

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

Juliana Andrade Campos

**DINÂMICA ESPAÇO-TEMPORAL DE SEDIMENTOS EM SUSPENSÃO NA
REGIÃO HIDROGRÁFICA DO PARAGUAI/PANTANAL**

Abordagens Envolvendo Aprendizado de Máquinas e Sensoriamento Remoto

Porto Alegre, 2023

Juliana Andrade Campos

**DINÂMICA ESPAÇO-TEMPORAL DE SEDIMENTOS EM SUSPENSÃO NA
REGIÃO HIDROGRÁFICA DO PARAGUAI/PANTANAL**

Abordagens Envolvendo Aprendizado de Máquinas e Sensoriamento Remoto

Tese apresentada ao Programa de Pós-graduação em Recursos Hídricos e Saneamento Ambiental, como requisito parcial para a obtenção do título de Doutorado em Recursos Hídricos e Saneamento Ambiental.

Orientador: Prof. Dr. Olavo Correa Pedrollo

Porto Alegre, 2023

CIP - Catalogação na Publicação

Campos, Juliana Andrade
DINÂMICA ESPAÇO-TEMPORAL DE SEDIMENTOS EM SUSPENSÃO
NA REGIÃO HIDROGRÁFICA DO PARAGUAI/PANTANAL:
Abordagens Envolvendo Aprendizado de Máquinas e
Sensoriamento Remoto / Juliana Andrade Campos. --
2023.
153 f.
Orientador: Olavo Correa Pedrollo.

Tese (Doutorado) -- Universidade Federal do Rio
Grande do Sul, Instituto de Pesquisas Hidráulicas,
Programa de Pós-Graduação em Recursos Hídricos e
Saneamento Ambiental, Porto Alegre, BR-RS, 2023.

1. hidrossedimentologia. 2. Escassez de dados. 3.
redes neurais artificiais. 4. sistemas de inferência
Fuzzy. 5. Empreendimentos hidrelétricos. I. Pedrollo,
Olavo Correa, orient. II. Título.

Juliana Andrade Campos

**DINÂMICA ESPAÇO-TEMPORAL DE SEDIMENTOS EM SUSPENSÃO NA
REGIÃO HIDROGRÁFICA DO PARAGUAI/PANTANAL**

Abordagens Envolvendo Aprendizado de Máquinas e Sensoriamento

Tese apresentada ao Programa de Pós-graduação em Recursos Hídricos e Saneamento Ambiental, como requisito parcial para a obtenção do título de Doutorado em Recursos Hídricos e Saneamento Ambiental.

Aprovado em: Porto Alegre, 08 de Dezembro de 2023.

Prof. Dr. Olavo Correa Pedrollo – IPH/UFRGS

Orientador

Prof^ª. Dr^ª Cintia Bertacchi Uvo – Lund University

Examinadora

Prof. Dr. Guilherme Garcia de Oliveira – PPGSR/UFRGS

Examinador

Prof. Dr. Ibraim Fantin da Cruz – PPGRH/UFMT

Examinador

Prof^ª. Dr^ª Nilza Maria dos Reis castro – IPH/UFRGS

Examinadora

Agradecimentos

Me atrevo a dizer que o processo de desenvolvimento dessa pesquisa de doutorado compôs uma linda música, cujas pessoas envolvidas direta e indiretamente representam os acordes que compõem a melodia. Sem vocês a música simplesmente não existiria.

Primeiramente eu quero agradecer ao meu orientador, Prof. Olavo. Desde 2017, ainda lá no mestrado, ele me ensinou muito sobre pesquisa científica, me ensinou a programar, me apresentou a ciência dos dados ambientais e as ferramentas poderosas computacionais que podemos utilizar para modelar estes dados. Para alguns amigos, eu costumo brincar que ele é o “Pai Olavo”, dado acolhimento, inspiração, amizade e parceria que construímos ao longo desses anos de convivência. Desenvolver essa Tese sob a orientação dele foi crucial para que o processo fosse o mais leve e interessante possível. Obrigada, Professor!

Agradeço também ao Instituto de Pesquisas Hidráulicas, e ao PPG em Recursos Hídricos e Saneamento Ambiental, motivo que me levou a morar em Porto Alegre, e que moldou a minha formação enquanto pesquisadora. Sou imensamente grata pela oportunidade de ter aprendido com figuras gigantes da área de recursos hídricos, como o Prof. Joel Goldenfum, Prof. Fernando Dornelles, Prof^a Nilza Castro, Prof. Gean Michel, Prof. André Silveira, Prof. Rodrigo Paiva, Prof. Walter Collischonn, Prof. Anderson Ruhoff, entre tantos outros igualmente importantes. Fazer parte dessa instituição moldou a minha forma de pensar, e influenciou os caminhos que eu escolhi seguir daqui pra frente. Obrigada IPH e UFRGS!

Quero agradecer a Cintia B. Uvo, pela acolhida tão calorosa durante o período do doutorado sanduiche na Lund University – Suécia. A Cintia foi fundamental na etapa final da minha pesquisa, período em que optamos por incluir o sensoriamento remoto como um ponto chave na Tese, e que juntou as partes da pesquisa de forma mágica e instigante. A Cintia é muito inspiradora, forte, de uma inteligência única, e eu certamente me inspiro muito na figura que ela representa, e no caminho profissional magnífico que ela trilhou. Obrigada, Cintia!

Agradeço também aos membros da banca, Profa. Nilza, Profa. Cintia, Prof. Guilherme e Prof. Ibraim. Obrigada pelas contribuições, desde a época da qualificação. Vocês são grandes fontes de inspiração!

Quero agradecer aos meus colegas do IPH, que tornaram esse processo todo muito mais divertido, leve, e cheio de significados. Obrigada Fran Zanandrea, Débora, Marcos, Alice, Marina, Cleber, Bruno, Carlos, Dani Pariconha, Benício, Iporã, Rafa, Gean, Karla, Dandan, Teteu, Pedro Miranda, Hugo Gico, Dani Duran, Itza, Michele, Fran Vanelli, Ligia, Ian, Larissa, Léo, Jéssica, e todos os outros com os quais eu convivi e dividi momentos especiais ao longo destes 4 anos.

Também agradeço aos amigos queridos da Lund University, Thais Fujita, Adriana Cuartas, Dimaghi, Emmy, Beshid e Anna Adell. Obrigada pelos momentos mágicos que tivemos durante o meu intercâmbio na Suécia, com as “wine therapys”, os “Fika” e os papos de corredores. Tenho muitas saudades de vocês!

Um agradecimento especial para a Alice Fassoni Andrade, que me inspirou e me ajudou muito nos estudos mais específicos de sensoriamento remoto, e na interpretação dos resultados para a planície de inundação do Pantanal. Alice, você é uma grande fonte de inspiração. Obrigada por todo o incentivo e acolhimento!

Agradeço também à Leticia Paludo, minha amiga desde a minha chegada em Porto Alegre, e minha *roomie*, minha família, minha parceirona de apartamento e de vida. Obrigada por ser uma irmã, com todo o teu acolhimento, com os nossos momentos diversões e de aconchego. Teu incentivo foi bem importante para que essa Tese chegasse ao fim.

Não poderia deixar de agradecer ao Joel Häggqvist, e todos os outros amigos que eu fiz durante as minhas temporadas na Suécia. Guardo no coração todos os momentos especiais que vivi nesse país, ao lado de pessoas queridas que conheci lá. Edwin, Isabel, Esme, Karin, Manfred, Andres, e todos os outros... Muito obrigada. Ao lado de vocês, eu me senti pertencida e acolhida, mesmo tendo ficado presa no país de vocês durante a pandemia. Joel, um agradecimento especial por todo apoio que você sempre me deu com a pesquisa de doutorado, se envolvendo e tentando me ajudar de diversas formas. Obrigada pelos momentos leves e maravilhosos. Você foi fundamental nesse processo.

Não poderia deixar de agradecer à minha família. Mãe (Meiry), Pai (Leco), minha irmã Tais, minhas sobrinhas Maria Julia e Maria Helena. Vocês são a minha razão de viver. Graças a vocês, eu tenho a oportunidade de viver com alegria, de me aventurar com a certeza de que nós sempre estaremos lá, um para o outro. Eu amo vocês!

Um agradecimento especial ao Carlos, pelos momentos leves agora na finaleira, me dando alegrias, aventuras, aconchego, conversas muito boas, momentos musicais, apoio e incentivo constante. Você foi fundamental para que eu conseguisse finalizar a Tese. Muito Obrigada!

Por fim, agradeço imensamente à CAPES, por ter financiado essa pesquisa de doutorado por meio da minha bolsa de doutorado, e a bolsa PRINT, para o meu doutorado sanduíche. A CAPES, por meio do governo brasileiro, me deu a oportunidade de vivenciar uma experiência internacional que mudou os rumos da minha pesquisa para melhor, bem como enriqueceu as minhas experiências pessoais. Espero poder retribuir, contribuindo em pesquisa e ensino de qualidade para o meu país!

O Pantanal é uma vastidão,
Uma miragem de águas e vida,
Um paraíso de biodiversidade,
Uma imensidão que nos convida.

Nas águas calmas e cristalinas,
Refletem-se as cores do céu,
E sob as árvores retorcidas,
A vida se renova

O Pantanal é um sonho,
Um lugar que toca a alma,
Onde a natureza é soberana,
E o tempo não tem pressa ou calma.

É um tesouro que devemos guardar,
Um exemplo de como a vida pode ser,
Um lugar que nos faz lembrar,
Que sem a natureza não dá pra viver.

Juliana Andrade Campos

RESUMO

A bacia do Alto Paraguai (BAP) possui a maior área úmida tropical do mundo: o Pantanal, marcado por um regime hidrológico de inundação sazonal e uma grande biodiversidade de fauna e flora. A BAP é considerada uma região bastante heterogênea, em termos de relevo, tipos de solo, cobertura vegetal e usos da terra. Essa heterogeneidade física, bem como o regime hidrológico sazonal resultam em rios com águas que vão desde transparentes a turvas, em diferentes regiões, caracterizando uma dinâmica hidrossedimentológica bastante complexa e ainda pouco compreendida. Pouco se sabe sobre os fatores causadores da variabilidade espaço-temporal que ocorre na BAP. Apesar da grande importância ambiental dessa região, a caracterização de impactos, assim como o desenvolvimento de estudos relacionados ao transporte de sedimentos são prejudicados pela escassez de dados de sedimentos *in situ*. Outra questão de interesse ambiental que vem ganhando atenção nessa região é o aumento de pequenos empreendimentos hidrelétricos nos rios tributários do Pantanal. Os impactos dessas estruturas menores no transporte de sedimentos foram pouco investigados. O uso de aprendizado de máquinas e de técnicas de sensoriamento remoto vem ganhando cada vez mais espaço nos estudos de fenômenos não lineares e de grande complexidade, como os fenômenos relacionados aos sedimentos. Neste sentido, o objetivo desta pesquisa foi desenvolver técnicas originais baseadas em máquinas de aprendizado e sensoriamento remoto para avaliar, compreender e caracterizar a dinâmica espaço-temporal de sedimentos suspensos na BAP. Um modelo regional baseado em redes neurais artificiais (RNAs) foi desenvolvido para estimar a concentração de sedimentos suspensos (CSS) em rios sem monitoramento desta variável, a partir de outras variáveis obtidas via sensoriamento remoto e via estações fluviométricas de domínio público. Também foram avaliados os efeitos de hidrelétricas no transporte de CSS, identificando relações entre diferentes características da bacia hidrográfica, características da barragem e variações hidrológicas que podem influenciar os efeitos causados pelas instalações hidrelétricas. Os efeitos foram avaliados por meio de uma metodologia original desenvolvida para interpretação de bancos de regras de sistemas de inferência fuzzy. Por fim, foi elaborado um mapeamento abrangente da dinâmica de CSS nos rios e lagoas do Pantanal, utilizando a plataforma Google Earth Engine, juntamente com imagens do Sentinel-2 e do Landsat-8/9, e modelos de RNAs. As abordagens desenvolvidas proporcionaram uma caracterização abrangente do comportamento dos sedimentos suspensos ao longo do Pantanal, da influência da sazonalidade hidrológica nesse comportamento, bem como da influência dos empreendimentos hidrelétricos na dinâmica de sedimentos da BAP.

Palavras-chave: Escassez de dados; Redes neurais artificiais; Sistemas de inferência fuzzy; Inteligência Artificial; Hidrossedimentologia; Empreendimentos hidrelétricos.

