelos em estações sem dados de vazão.

A bacia do Alto Paraguai possui uma grande variabilidade de tipo de solo e altitude, apresentando uma grande diferença entre os processos hidrológicos que ocorrem no planalto e na planície. E a inserção de entrada relativas às características físicas da área de drenagem de cada ponto, tais como o tipo de solo, a declividade média, o uso do solo e a cobertura vegetal, proporcionou aos modelos a capacidade de diferenciação destes processos.

Estão presentes na bacia do Alto Paraguai 49 estações que monitoram turbidez. Embora este número ainda seja baixo frente ao tamanho da bacia (cerca de 360.000 km²), as mesmas possuem uma boa distribuição espacial, e por este motivo, podem ampliar, pelo uso do modelo espacial, as informações sobre CSS na bacia.

A grande vantagem da abordagem espacial proposta neste estudo é o aumento do número de dados para treinamento, validação e verificação com RNAs, em função da junção

dos dados de todas as estações sedimentométricas dentro da bacia. Outra vantagem é que o modelo fornece informações para diversos pontos da bacia, podendo servir de base para diversos estudos futuros.

Uma limitação da abordagem espacial elaborada é a dependência de dados de turbidez para entrada. Apesar da turbidez ser uma variável mais fácil de ser adquirida, a periodicidade em que a mesma é amostrada na bacia do Alto Paraguai ainda é pequena (cerca de 5 a 6 medições por ano), embora, ainda seja maior que a de CSS.

No capítulo 3, que corresponde ao segundo artigo, os modelos desenvolvidos estimam a concentração de sedimentos em suspensão na estação fluviométrica de Cuiabá (um único ponto) a partir de dados de nível, chuva pontual e o somatório da chuva total na bacia. Essas variáveis de entrada são, tipicamente, monitoradas diariamente nas estações brasileiras, e por este motivo, o modelo temporal é capaz de estimar concentração de sedimentos em suspensão em escala diária.

Grande parte das estações que registram sedimentos suspensos possuem baixa frequência de amostragem, e por este motivo, dificilmente se encontram grandes séries históricas de CSS para calibração de modelos. Portanto, para a construção do modelo temporal com RNAs, lançou-se mão da técnica de treinamento de RNAs com validação por reamostragem, que, comprovadamente (SARI et al. 2017) consegue estabelecer uma relação entre as variáveis de entrada e saída, mesmo em situações com baixa disponibilidade de dados, como é o caso da maior parte das estações sedimentométricas brasileiras. Assim, o modelo obtido nesta etapa da pesquisa é capaz de produzir séries históricas de estimativa da CSS, sendo dependente somente do tamanho da série histórica das variáveis de entrada, bem como da observação quanto à extrapolação do domínio.

A inserção das médias móveis ponderadas exponencialmente das chuvas passadas proporcionou melhoria no desempenho dos modelos, tanto espacial, mas principalmente o temporal, evidenciando que estas variáveis podem ser mais exploradas em modelos de estimativas de sedimentos.

Trabalhos anteriores documentam modelos de estimativa da CSS a partir de vazões e turbidez, para uma única seção, com desempenhos satisfatórios. Nesta pesquisa, observa-se que estas correlações são válidas para estabelecer relações em uma única seção, submetida às mesmas condicionantes físicas. Porém, comprova-se, nesta pesquisa, que, para uma seção

específica, estimativas da CSS podem ser obtidas a partir de dados hidrológicos (chuvas e níveis ou vazões), sem necessidade de fazer uso das relações com as medidas simultâneas de turbidez, além de viabilizar a obtenção facilitada de séries diárias de dados de CSS.

De forma geral, observou-se que é possível estabelecer uma relação entre a CSS e as ocorrências recentes de chuvas e de níveis, para uma seção fluvial com dados suficientes, uma vez que as informações das características físicas (como o tipo de solo) da bacia representada por esta seção são supostas implícitas na estrutura e nos pesos sinápticos das redes neurais artificiais, após o treinamento.

Quando não existem dados suficientes em uma única seção, porém, ainda é possível produzir modelos para a estimativa de CSS, desde que as características físicas sejam incluídas, uma vez que modelos regionais para CSS, com dados apenas de turbidez e de descarga, por exemplo, não apresentam bons resultados. Porém, com dados físicos de cada seção, a inclusão também da turbidez revelou-se fundamental para a obtenção de modelos relevantes.