ABSTRACT

The Upper Paraguay River Basin (UPRB) holds the world's largest tropical wetland area: the Pantanal, characterized by a seasonal flooding hydrological regime and a rich biodiversity of fauna and flora. The UPRB is considered a highly heterogeneous region in terms of topography, soil types, vegetation cover, and land use. This physical heterogeneity, associated with the seasonal hydrological regime, leads to rivers ranging from clear to turbid waters across different areas, defining a highly complex hydrosedimentological dynamic that is still poorly understood. Limited knowledge exists regarding the factors causing the spatial and temporal variability in the UPRB. Despite the environmental importance of this region, understanding the impacts and conducting sediment-related studies is hindered by the scarcity of *in situ* sediment data. Another environmental concern gaining attention in this region is the rise of small hydropower projects in the tributaries of the Pantanal. The impacts of these smaller structures on sediment transport have been poorly investigated. The use of machine learning and remote sensing techniques has been increasingly integrated into studies of nonlinear and highly complex phenomena, such as those related to sediments. In this context, the objective of this research was to develop original techniques based on machine learning and remote sensing to assess, understand, and characterize the spatio-temporal dynamics of suspended sediments in the UPB. A regional model based on artificial neural networks (ANNs) was developed to estimate suspended sediment concentration (SSC) in rivers without monitoring of this variable, using other variables obtained via remote sensing and from publicly available river gauging stations. The effects of hydropower plants on sediment transport were also evaluated, identifying relationships among different characteristics of the hydrographic basin, dam features, and hydrological variations that can influence the effects caused by hydropower facilities. The effects were assessed using an original methodology developed for interpreting rule banks of fuzzy inference systems. Finally, a comprehensive mapping of suspended sediment dynamics in the rivers and lakes of the Pantanal was developed using the Google Earth Engine platform, along with Sentinel-2 and Landsat-8/9 imagery, and artificial neural network models. The developed approaches provided a comprehensive characterization of the behaviour of suspended sediments along Pantanal, the influence of hydrological seasonality on this behaviour, as well as the influence of hydropower projects on the hydro-sedimentology of the UPRB.

Keywords: Data scarcity; Artificial neural networks; Remote sensing; Fuzzy inference systems; Hydropower plants; Artificial intelligence; Hydrosedimentology.

Lista de Figuras

Fig. 1 – Região de estudo da Tese.....	15
Fig. 2 - Estrutura geral da Tese – formato de artigos.....	21
Fig. 3 - Comportamento das chuvas e das vazões ao longo da bacia do Alto Paraguai.....	23
Fig. 4 - Altimetria da bacia do Alto Paraguai	25
Fig. 5 - Uso e cobertura da terra na BAP	26
Fig. 6 - Tipos de solos da BAP.....	27
Fig. 7 – Rede de monitoramento hidrológico da bacia do Alto Paraguai	28
Fig. 8 - Localization of the study area, showing the selected hydrometric stations.....	45
Fig. 9 - Summary of the input and output variables.....	49
Fig. 10 - Soil type classes (a), land use classes (b) and digital elevation model (c) in the UPRB	52
Fig. 11 - 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	57
Fig. 12 - Study area and hydroelectric facilities in the Pantanal watershed.....	64
Fig. 13 - Land use and cover (a) and soil type (b) in the Upper Paraguay River Basin.....	67
Fig. 14 - Methodological framework	68
Fig. 15 - Summary of the selected input and output variables.....	70
Fig. 16 - Scheme of the general Mamdani FIS structure	71
Fig. 17 - Observed and calculated alteration of SSC by FIS 01, FIS 03, and FIS 05	76
Fig. 18 - Fuzzy sets of input variables of FIS 03. Blue: Low fuzzy set; Red: Medium fuzzy set; Green: High fuzzy set.....	77
Fig. 19 - Fuzzy sets of the sediment variables of FIS 03	78
Fig. 20 - Feature importance analysis for FIS 03	80
Fig. 21 - Frequency analysis of the input variables – FIS 03.....	81
Fig. 22 - Upper Paraguay river basin (Pantanal hydrographic region).	96
Fig. 23 - Flowchart of the methodology.....	98
Fig. 24 - Region of influence of the streamflow gauging station.....	100
Fig. 25 - Architecture of the k-fold ANN models	104
Fig. 26 - Fit between observed and calculated data for the 5 ANN models within the verification sample.....	105
Fig. 27 - Time series of SSC calculated at the Cuiabá (1), Porto Conceição (2), Acima do Córrego Grande (3), Porto do Alegre (4), Coxim (5) and Amolar (6) gauging stations. The SSC scale on the y-axis is different for upland stations (stations 1, 2 and 3) and floodplain stations (4, 5 and 6).	106
Fig. 28 - Quarterly SSC mapping for upland stations	108
Fig. 29 - Quarterly SSC mapping for floodplain stations	110

Fig. 30 – Área de estudo – Principais sub-bacias da bacia do Alto Paraguai	116
Fig. 31 – Inventário de empreendimentos hidrelétricos na bacia do Alto Paraguai.....	117
Fig. 32 – Sub-bacia 01 – Paraguai superior	120
Fig. 33 – Sub-bacia 02 – rio Cuiabá.....	121
Fig. 34 – Sub-bacia 03 – rio São Lourenço.....	123
Fig. 35 – Sub-bacia 04 – rio Piquiri/Correntes.....	124
Fig. 36 – Sub-bacia 05 – rio Taquari.....	126
Fig. 37 – Sub-bacia 06 – rio Negro MS	127
Fig. 38 – Sub-bacia 07 – rio Miranda.....	128
Fig. 39 – Sub-bacia 08 – Corixó Grande.....	129
Fig. 40 – Sub-bacia 09 – El Río Negro	130
Fig. 41 – Região da Planície de Inundação do rio Paraguai.....	131

Lista de Tabelas

Tab. 1 - Selected hydrometric stations	46
Tab. 2 - Sample separation	50
Tab. 3- Descriptive statistics of quantitative variables used in the ANN models	53
Tab. 4 - Descriptive statistics and linear correlations between SSC and Turbidity for each station	54
Tab. 5 - Statistical performance of ANN models	56
Tab. 6 - characteristics of the selected hydropower facilities	66
Tab. 7 - Quantitative performances in the verification sample, and resulting fuzzy sets of the FIS models.....	76
Tab. 8 - Qualitative performance of FIS 03	79
Tab. 9 - The best 6 FIS rules for each fuzzy output set – FIS 03. Input features: (a) Watershed area; (b) Reservoir area; (c) Reservoir volume; (d) Detention time; (e) Inflow; (f) Forest; (g) Grassland; (h) Pasture; (i) Agriculture; (j) Sandy soil; (k) Silty soil; (l) Clayey soil; (m) EWMA of past rainfall; (n) Upstream SSC	85
Tab. 10 - Similarity analysis. Input features: (a) Watershed area; (b) Reservoir area; (c) Reservoir volume; (d) Detention time; (e) Inflow; (f) Forest; (g) Grassland; (h) Pasture; (i) Agriculture; (j) Sandy soil; (k) Silty soil; (l) Clayey soil; (m) EWMA of past rainfall; (n) Upstream SSC	87
Tab. 11 - Performance statistics of the 5 ANN models.....	103
Tab. 12 – Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 01 – Paraguai Superior	119
Tab. 13 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 02	122
Tab. 14 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 03	123
Tab. 15 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 04	125
Tab. 16 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 05	126
Tab. 17 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 06	127
Tab. 18 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 07	128
Tab. 19 - Disponibilidade de estações <i>in situ</i> com dados de turbidez e CSS na sub-bacia 10	132

Sumário

1. Introdução	15
1.1. Motivação da pesquisa	15
1.2. Objetivo da pesquisa	19
1.3. Organização da Tese	20
2. Fundamentação teórica	22
2.1. Região hidrográfica do Paraguai/ Pantanal	22
2.1.1. Clima e Hidrologia	22
2.1.2. Altitude	24
2.1.3. Uso e cobertura da terra	25
2.1.5. Tipos de solos	27
2.1.6. Disponibilidade de dados hidrométricos e pluviométricos	28
2.1.7. Usos da água	29
2.2. Complexidade espaço-temporal dos processos de produção, transporte e deposição de sedimentos	30
2.2.1. Estudos hidrossedimentológicos na bacia do Alto Paraguai	31
2.3. Aprendizado de Máquinas	33
2.3.1. Redes Neurais Artificiais	34
2.3.2. Sistemas Especialistas Fuzzy	35
2.3.3. Estudo do transporte de sedimentos com modelos baseados em inteligência artificial – revisão de literatura	36
2.4. Sensoriamento Remoto na hidrossedimentologia	38
3. ARTIGO 1 - Estimation of suspended sediment concentrations in ungauged heterogeneous basins with scarce in situ data by using a regional ANN-based model	41
3.1. Introduction	42
3.2. Study area and data	44
3.2.1. Pantanal wetland	44
3.2.2. Data	46
3.3. Model development	48
3.3.1. Input and output model variables	48
3.3.2. ANN models	49
3.3.3. Model performance statistics	50
3.4. Results and discussion	51
3.4.1. Data analysis	51
3.4.2. ANN models for estimation of SSC in the UPRB	55
3.5. Conclusions	58
4. ARTIGO 2 - Modelling and Assessing How Small Hydropower Facilities Affect Sediment Transport by Using Fuzzy Inference Systems	60
4.1. Introduction	61
4.2. Materials and methods	63
4.2.1. Study area and hydroelectric facilities	63
4.2.2. Data sources	65
4.2.3. Modelling and data mining	68
4.3. Results and discussions	75

4.3.1. Quantitative performance	75
4.3.2. Fuzzy sets and qualitative performance	77
4.3.3. Feature importance analysis	79
4.3.4. Frequency analysis	80
4.3.5. Rule ranking	84
4.3.6. Similarity analysis	86
4.4. Implications and recommendations for the Pantanal wetland	89
4.5. Conclusion	90
5. ARTIGO 3 – Mapping suspended sediment dynamics in the Pantanal wetland using artificial neural networks and remote sensing	91
Abstract	91
5.1. Introduction	92
5.2. Pantanal – study area	94
5.3. Data and Methods	97
5.3.1. <i>In situ</i> data	98
5.3.2. Acquisition and processing of satellite imagery	99
5.3.3. ANN model development	101
5.4. Results and Discussions	103
5.4.1. Performance of the ANN models	103
5.4.2. Spatio-temporal dynamics of SSC in the Pantanal	105
5.5. Conclusions	112
6. RIOS DO SISTEMA RIO-PLANÍCIE DO PANTANAL: DISPONIBILIDADE DE DADOS IN SITU, PRESENÇA DE PCHs NAS CABECEIRAS E DINÂMICA ESPAÇO-TEMPORAL DE SEDIMENTOS	114
6.1. Introdução	114
6.2. Materiais e Métodos	115
6.2.1. Área de Estudo	116
6.2.2. Avaliação quanto à escassez de dados <i>in situ</i> de turbidez e de sedimentos em suspensão	116
6.2.3. Avaliação quanto à presença e prospecção de PCHs e à interferência no transporte de sedimentos	117
6.2.4. Avaliação da dinâmica espaço-temporal de sedimentos suspensos no rio principal	118
6.3. Resultados	118
6.3.1. Sub-bacia do rio Paraguai superior	118
6.3.2. Sub-bacia do rio Cuiabá	120
6.4. Discussões	133
6.5. Conclusões	136
7. Conclusões Gerais	138
Referências	141
APÊNDICE 1	151
APÊNDICE 2	152
APÊNDICE 3	153

1. Introdução

1.1. Motivação da pesquisa

A bacia do Alto Paraguai (BAP) abrange uma área de mais de 600.000 km² (Fig. 1), ocupando parte do território brasileiro, bem como parte dos territórios do Paraguai e da Bolívia. A parcela brasileira dessa bacia hidrográfica representa cerca de 61% de sua área total e corresponde a uma das 12 regiões hidrográficas brasileiras, denominada Região Hidrográfica do Paraguai (RH-Paraguai).

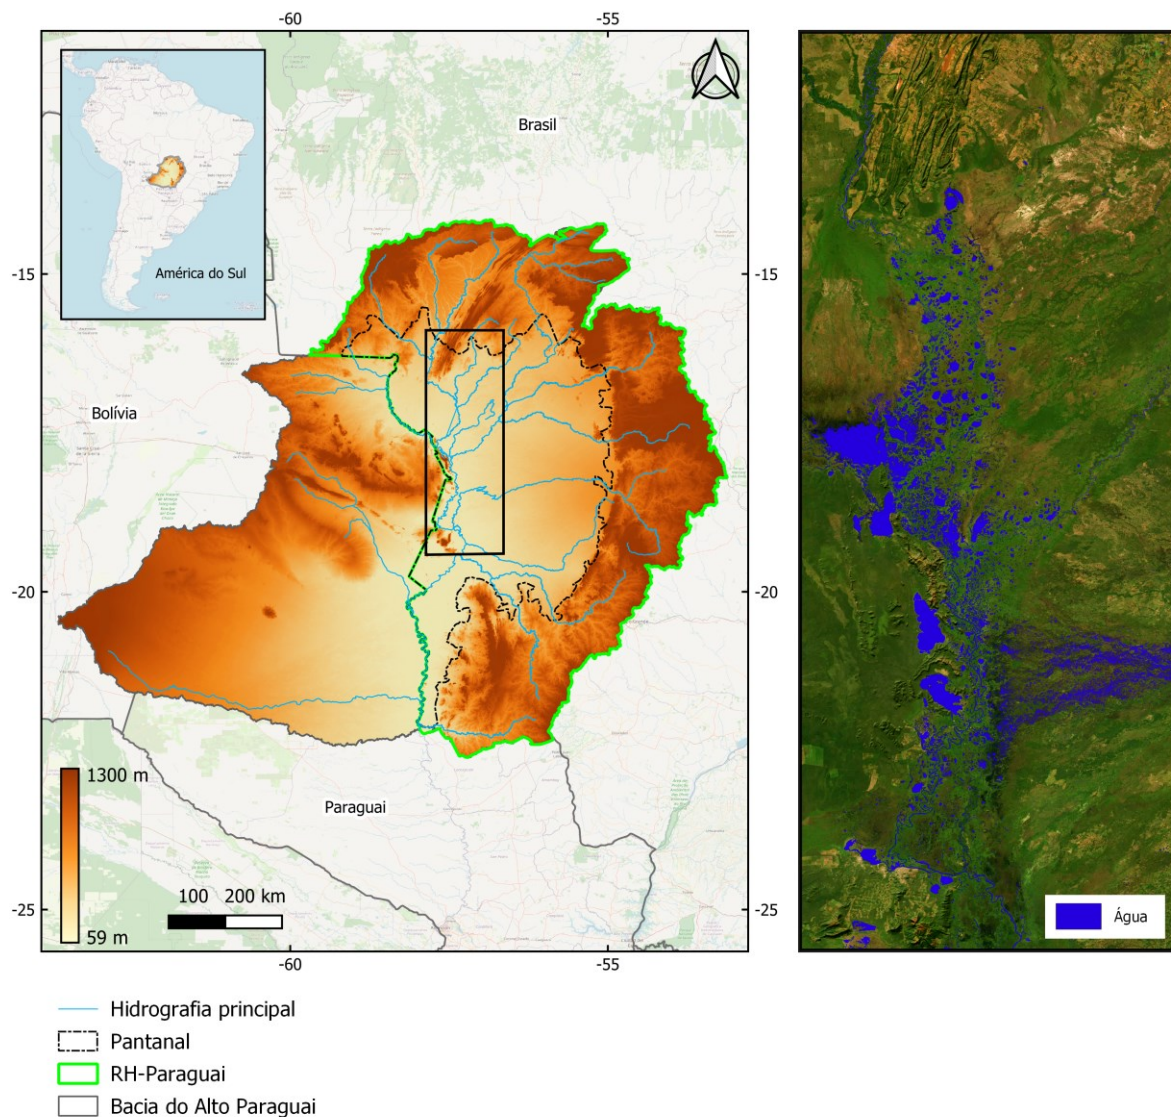


Fig. 1 – Região de estudo da Tese

A BAP apresenta importância ambiental singular por incluir uma das maiores extensões de áreas alagadas do planeta: o Pantanal, declarado Patrimônio Nacional pela Constituição

Brasileira de 1988, área de relevante importância internacional designada pela Convenção de Áreas Úmidas RAMSAR, em 1993, e Reserva da Biosfera pela UNESCO, em 2000. As extensas áreas úmidas do Pantanal, associadas a um regime hidrológico de grande sazonalidade, favorecem a ocorrência de grande biodiversidade de plantas, peixes, aves, anfíbios, répteis e mamíferos, e desempenham serviços ecossistêmicos essenciais, como armazenamento de carbono, reprodução de peixes e recarga de aquíferos (Alho, 2008).

O ponto crucial para o desenvolvimento do bioma do Pantanal é a relação entre o planalto e a planície. Grande parte da produção hídrica que mantém o pulso de inundação da planície pantaneira é originada nas regiões do planalto. Da mesma forma, os sedimentos que se depositam na planície do Pantanal devido ao relevo extremamente plano e às baixas velocidades das águas também são originados principalmente no planalto (ANA, 2018). Devido a essa grande interdependência entre o planalto e a planície, quaisquer alterações nas áreas de planalto, sejam elas causadas por atividades antrópicas ou por mudanças climáticas, podem causar impactos importantes na região do Pantanal.

A BAP possui uma grande heterogeneidade em termos de relevo, tipos de solo, cobertura vegetal e usos da terra. Essa heterogeneidade fisiográfica, bem como o regime hidrológico sazonal, resultam em rios com águas que vão desde transparentes a turvas, em diferentes regiões, caracterizando uma dinâmica hidrossedimentológica bastante complexa e ainda pouco compreendida. Embora existam estudos envolvendo sedimentos nessa região, as pesquisas em grande escala são, em geral, focadas na quantificação de processos erosivos (Bergier, 2013; Colman et al., 2019; Roque et al., 2021), e as pesquisas relacionadas ao transporte de sedimentos são focadas em determinadas partes da bacia, tais como a bacia do rio Miranda (Farias et al., 2018), a bacia do rio São Lourenço (Mingoti et al., 2019), bacia do rio Cuiabá (Campos, 2019) e a bacia do rio Taquari (Wosiacki et al., 2021). Neste sentido, existe uma lacuna importante em relação à caracterização da dinâmica espacial e temporal de sedimentos em suspensão ao longo da bacia do Alto Paraguai como um todo, e dos fatores predeterminantes dessa variabilidade nos rios.

Outra questão de grande interesse ambiental e socioeconômico na BAP é o grande aumento do número de pequenos empreendimentos hidrelétricos nos rios tributários do Pantanal, localizados no planalto. Até o momento desta pesquisa (setembro de 2023), foram identificados 55 empreendimentos em operação (sendo 7 UHEs, 16 CGHs e 32 PCHs), e mais outros 72 novos aproveitamentos hidrelétricos (grande maioria PCHs) em estágio de construção, planejados, propostos ou identificados pelo governo como locais potenciais (SIGA/ANEEL, 2023). Em geral, os efeitos de grandes barramentos no transporte de

sedimentos são bastante conhecidos e documentados na literatura (Erskine, 1985; Dai e Liu, 2013; Wang et al., 2018; Wei et al., 2021). No entanto, os efeitos causados por barragens menores ainda são pouco estudados, principalmente os efeitos cumulativos ao longo de um rio ou os efeitos de diversas barragens pequenas em uma região hidrográfica (Fantin-Cruz et al., 2020; Oliveira et al., 2020; Casserly et al., 2021; Magilligan et al., 2021).

Apesar de poucos estudos terem investigado os efeitos de barragens menores no transporte de sedimentos, os estudos disponíveis indicam que estes efeitos variam amplamente, desde alterações substanciais (Orr et al., 2006; Baker et al., 2011; Fantin-Cruz et al., 2020; Casserly et al., 2021), até alterações mínimas ou não existentes entre montante e jusante dessas estruturas (Lindloff, 2003; Ashley et al., 2006; Csiki e Rhoads, 2014). Essa variabilidade ainda é pouco compreendida e depende do grau de variabilidade hidrológica do rio em que a barragem está localizada, das características da bacia hidrográfica, da entrada de sedimentos na barragem, das características da barragem e da capacidade da hidráulica do rio em transportar sedimentos pela barragem (Csiki e Rhoads, 2010). Frente ao crescente aumento do número de empreendimentos menores ao redor do mundo, principalmente em regiões tropicais (Couto e Olden, 2018), a compreensão da variabilidade desses efeitos é importante para fundamentar o desenvolvimento de diretrizes relacionadas a implantação de futuros aproveitamentos hidrelétricos.

Apesar da grande importância ambiental da BAP, a caracterização de impactos, assim como o desenvolvimento de estudos relacionados ao transporte de sedimentos são prejudicados pela escassez de dados *in situ*. O monitoramento do transporte de sedimentos na BAP é ainda bastante limitado, sendo realizado por meio de 44 estações hidrométricas do sistema nacional de recursos hídrico (aproximadamente uma estação para cada 8.000 km²) e com frequência temporal extremamente baixa (menos de 2 coletas por ano) (Campos, 2019).

O movimento de sedimentos da bacia hidrográfica para os rios constitui um ciclo contínuo de erosão, transporte e deposição. A quantidade de sedimentos em suspensão que entram e saem dos rios é influenciada por uma complexa interação de vários fatores operando em diferentes escalas de tempo e espaço, tornando-o um processo altamente não linear e desafiador de se modelar (Bracken et al., 2015).

Para enfrentar essa dificuldade, assim como outras aplicações relacionadas a fenômenos altamente não lineares e complexos, como aqueles relacionados aos sedimentos, têm-se utilizado modelos baseados em inteligência artificial (IA). Entre esses modelos, destacam-se as redes neurais artificiais (RNAs) e os sistemas de inferência fuzzy (SIF). Estes modelos são muito úteis no estudo de fenômenos ambientais sem física explícita, pois são capazes de simular

o fenômeno estudado a partir de outros dados relacionados, produzindo resultados satisfatórios desde que treinados adequadamente. Além disso, alguns desses modelos também podem ser utilizados para o descobrimento de conhecimentos ou identificação de padrões junto aos dados por meio de técnicas de “mineração” de dados. De fato, diversos modelos baseados em IA vêm sendo amplamente utilizados na modelagem de sedimentos (Jain, 2001; Aytok e Kişi, 2008; Kisi et al., 2012, 2012; Lafdani et al., 2013; Afan et al., 2014; Atieh et al., 2015; Sirabahenda et al., 2017; Buyukyildiz e Kumcu, 2017; Sari et al., 2017; Shoaib et al., 2018; Yadav et al., 2018; Kumar et al., 2019; Teixeira et al., 2020), no entanto, a dificuldade em se monitorar continuamente os sedimentos em suspensão impõem grandes desafios no estudo dos processos hidrossedimentológicos envolvendo modelagens baseadas em dados.

Essa baixa disponibilidade de dados *in situ* de sedimentos em suspensão nos rios vem sendo contornada a partir da complementação destes com dados de sensoriamento remoto. Atualmente, é possível se obter diversas estimativas de dados hidrológicos como chuva, evapotranspiração, sedimentos suspensos, clorofila, turbidez, temperatura da água, entre outros, a partir de sensores a bordo de satélites, ou outros dispositivos, como drones. A resolução temporal e a cobertura espacial, bem como a precisão da medição, estão melhorando continuamente devido aos avanços constantes na tecnologia de sensores e novos métodos para mesclar várias fontes de dados (Gebremicael et al., 2017). Além disso, por meio do sensoriamento remoto também podem ser obtidos dados de elevação do terreno, monitoramento do uso e cobertura da terra, que compõem características essenciais nos estudos hidrossedimentológicos.

A associação entre dados de sensoriamento remoto e modelos de IA vem apresentando resultados satisfatórios (Sharaf El Din et al., 2017; Mollae et al., 2018; Kwon et al., 2020), e são uma alternativa para o estudo de fenômenos ambientais complexos sem física explícita, principalmente em regiões com baixa disponibilidade de dados *in situ*, como é o caso da BAP.

Neste sentido, esta pesquisa é direcionada ao desenvolvimento de técnicas baseadas em modelos de inteligência artificial e dados de sensoriamento remoto para caracterizar a dinâmica espacial e temporal dos sedimentos em suspensão ao longo da região como um todo, considerando a escassez de dados hidrossedimentológicos, e realizar a identificação dos efeitos sobre o transporte de sedimentos causados pelos empreendimentos hidrelétricos atuais e previstos para o futuro.

1.2. Objetivo da pesquisa

O objetivo desta pesquisa é desenvolver técnicas originais baseadas em aprendizado de máquinas e sensoriamento remoto para avaliar, compreender e caracterizar a dinâmica espaço-temporal de sedimentos suspensos na bacia hidrográfica do Alto Paraguai.

Para tanto, enumeramos os seguintes objetivos específicos, que são abordados nos artigos científicos desta Tese:

1. Estimar CSS a partir de outros dados relacionados oriundos de sensoriamento remoto, utilizando RNAs;
2. Identificar como os empreendimentos hidrelétricos localizados nas cabeceiras dos rios formadores do Pantanal interferem no transporte de sedimentos para a planície;
3. Experimentar SIFs para investigar como diferentes características das bacias hidrográficas e das barragens, bem como variações hidrológicas, afetam as respostas sedimentológicas de empreendimentos hidrelétricos;
4. Desenvolver um mapeamento das CSS na bacia do Alto Paraguai, utilizando a plataforma GEE e imagens dos satélites Landsat-8/9 e Sentinel-2, e modelos de RNAs;
5. Identificar como a sazonalidade hidrológica afeta a dinâmica de sedimentos suspensos nos rios do Pantanal.

O primeiro objetivo específico partiu da necessidade de se ampliar a quantidade de dados *in situ* de CSS disponíveis ao longo da BAP. Neste sentido, um modelo regional baseado em RNAs foi desenvolvido com o intuito de estimar CSS em locais sem dados desta variável, mas com disponibilidade de outros dados mais fáceis de serem obtidos, como, por exemplo, dados de turbidez, vazão e dados obtidos via sensoriamento remoto.

O segundo e terceiro objetivos específicos referem-se às implicações que os empreendimentos hidrelétricos existentes nas cabeceiras da BAP podem representar no transporte de sedimentos para o Pantanal. Neste sentido, os Sistemas Especialistas Fuzzy foram empregados para se investigar como as diferentes características das bacias hidrográficas e das barragens, bem como as variações hidrológicas afetam a forma como os empreendimentos interrompem a conectividade natural do rio e interferem no transporte de sedimentos para jusante. As regras geradas pelos SIFs foram aproveitadas para obter interpretações acerca das alterações das barragens e suas influências na dinâmica hidrossedimentológica da BAP.

O penúltimo e último objetivos específicos referem-se ao mapeamento espaço-temporal da CSS por meio de RNAs e imagens multiespectrais de satélite desenvolvido. Essa etapa leva ao objetivo geral da Tese, e faz uso dos dados de CSS *in situ* existentes ao longo da BAP e dos dados de CSS calculados por meio do modelo regional desenvolvido previamente.

Desta forma, a presente pesquisa proporciona uma caracterização abrangente da dinâmica espaço-temporal dos sedimentos ao longo da BAP, superando as limitações relacionadas à escassez de dados *in situ*, observando os efeitos dos empreendimentos hidrelétricos nas áreas de planalto, e proporcionando aplicações originais envolvendo sensoriamento remoto e aprendizado de máquinas no âmbito da hidrossedimentologia.

1.3. Organização da Tese

A presente Tese de doutorado foi desenvolvida em formato de artigos, cuja organização e subdivisão dos assuntos são apresentadas na Fig. 2. No total, são apresentados 7 capítulos. Este primeiro capítulo é destinado à apresentação das motivações e dos objetivos desta pesquisa, bem como da descrição da estrutura do documento. O segundo capítulo é destinado às fundamentações teóricas relacionadas a assuntos de interesse desta pesquisa.

Os quatro capítulos seguintes são em formato de artigos científicos, conforme apresentado na Fig. 2, e descritos a seguir:

- Capítulo 3 - Artigo 1 (Publicado na revista Hydrological Sciences Journal - 2021): *Estimation of suspended sediment concentrations in ungauged heterogeneous basins with scarce in situ data by using regional ANN-based models;*
- Capítulo 4 – Artigo 2 (Publicado na revista Journal of Hydrology - 2023): *Modelling and Assessing how small hydropower facilities affect sediment transport by using fuzzy inference systems;*
- Capítulo 5 – Artigo 3 (Submetido na revista Remote Sensing of Environment - 2024): *Mapping spatio-temporal dynamics of suspended sediments in the Pantanal using ANN-based models and Remote sensing;*
- Capítulo 6 – Artigo 4 (Manuscrito): Rios da bacia do Alto Paraguai: Disponibilidade de dados *in situ*, presença de PCHs e dinâmica espaço-temporal de sedimentos

Finalmente, o capítulo 7 destina-se à apresentação das conclusões e observações da Tese.

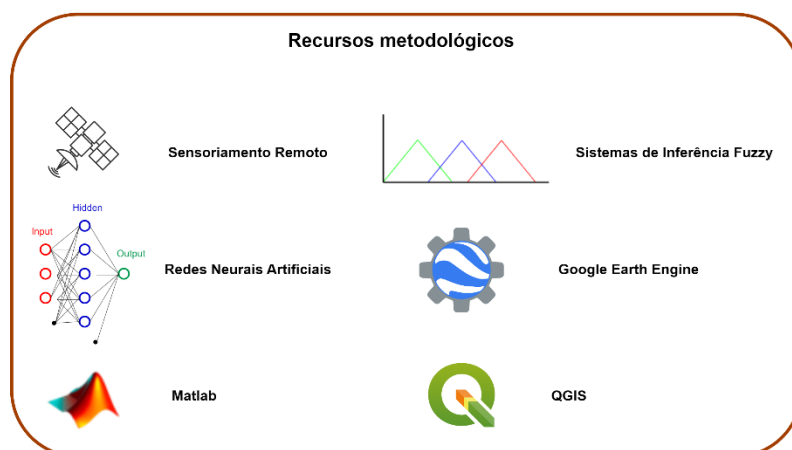
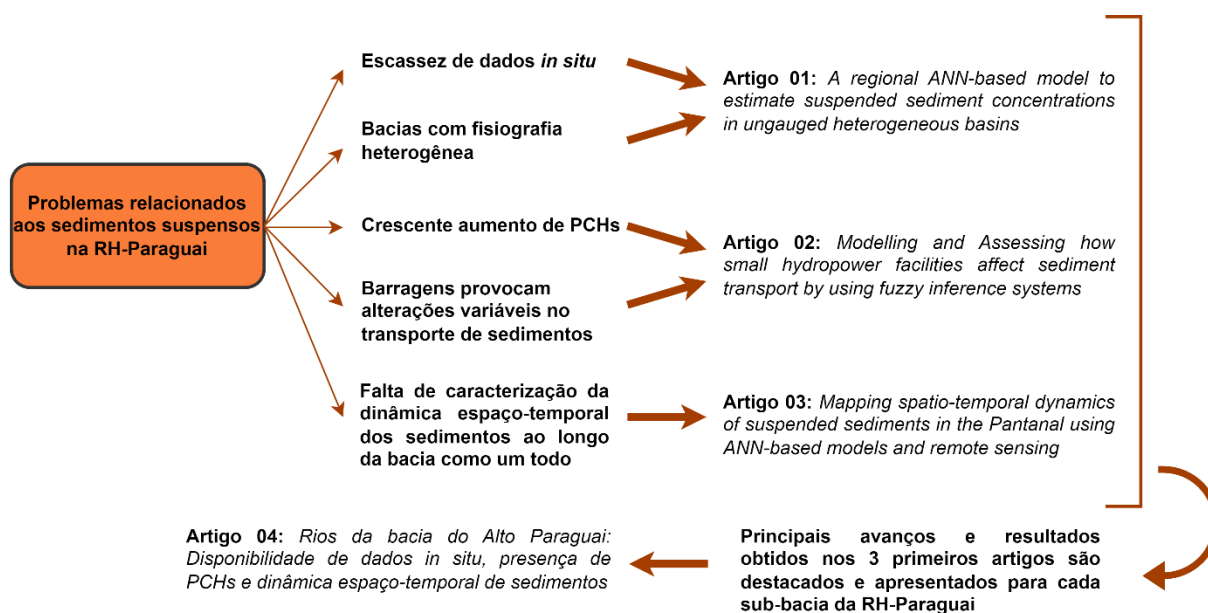


Fig. 2 - Estrutura geral da Tese – formato de artigos

A estrutura de artigos foi pensada de forma que os 3 primeiros artigos da Tese estejam focados no desenvolvimento de métodos originais envolvendo aprendizado de máquinas e dados de sensoriamento remoto, utilizando a BAP como objeto de estudo. O primeiro artigo está relacionado ao objetivo específico 1; o segundo artigo refere-se aos objetivos específicos 2 e 3; O terceiro artigo refere-se aos objetivos específicos 4 e 5; Já o quarto e último artigo é voltado para a apresentação dos resultados obtidos nos 3 primeiros artigos para cada uma das sub-bacias que drenam para o Pantanal, de forma a destacar e discutir os métodos desenvolvidos de maneira regionalizada e compartimentada ao longo da bacia do Alto Paraguai.

2. Fundamentação teórica

Este capítulo é destinado a uma caracterização da área de estudo da Tese, em termos de clima, hidrologia, altimetria, uso e cobertura da terra, tipos de solos, disponibilidade de dados e usos da água.

Além disso, é oferecida uma breve revisão sobre: i) a complexidade espaço-temporal dos fenômenos hidrossedimentológicos; ii) a utilização de técnicas de modelagens com aprendizado de máquinas no âmbito dos sedimentos, incluindo as RNAs e SIFs; e iii) uma revisão sobre sensoriamento remoto na hidrossedimentologia.

2.1. Região hidrográfica do Paraguai/ Pantanal

2.1.1. Clima e Hidrologia

Conforme a classificação climática de Köppen-Geiger, o clima predominante na bacia do Alto Paraguai é do tipo “Aw” - clima tropical úmido e seco, ou clima tropical de savana. Esse clima possui duas estações bem definidas, sendo uma chuvosa, de outubro a março, e outra seca que se estende até setembro. A temperatura média é de 20°C em julho e 27° C em dezembro (Marengo et al., 2015).

A precipitação não é uniforme em toda a BAP (Fig. 3), com médias anuais variando entre 800 e 2.000 mm. A distribuição das chuvas recebe influência direta das diferenças de relevo. Assim, na região da planície pantaneira, os totais anuais de precipitação ficam em faixas inferiores, de 800 a 1.200 mm, enquanto nas áreas de maior altitude, na região do planalto, são observados os valores mais elevados de precipitação (ANA, 2018).

O regime de chuvas é bem definido na região, com um período chuvoso de outubro a abril e um período seco que se estende até setembro. A maior parte das chuvas ocorre entre outubro e abril, onde chove praticamente 70% da chuva anual. Em contrapartida, o inverno é extremamente seco, chovendo em média menos de 25 mm no mês mais seco (Campos, 2019).

A distribuição de chuvas não uniforme na BAP, associada às características pedológicas e de uso e ocupação do solo na bacia, caracterizam a região de planalto como grande produtora de água e de sedimentos, sendo estes transportados em direção à planície pantaneira. É na planície, por sua vez, onde se registra a taxa mais baixa de produção hídrica e de material sólido, e a maior tendência de deposição dos sedimentos produzidos nas partes altas da bacia, em função da baixa velocidade do escoamento (ANA, 2018).

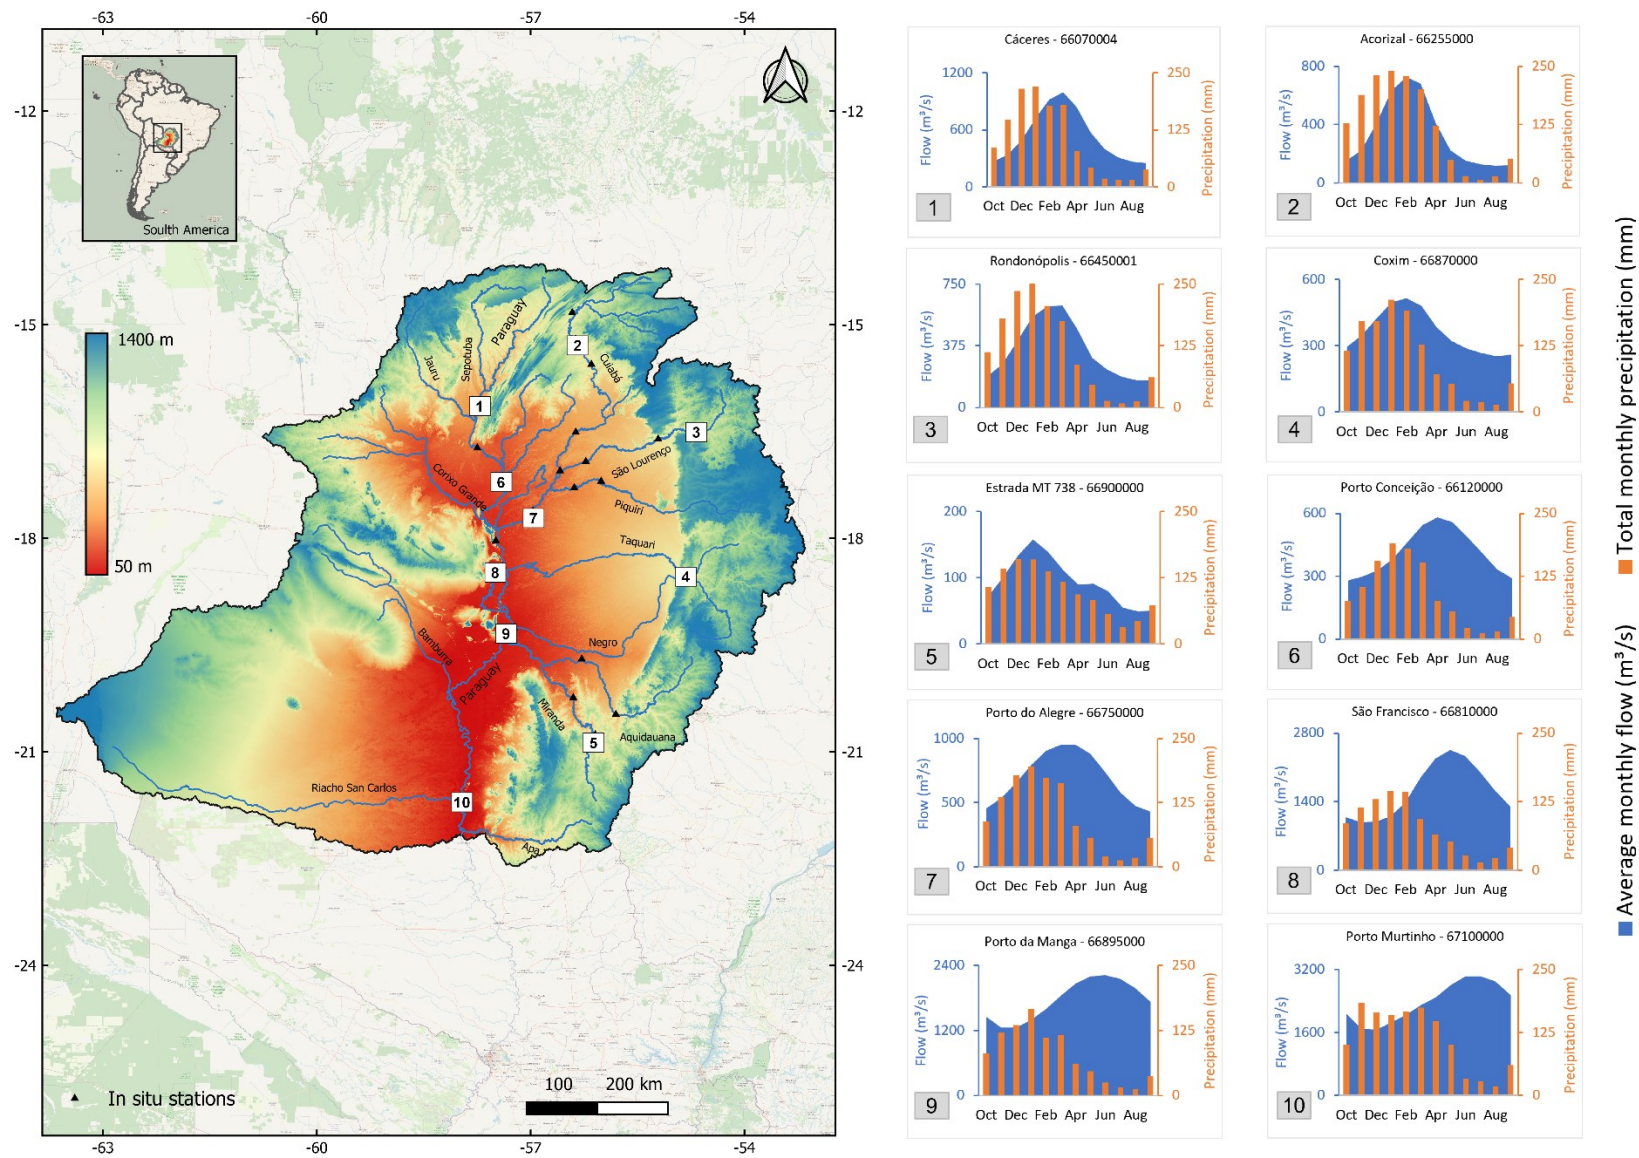


Fig. 3 - Comportamento das chuvas e das vazões ao longo da bacia do Alto Paraguai

O rio Paraguai é um dos principais rios de planície de inundação do Brasil e o principal contribuinte de água para a planície do Pantanal. Seus principais afluentes na margem direita são os rios Cabaçal, Jauru, Sepotuba e Corixó Grande, e na margem esquerda estão os rios Cuiabá, São Lourenço, Correntes, Taquari, Negro, Aquidauana, Miranda e Apa. Tanto o rio Paraguai quanto seus afluentes descem das terras altas, transportando água principalmente das partes altas do norte e leste da BAP e, ao alcançarem o Pantanal, encontram um terreno extremamente plano. O canal principal dos rios apresenta profundidades menores (margens mais baixas) e pequenas declividades à medida que avançam sobre o Pantanal, resultando em baixas velocidades de fluxo. Durante os períodos de inundação, os canais são incapazes de conduzir a água excedente, e extensas áreas da planície ficam inundadas, cobrindo áreas que podem variar de 10.000 a 110.000 km² todos os anos (Hamilton et al., 1996).

Nas estações *in situ* do planalto (estações 2, 3, 4 e 5), o pico do período chuvoso é o mesmo do pico das vazões máximas (janeiro-fevereiro). Nas estações da planície (estações 1, 6, 7, 8, 9 e 10), há um atraso perceptível entre o pico de chuvas (janeiro) e o pico das vazões. Em estações como Porto Conceição (6), Porto do Alegre (7), São Francisco (8), Porto da Manga (9) e Porto Murtinho (10), o pico das inundações pode variar entre 3 a 5 meses após o pico da estação chuvosa. Isso demonstra a resposta hidrológica extremamente lenta da planície de inundação do Pantanal às chuvas.

2.1.2. Altitude

A BAP caracteriza-se por uma clara macrocompartimentação física em duas áreas: o planalto e a planície pantaneira. O planalto representa 59% da área da RH, com terras acima de 200 m de altitude que podem atingir até 1.300 m. A planície representa 41% da área da BAP, com terras baixas e úmidas e altitudes variando entre 59 e 200 m, onde está inserido o Pantanal. Deste modo, a curva de nível de 200 m de altitude corresponde, aproximadamente, aos limites entre a planície do Pantanal e o planalto (Macedo, 2017). As partes altas da bacia podem chegar a 1300 m de altitude (Fig. 4).

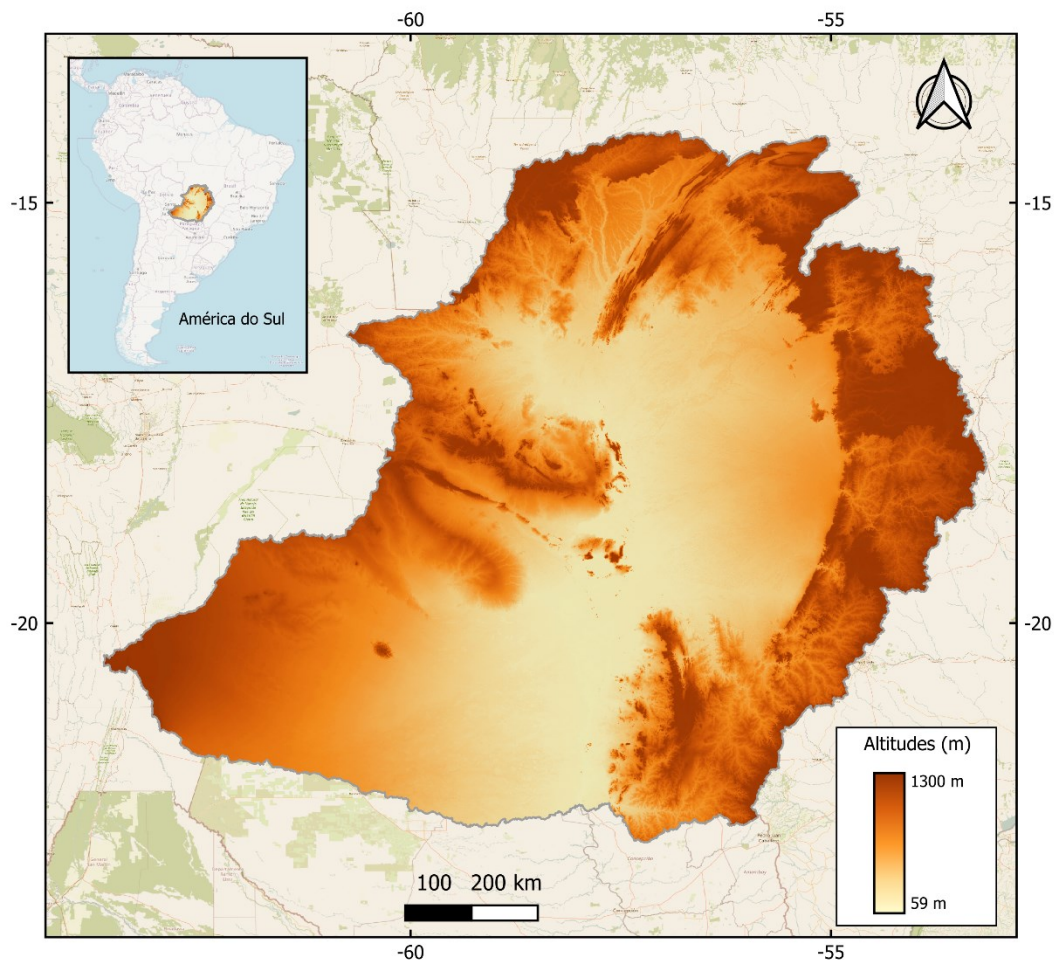


Fig. 4 - Altimetria da bacia do Alto Paraguai

2.1.3. Uso e cobertura da terra

O uso e cobertura da terra na BAP (Fig. 5) foi caracterizado a partir de um mapa dinâmico de cobertura terrestre (nome do produto: *The WorldCover 2020 Map V100*), produzido e disponibilizado pela *The Copernicus Global Land Service (CGLS)*. Este produto fornece um mapa global dinâmico de cobertura terrestre, com resolução espacial de 100 metros.

As principais classes de uso e cobertura da terra observadas na parcela brasileira da BAP são o Campo e a Agricultura. A agricultura ocupa cerca de 7% da área total da BAP, sendo praticada majoritariamente no planalto; no Pantanal, tem pouca expressão como atividade econômica, devido ao alagamento sazonal das planícies e dos solos pobres das áreas que não alagam. Nas áreas de campo, a pecuária é fortemente praticada, mais especificamente a bovinocultura de corte, sendo desenvolvida tanto na região de planalto como na planície pantaneira, ocupando cerca de 31% da área total da bacia (ANA, 2018).

Na parcela boliviana da BAP, observa-se maior presença de classes de floresta densa, floresta não densa e savana. Ao longo do curso d'água do rio Paraguai, observa-se a presença da classe área úmida.

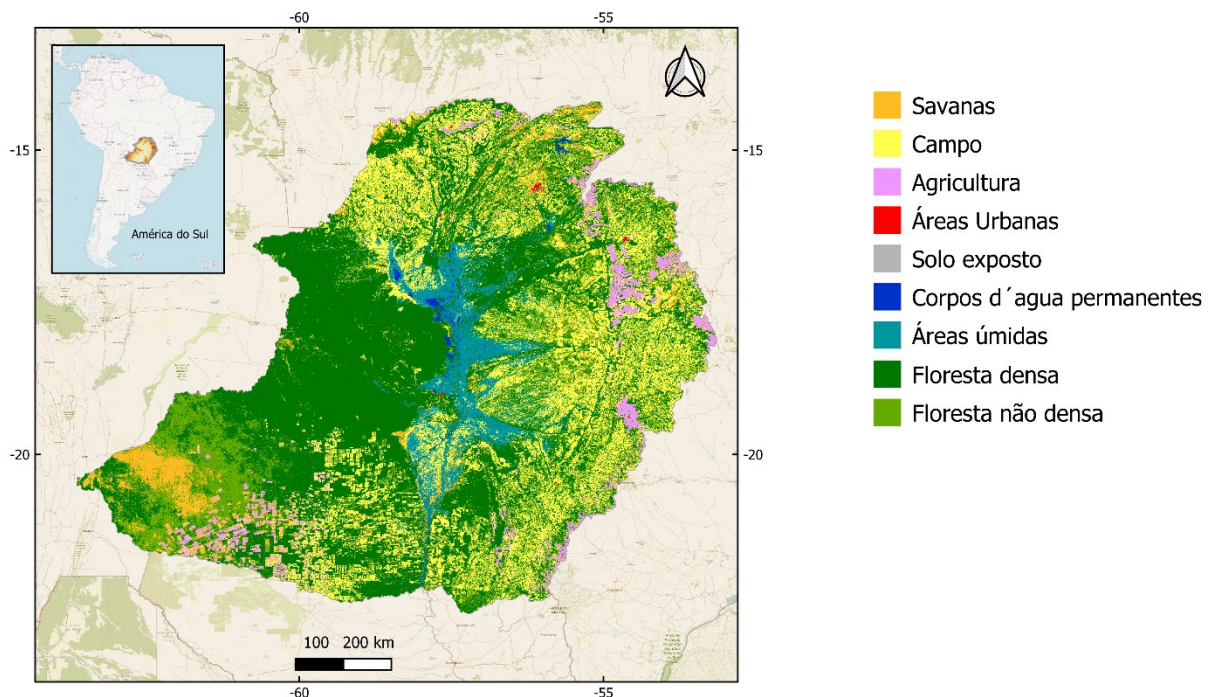


Fig. 5 - Uso e cobertura da terra na BAP

Diversas modificações antrópicas têm sido intensificadas no Planalto ao longo das últimas décadas, como por exemplo a extensa conversão de área vegetativa natural em área antrópica, principalmente devido a práticas de pecuária e agricultura. Diversos estudos têm apontado um aumento na produção de sedimentos nas bacias do planalto devido às mudanças no uso da terra (Bergier, 2013; Mingoti et al., 2019).

Em termos de bioma, a BAP é marcada pela presença de três biomas brasileiros: Amazônia, Cerrado e Pantanal. Em menores proporções, a região também possui formações denominadas Matas Secas Chiquitanas, ao norte (na divisa com a Bolívia), e formações vegetais de alcunha Chaco Paraguai, a sudoeste. Também ocorrem no centro-sul enclaves do bioma Mata Atlântica (ANA, 2018).

Em termos de extensão, o principal bioma é o Cerrado, que ocupa cerca de 50% da área da BAP. Na região noroeste da RH, também se verifica a presença do bioma Amazônia, ocupando cerca de 9% da área total. Na planície se encontra o Pantanal, segundo maior bioma na BAP, correspondente a cerca de 41% de sua área total. O Pantanal é a maior área úmida do mundo e ocupa, em território brasileiro, cerca de 138.000 km² (totalmente inseridos na BAP), estendendo-se ainda até a Bolívia por cerca de 15.000 km² e Paraguai por 5.000 km².

2.1.5. Tipos de solos

Com base no mapa de solos do Brasil (Santos et al., 2018), e no mapa mundial de solos da FAO (FAO/UNESCO, 1974), foi gerado um mapa de solos para a BAP, agrupando os solos da mesma classe (Fig. 6).

As classes de solo mais frequentes no planalto são os Argissolos, Neossolos e Latossolos. Essa região apresenta solos com grandes profundidades e forte drenagem, com cores que vão do avermelhado ao amarelado e mais raramente acastanhado ou acinzentado.

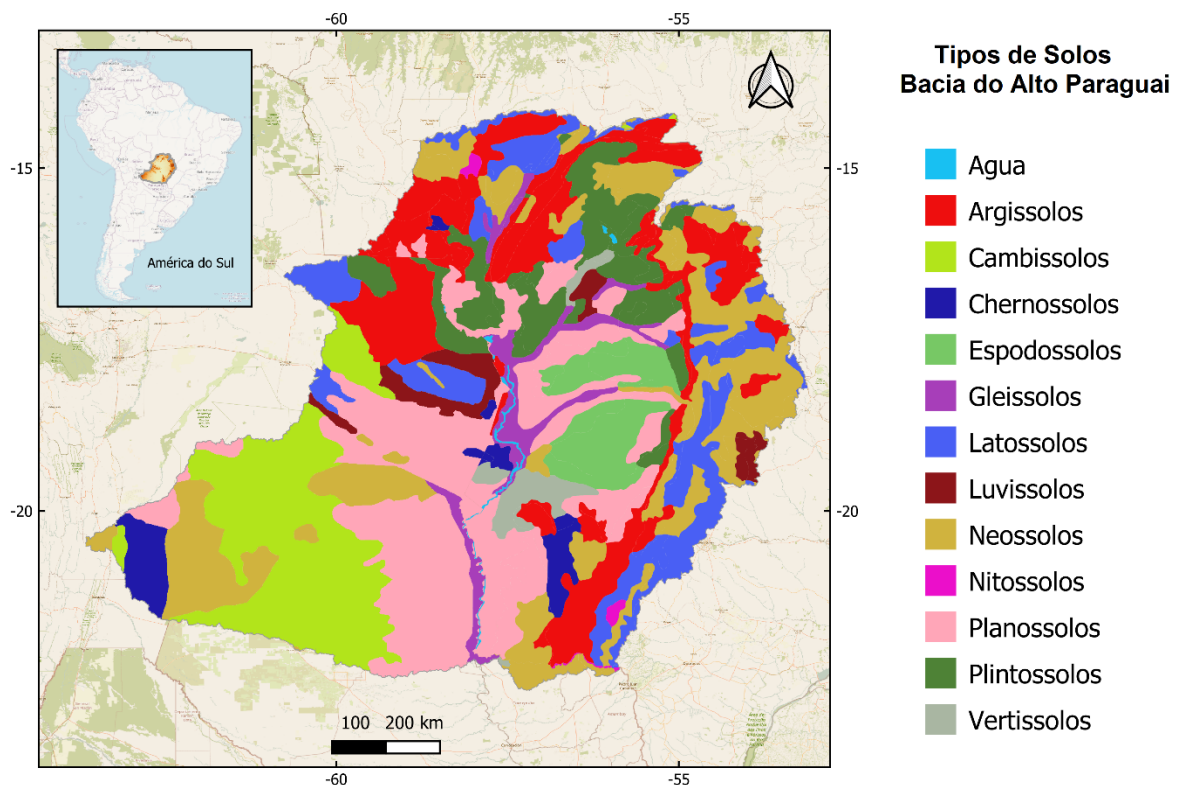


Fig. 6 - Tipos de solos da BAP

As classes de solo encontrados no Pantanal são, em quase sua totalidade, compostos por solos hidromórficos, condicionados pela fraca eficiência da drenagem gerando grande tendência a inundações periódicas e prolongadas. As principais classes são os Gleissolos, Espodossolos e Planossolos. Esses tipos de solo são periodicamente ou permanentemente saturados de água, sendo, portanto, muito diferentes dos solos da região do Planalto (Macedo, 2017).

2.1.6. Disponibilidade de dados hidrométricos e pluviométricos

Na Fig. 7 estão representadas as estações de monitoramento hidrológico, hidrossedimentológico e de qualidade da água na parcela brasileira da BAP, disponíveis no Sistema Nacional de Informações sobre Recursos Hídricos (SNIRH - <https://www.snirh.gov.br/>). Ao total, foram encontrados 226 estações pluviométricas, 169 estações fluviométricas, 196 estações com dados de qualidade da água e 81 pontos de monitoramento de sedimentos.

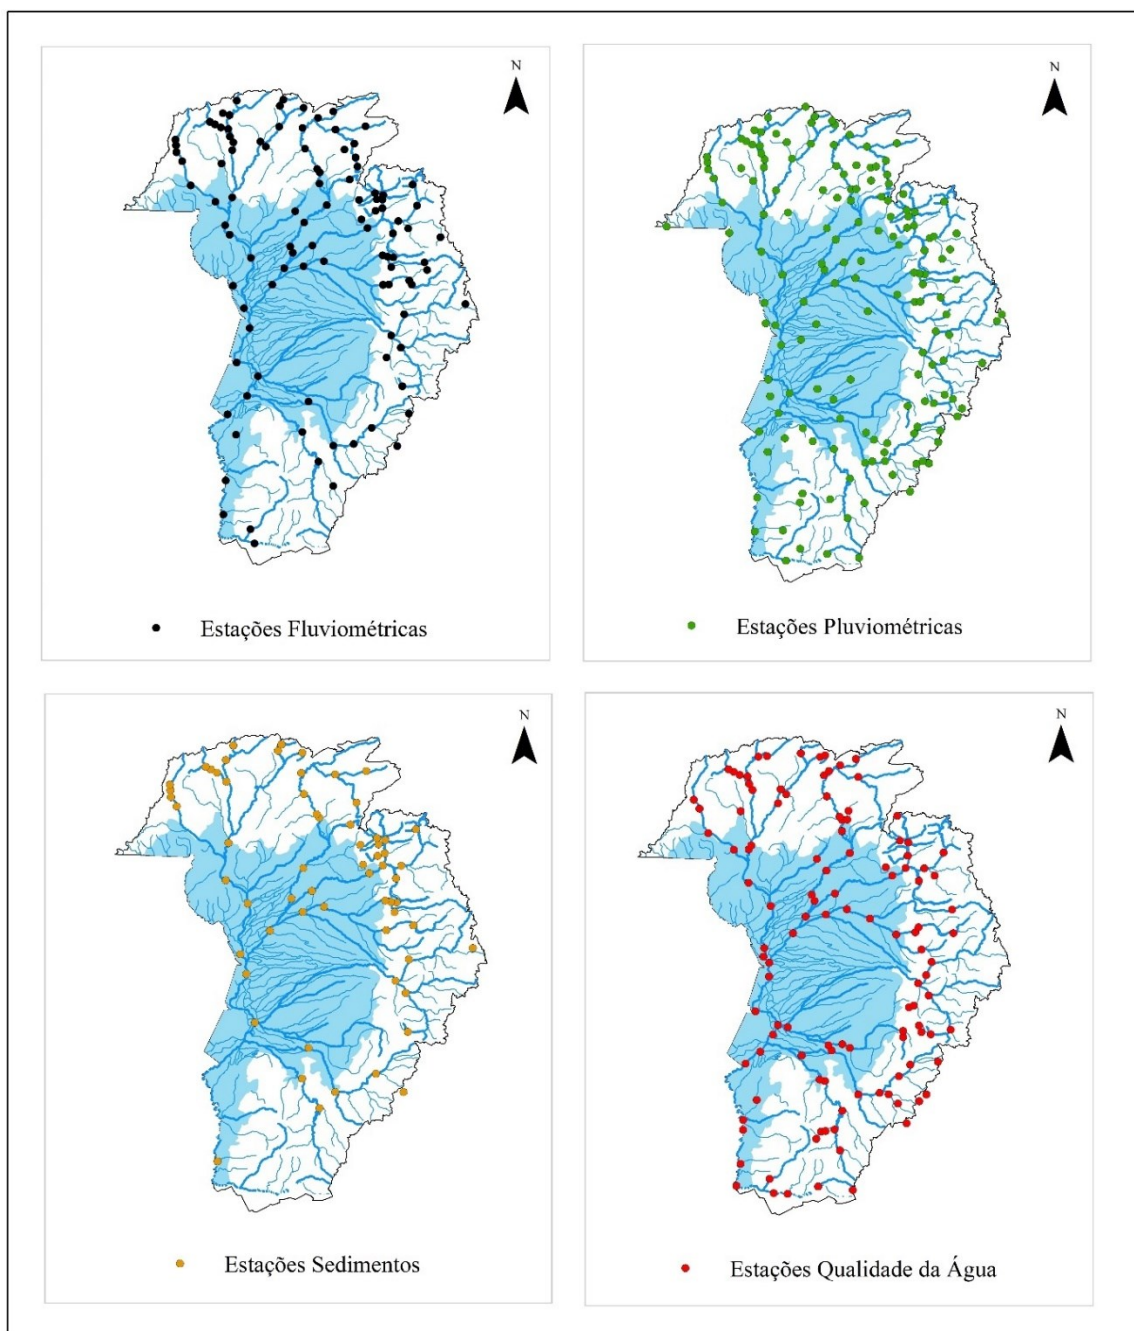


Fig. 7 – Rede de monitoramento hidrológico da bacia do Alto Paraguai

Ressalta-se que boa parte das estações fluviométricas e pluviométricas não possuem séries de dados contínuos, apresentando grandes períodos de falhas em alguns casos. Além disso, a escala temporal de coleta de dados de qualidade da água é quase sempre trimestral ou maior, e a coleta de sedimentos é em escala semestral ou anual. Muitas estações de monitoramento de sedimentos e de qualidade da água foram temporárias, para coletas de estudos específicos na BAP.

2.1.7. Usos da água

Cerca de 1,9 milhão de pessoas vivem na BAP, sendo que 84,7% delas vivem em áreas urbanas, concentradas nas cidades de Cuiabá (483 mil habitantes), Várzea Grande, (215 mil habitantes) e Rondonópolis (150 mil habitantes), principais centros populacionais de Mato Grosso. Nestas áreas, os usos da água predominantes são o abastecimento público e diluição de efluentes domésticos (ANA, 2018).

Para as áreas rurais, destacam-se também os usos principalmente para a dessedentação animal na pecuária, bem como na criação de aves e suínos, a irrigação da monocultura de grãos, que vem crescendo nos últimos anos, além da piscicultura, indústria e geração de energia.

O uso da água para a geração de energia elétrica na BAP também é expressivo e se encontra em expansão, com possibilidade de construção de novos aproveitamentos hidrelétricos. Em 2018 já existiam 53 empreendimentos (sendo 7 UHEs, 16 CGHs e 30 PCHs), e mais outros 127 novos aproveitamentos hidrelétricos (grande maioria PCHs) construção, planejados, propostos ou identificados pelo governo como locais potenciais, de acordo com o Plano de Recursos Hídricos da RH-Paraguai (ANA, 2018). A maioria desses empreendimentos são Pequenas Centrais Hidrelétricas (PCHs), caracterizadas por gerar até um limite de 30 MW.

Além disso, o hidroturismo é um uso da água importante, que tem como principal atrativo os cursos d'água na bacia onde há maior desnível com formação de corredeiras e cachoeiras, e nos corpos d'água do Pantanal, onde também é intenso o turismo de pesca (ANA, 2018).

Atualmente existe uma complexa conjuntura ambiental e socioeconômica na região devido aos conflitos entre as fortes demandas hídricas relacionadas à pecuária, agricultura, pesca, geração de energia elétrica, navegação, abastecimento humano, indústria, turismo, populações tradicionais (ribeirinhos, pescadores, indígenas e quilombolas), e à preservação do Pantanal, que é um ecossistema sensível e que tem sofrido diversos impactos ambientais negativos devido aos avanços nos usos da terra e nos usos hídricos que ocorrem nessa região.

2.2. Complexidade espaço-temporal dos processos de produção, transporte e deposição de sedimentos

O processo de transferência de sedimentos da bacia hidrográfica para o rio é um constante ciclo de erosão, transporte e deposição. A quantidade de sedimentos suspensos levados para e pelos rios depende da interação de múltiplos condutores agindo em diferentes escalas espaciais e temporais, sendo, portanto, um processo altamente não linear e difícil de ser modelado (Bracken et al., 2015).

A carga total de sedimentos nos rios geralmente consiste em sedimentos suspensos e carga de fundo. Esta pesquisa se concentra em sedimentos suspensos, que é a fração fina dos sedimentos (geralmente < 0.0063 mm – silte e argila), transportado dentro da coluna d'água de um rio. A parcela de sedimentos suspensos é dominante nas bacias hidrográficas e é responsável por aproximadamente 70% do aporte anual de sedimentos pelos rios nos oceanos (Morgan, 2005).

A erosão dos solos é uma das principais fontes de sedimentos suspensos nos rios. A erosão do solo ocorre em duas fases. Primeiro, as partículas individuais do solo ou pequenos agregados são desprendidas do solo como resultado de vários processos, tais como impacto da chuva, água corrente, atividade biológica, ciclo de congelamento-degelo, vento e outros processos que perturbam o solo; em seguida, as partículas e agregados destacados do solo são arrastados pelo vento ou pelo escoamento superficial, que os transporta para longe de seu ponto de origem. A erosão do solo é causada principalmente por: (i) erosividade do agente de erosão; (ii) a erodibilidade do solo (determinada pelas propriedades do solo); (iii) o comprimento do declive e a inclinação do terreno (ou seja, a topografia); e (iv) a natureza da cobertura da superfície, incluindo o uso e a cobertura da terra, e práticas de manejo (Morgan, 2005). Além da erosão dos solos, os sedimentos também podem ser originados de movimentos de massa, erosão das margens de rios e/ou atividades antrópicas (Fryirs, 2013).

A combinação de características geológicas, topográficas, climáticas e de cobertura do solo de uma bacia hidrográfica determina a distribuição espacial da erosão do solo e da transferência de sedimentos que regulam a concentração de SS em qualquer ponto particular do rio (Veracruz et al., 2017).

A carga de sedimentos de um rio é determinada principalmente pela disponibilidade de sedimentos na bacia hidrográfica e pela capacidade de transporte do agente erosivo. Além disso, a quantidade de sedimento que chega no canal do rio depende principalmente da conectividade da bacia. Finalmente, uma vez que o sedimento fino é entregue ao rio, ele será transportado a

jusante como carga em suspensão ou depositado localmente, principalmente dependendo do tamanho do grão das partículas de sedimento e da energia do fluxo do rio, ou seja, a capacidade do rio para transportar sedimentos finos (Morgan, 2005).

A variabilidade temporal no transporte de sedimentos suspensos em um determinado ponto do rio é determinada pela interação de vários fatores (Thompson et al., 2014; Grove et al., 2015), que podem ser classificados em quatro categorias principais: (i) fatores hidrometeorológicos (ii) variações da fonte de sedimentos; (iii) perturbações da paisagem natural; e (iv) intervenções humanas.

Neste sentido, é evidente que o transporte de sedimentos em rios é um fenômeno altamente não linear, no tempo e no espaço (Bracken et al., 2015). A natureza não linear da erosão do solo e do transporte de sedimentos na escala de bacia resulta em variações espaço-temporais na geração de sedimentos, transferência para o canal e transporte na rede fluvial. Um ponto a montante da bacia hidrográfica pode ser caracterizado por uma dinâmica de sedimentos totalmente diferente, em comparação com o exutório da bacia. Essas diferenças são ainda mais expressivas em bacias hidrográficas com taxas de erosão variáveis devido ao uso misto da terra (por exemplo urbanização, agricultura, pastagem e floresta), ou uma topografia e litologia heterogêneas (Zeiger e Hubbart, 2016). Além disso, um único ponto no rio é frequentemente caracterizado por uma mudança no regime de sedimentos ao longo do tempo.

2.2.1. Estudos hidrossedimentológicos na bacia do Alto Paraguai

Alguns estudos já proporcionaram importantes avanços relacionados aos aspectos hidrossedimentológicos na bacia do Alto Paraguai, e serão brevemente apresentados a seguir.

Colman et al., (2019) investigaram os efeitos da erosão do solo no Pantanal brasileiro sob perspectiva de mudanças climáticas e de mudanças no uso e cobertura do solo, combinando diferentes cenários de erosividade projetada das chuvas e gestão da cobertura do solo. A erosão média anual foi calculada para o ano de 2012, e a partir disso, foram elaborados diferentes cenários futuros para os anos 2020, 2035 e 2050. Para o pior cenário, os autores observaram um aumento na perda de solo de até 100% entre 2012 e 2050, associado à expansão das áreas agrícolas nas áreas de planalto. Além disso, para o mesmo período, os resultados indicaram um aumento de 20 a 40% na perda de solo em partes baixas da bacia, já no bioma do Pantanal, relacionado ao aumento de áreas de pecuária.

Roque et al., (2021) avaliaram o aumento na carga de pesticidas e na carga de sedimentos na BAP para o ano de 2050 sob três cenários potenciais. As avaliações foram feitas por meio

de uma abordagem de modelagem de Mudança de Uso e Cobertura da Terra. Os resultados para produção de sedimentos indicaram que a produção anual na BAP aumentará em 402% até 2050 no cenário de "*Business as usual*", ultrapassando 75 t/ha/ano (aumento de 458% na planície e 398% no planalto). O cenário de "*Acceleration of Anthropogenic Changes*" prevê um aumento de 460% na BAP (aumento de 608% na planície e 449% no planalto), enquanto o cenário de "*Buffered Protected Area*" prevê um aumento de 223% na BAP até 2050 (aumento de 191% na planície e 226% no planalto).

Fantin-Cruz et al. (2020) analisaram o transporte de sedimentos em suspensão e no leito do rio a montante e a jusante de 29 instalações hidrelétricas atuais localizadas no planalto da bacia do Alto Paraguai. Os resultados indicaram uma grande variabilidade entre as instalações analisadas, incluindo retenção, nenhuma alteração e liberação de sedimentos em alguns casos. O transporte de sedimentos no leito do rio se mostrou um componente pequeno do transporte total de sedimentos, representando menos de 10% na maioria dos casos. Além disso, um modelo preditivo usando redes neurais artificiais estimou o impacto de 80 futuras PCHs no transporte de sedimentos em suspensão, com base em observações em instalações atuais. A previsão indicou que as futuras PCHs reduziram o transporte de sedimentos em suspensão em cerca de ~62% em direção ao Pantanal.

Bühler et al., (2012) caracterizaram o tipo e a quantidade de sedimentos presentes no rio Paraguai no trecho entre o perímetro urbano de Cáceres-MT. Foram levantados dados relativos às variáveis hidrodinâmicas como velocidade do fluxo da água, profundidade e largura do canal, dados físico-químicos como temperatura e turbidez e foram coletados sedimentos de fundo e em suspensão em quatro seções previamente definidas. A granulometria de sedimento de fundo indicou a predominância de areia média em todas as seções, com exceção da primeira em que predominou o silte. A baixa quantidade de argila encontrada em todas as seções indica a ocorrência de um processo erosivo no trecho estudado. Nas seções em que foram registrados predomínio de material grosseiro (seções 2, 3 e 4) como a areia média são pontos em que foram evidenciados supressão da mata ciliar com poucas árvores, provavelmente derrubadas para construção de espaços de lazer como chácaras, sítios e pousadas também observadas nas margens dessas seções.

Luz (2019) caracterizou a geomorfologia e a hidrologia da zona de confluência entre os rios Paraguai e Cuiabá na porção norte do Pantanal. Foram utilizados dados de sensoriamento remoto, sedimentológicos e geocronológicos para descrever a evolução geomorfológica da planície, e dados hidrossedimentológicos para descrever o transporte e deposição de sedimentos

no lobo atual do megaleque do rio Cuiabá, bem como medições em 2D e 3D do fluxo na confluência Paraguai-Cuiabá para entender a hidrodinâmica. Apesar do seu caráter localizado, este estudo proporcionou uma descrição da geomorfologia fluvial única e ainda não descrita na literatura para o trecho avaliado. Os resultados evidenciaram a dominância do rio Cuiabá na estrutura de fluxo, velocidades e no transporte de sedimentos para o trecho de confluência com o rio Paraguai. Também foram observados efeitos de remanso produzidos pelo rio Paraguai no rio Cuiabá.

Além disso, também foram encontrados estudos mais localizados, como por exemplo na sub-bacia do rio Cuiabá (Silveira et al., 2014), na sub-bacia do rio São Lourenço (Mingoti et al., 2019), na sub-bacia do rio Taquari (Assine, 2005; Galdino et al., 2006; Wosiacki et al., 2021), e na sub-bacia do rio Miranda (Farias et al., 2018). Também foram identificados diversos estudos voltados para a descrição e caracterização dos padrões de inundação da planície do Pantanal (Hamilton et al., 1996a; Allasia et al., 2004; Padovani, 2010; Fantin-Cruz et al., 2011; Bravo et al., 2012; Jean Milien et al., 2023).

Apesar da disponibilidade de diversos estudos hidrossedimentológicos na BAP, tanto relacionados aos aspectos de erosão e uso e cobertura da terra, quanto a aspectos de geomorfologia fluvial em algumas partes da bacia, ainda observa-se uma lacuna significativa relacionada a uma avaliação abrangente da dinâmica de sedimentos em suspensão ao longo do sistema rio-planície alagável, bem como os principais rios tributários do Pantanal, e a relação dessa dinâmica com a sazonalidade hidrológica da região.

2.3. Aprendizado de Máquinas – Modelos baseados em Inteligência Artificial

Os sistemas de aprendizado de máquinas constituem uma categoria de tecnologia que possibilita aos sistemas computacionais a capacidade de aprender e melhorar seu desempenho em tarefas específicas a partir da exposição a dados. Este campo da inteligência artificial tem se destacado em diversas áreas, permitindo a automação de processos complexos e a geração de *insights* valiosos a partir de conjuntos volumosos de informações.

No contexto das ciências hidrológicas e ambientais, o emprego de técnicas de aprendizado de máquina tem revolucionado a forma como lidamos com a gestão de recursos hídricos, previsões climáticas e a compreensão dos padrões e fenômenos relacionados à água,

proporcionando soluções mais precisas e eficientes para os desafios enfrentados nesse campo crucial da pesquisa e da prática científica.

Existem diversos métodos de aprendizado de máquinas, sendo que os mais populares dentro das ciências hidrológicas e ambientais são as redes neurais artificiais, máquinas de vetores de suporte, árvores de decisão, florestas aleatórias, processos gaussianos, redes bayesianas e sistemas de inferência fuzzy. A presente pesquisa emprega as redes neurais artificiais e os sistemas de inferência fuzzy. Portanto, uma descrição mais detalhada destes métodos é apresentada a seguir.

2.3.1. 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).

As ideias precursoras das Redes Neurais Artificiais surgiram em 1943, com o trabalho de McCulloch e Pitts, (1943) visando emular o funcionamento dos neurônios reais que transmitem informações no cérebro por meio de impulsos nervosos. Posteriormente, Hebb (1949) introduziu a ideia de treinamento de neurônios com o uso de pesos sinápticos. Entretanto, foi somente em 1958, com o trabalho de Rosenblatt (1958), que o conceito de Perceptron foi estabelecido como uma rede de neurônios artificiais em camadas paralelas, onde um limiar determinava a passagem do sinal. Dois anos depois, em 1960, Widrow e Hoff (1960) desenvolveram a regra delta, utilizada até hoje no treinamento das RNAs, permitindo funções de ativação mais complexas, em que o sinal poderia ser parcialmente transmitido, seguindo o formato de uma função de ativação.

No final da década de 1980, avanços significativos surgiram na área das RNAs. Rumelhart et al., (1986) introduziram o algoritmo retropropagativo, um marco na aplicação da regra delta, permitindo o treinamento de RNAs de múltiplas camadas. Depois, Hecht-Nielsen (1989) apresentou o teorema da existência, demonstrando a capacidade de uma rede neural artificial única em aproximar relações contínuas. Em 1989, Hornik et al., (1989) desenvolveram o Teorema da Aproximação Universal, reconhecendo a capacidade das RNAs de aproximar

qualquer relação mensurável existente. Esses avanços fizeram com que o interesse nas RNAs crescesse rapidamente, passando a ser amplamente utilizada a partir da década de 90.

Em aplicações hidro ambientais, as RNAs do tipo *feedforward*, as quais possuem uma estrutura com os neurônios agrupados em camadas, são comumente utilizadas, em geral com uma estrutura de três camadas. 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).

2.3.2. Sistemas Especialistas Fuzzy

Os sistemas de inferência fuzzy (SIF) foram desenvolvidos como uma tentativa de simular o raciocínio humano na tomada de decisões. Surgiram a partir das ideias iniciais de Lotfi Zadeh na década de 1960, que propôs a teoria dos conjuntos fuzzy como uma forma de lidar com a incerteza e a imprecisão presentes no mundo real. Zadeh introduziu o conceito de lógica fuzzy, onde as fronteiras entre as classes não são definidas de forma rígida, mas sim por meio de conjuntos difusos que permitem a sobreposição e a graduação de pertinência. Esse novo paradigma de modelagem permitiu a representação de informações imprecisas e incertas, tornando-se uma abordagem eficaz para lidar com sistemas complexos, como os presentes nas ciências hidrológicas.

Um SIF é um esquema de modelagem qualitativa no qual o comportamento do sistema é descrito usando linguagem natural (Lohani et al., 2007). Os sistemas de inferência fuzzy de Mamdani (Mamdani, 1977) são os mais compreensíveis e interpretáveis devido aos termos linguísticos no antecedente e no conseqüente, mantendo a formalização verbal durante todo o processo de inferência. Os sistemas de Mamdani geralmente são compostos pelos seguintes componentes: (1) fuzzificação das variáveis de entrada e saída; (2) uma base de regras ou base de conhecimento; (3) mecanismo de inferência fuzzy; e (4) defuzzificação da saída fuzzy para um número preciso.

O processo de fuzzificação é realizado por meio de funções de pertinência (FPs), que podem ser projetadas em diferentes formatos, como triangular, senoidal ou trapezoidal. Todas as FPs têm um protótipo, que é o ponto onde o conjunto fuzzy atinge o valor máximo de pertinência, correspondendo ao ponto onde os próximos conjuntos fuzzy têm um valor de

pertinência nulo. Através das FPs, cada variável pertence a um máximo de dois conjuntos fuzzy, cuja soma de valores sempre resulta em 1 (Lucchese et al., 2021).

A base de regras é o aspecto mais importante do design de um FIS, uma vez que a interpretabilidade e a precisão do modelo dependem fortemente dela. As regras fuzzy são relações simples entre variáveis fuzzy, por exemplo, "SE x é baixo ENTÃO y é alto", onde "baixo" e "alto" são rótulos de conjuntos fuzzy, e "x" e "y" são valores nítidos (Zadeh, 1973). A base de regras pode ser projetada por meio de abordagens orientadas por especialistas ou abordagens orientadas por dados.

O mecanismo de inferência fuzzy refere-se aos métodos de implicação fuzzy e aos operadores de composição fuzzy. Após a fuzzificação dos dados nítidos, as regras são ativadas para cada grau de pertinência, e o método de implicação é realizado para avaliar as regras e produzir valores fuzzy de saída; a implicação das regras ativadas é agregada para finalmente obter a saída fuzzy. Em seguida, a saída fuzzy é convertida em um valor específico; esse processo é realizado pelo processo de defuzzificação por meio de várias opções, como centroide de área ou bissectriz de área (Matía et al., 2011).

Os FIS são principalmente caracterizados por dois recursos que avaliam a qualidade do modelo obtido: (i) interpretabilidade - que se refere à capacidade do modelo FIS de expressar o comportamento do sistema de maneira compreensível; (ii) precisão - que se refere à capacidade do modelo FIS de representar fielmente os fenômenos modelados, com alta precisão. Interpretabilidade e precisão são questões contraditórias, e alcançar ambos os critérios com alto grau é uma tarefa difícil (Pancho et al., 2013). No entanto, os FIS oferecem a possibilidade de negociar esses recursos até que o equilíbrio desejado seja alcançado (Dutu et al., 2018), embora, no que diz respeito às aplicações nas ciências hidrológicas, até agora, mais prioridade tem sido dada à precisão dos modelos para fornecer boas estimativas numéricas.

2.3.3. Estudo do transporte de sedimentos com modelos baseados em dados – revisão de literatura

A heterogeneidade dos processos de transporte de sedimentos no tempo e no espaço requer o uso de metodologias avançadas para representar a dinâmica de sedimentos e identificar os principais fatores que os controlam (Onderka et al., 2012; Francke et al., 2014). O aumento do volume de dados ambientais, incluindo dados de sensoriamento remoto, tem criado oportunidades para o uso de modelos computacionais mais complexos, como os modelos baseados em IA.

Nas últimas décadas, diversas pesquisas diferentes demonstraram a capacidade das técnicas de modelagem baseada em inteligência artificial em modelar os sistemas hidrossedimentológicos de bacias hidrográficas, levando em conta a variabilidade espaço-temporal nas concentrações e cargas de sedimentos suspensos. Diversos estudos indicam que o transporte de sedimentos suspensos é fortemente impulsionado por um conjunto de fatores específicos da bacia.

Jain (2001) desenvolveu modelos de RNA para estabelecer uma relação entre SSC e descarga em dois pontos do rio Mississippi e comparou-os com a técnica tradicional da curva-chave de sedimentos. O autor mostrou que os resultados das redes neurais artificiais foram muito mais próximos dos valores observados do que a curva-chave de sedimentos. A curva-chave é amplamente utilizada na determinação indireta de SSC, porém, os graus de liberdade da equação muitas vezes se mostram insuficientes para boas estimativas, devido à influência da representação de outros fatores, como por exemplo o fenômeno de histerese.

Grove et al. (2015) usaram um modelo de RNAs baseado em análise discriminante múltipla, utilizando um conjunto de variáveis hidrometeorológicas e fisiográficas, além de dados de turbidez, coletados ao longo de dois anos, para dez locais de referência, para prever as concentrações médias anuais de sedimentos suspensos. Eles descobriram que a concentração média anual de sedimentos suspensos era significativamente diferente para todos os locais, entre os dois anos observados, e que essa variabilidade poderia ser prevista razoavelmente bem pelo modelo.

Atieh et al. (2015) aplicaram modelos de RNA para estimar sedimentos em bacias sem monitoramento, em Ontário, no Canadá. Os autores integraram 94 bacias para estimar parâmetros de curva-chave de sedimentos em bacias não monitoradas. Foram utilizadas variáveis de entrada fisiográficas, climáticas e hidrométricas. Esta abordagem permitiu o desenvolvimento de curvas-chave de sedimentos para bacias onde os sedimentos não são monitorados, com desempenho satisfatório. Por outro lado, as bacias utilizadas para calibração e validação dos modelos possuíam dados suficientes para ajustar boas curvas-chave de sedimentos.

Zeiger & Hubbart (2016) realizaram múltiplas análises de regressão linear em um conjunto de dados de sedimentos suspensos de quatro anos na bacia hidrográfica de Hinkson Creek, na bacia do rio Mississippi, EUA. Eles concluem que as cargas anuais de sedimentos estão significativamente correlacionadas com a precipitação anual total, mas também com o uso da terra.

Cobaner; Unal; Kisi (2009) usaram modelos baseados em neuro-fuzzy e redes neurais

artificiais para prever as concentrações de sedimentos suspensos na bacia hidrográfica do rio Mad, EUA. Semelhante às conclusões de outros estudos, este estudo demonstra que os modelos contendo dados hidrometeorológicos têm melhor desempenho na previsão de sedimentos em comparação com as curvas-chave de sedimentos.

Teixeira et al. (2020) desenvolveram modelos regionais baseados em RNA e sistema de inferência fuzzy (SIF) para estimar CSS e turbidez, usando como variáveis preditivas vazão, área da bacia hidrográfica e precipitação horária agregada através da média móvel exponencialmente ponderada da precipitação passada. O monitoramento dos dados foi realizado em quatro bacias homogêneas da mesma região no sul do Brasil. Vários modelos SIF e RNA tiveram um desempenho muito bom para a previsão de CSS devido à inclusão da média móvel exponencialmente ponderada da precipitação passada. Os resultados permitem concluir que é possível estimar CSS em bacias com poucos dados individuais por meio de um modelo empírico regional, desde que as bacias tenham características físicas e climáticas semelhantes.

Os estudos indicam que as estimativas de sedimentos suspensos feitas com base apenas nas descargas líquidas do rio são menos precisas (por exemplo a curva-chave de sedimentos, que é amplamente utilizada) do que estimativas que incluem também dados hidrometeorológicos, fisiográficos e hidrométricos.

2.4. Sensoriamento Remoto na hidrossedimentologia

Na hidrossedimentologia, compreender os fenômenos erosivos, de transporte e de deposição de sedimentos requer monitoramento contínuo de algumas variáveis ambientais. No entanto, em áreas remotas e de difícil acesso, como o Pantanal, medir a quantidade de sedimentos ao longo dos cursos d'água, bem como outras variáveis hidrológicas relacionadas, se torna um processo complexo e oneroso. Neste sentido, dados obtidos por meio de técnicas de sensoriamento remoto funcionam como importantes complementos no monitoramento *in situ* de variáveis hidrossedimentológicas, oferecendo uma abordagem complementar e abrangente para compreender processos em larga escala.

Um vasto conjunto de dados de sensoriamento remoto, provenientes de sensores acoplados a satélites, está disponível gratuitamente por meio de agências espaciais renomadas, como a NASA - *National Aeronautics and Space Administration* e a ESA - *European Space Agency*, oferecendo diversas informações úteis para estudos na área da hidrossedimentologia. Entre esses dados, destacam-se os registros de precipitação da constelação GPM - *Global*

Precipitation Measurement (Hou et al., 2014), bem como os produtos que combinam dados de precipitação *in situ* com dados obtidos por sensoriamento remoto, tais como IMERG - *Integrated Multi-satellite Retrievals for GPM* (Huffman et al., 2020), CHIRPS - *Climate Hazards group Infrared Precipitation with Stations* (Funk et al., 2015), e MERGE - Produto de precipitações gerado pelo INPE - Rozante et al. (2010). A validação desses produtos em diversas bacias brasileiras já foi realizada em vários estudos (Cavalcante et al., 2020; Rozante et al., 2020; Pradhan et al., 2022), evidenciando sua eficácia e utilidade para análises hidrossedimentológicas.

Outro exemplo de dados de sensoriamento remoto que é muito útil e importante no campo da hidrossedimentologia são os dados de uso e cobertura da terra. Existem diversos conjuntos de dados gratuitos disponíveis em escala global, como os produtos: i) *Copernicus Global Land Cover 100m* (Buchhorn et al., 2020), com resolução espacial de 100 m, e dados anuais de 2015 a 2019; ii) *The MODIS Land Cover Type Product* (Friedl et al., 2002, 2010), com resolução espacial de 500m e dados anuais de 2001 até o presente; iii) *Dynamic World, Near real-time global 10m land use land cover mapping* (Brown et al., 2022), com resolução espacial de 10m e dados atualizados continuamente desde 2015 (atualizado a cada 5 dias aproximadamente); e o iv) *ESA WorldCover 10m* (Zanaga et al., 2022), com resolução espacial de 10 m e disponível para o ano de 2021. Em escala nacional, destaca-se o produto de uso e cobertura da terra do Mapbiomas (Souza et al., 2020), que monitora o Brasil a partir dos dados da missão Landsat, com resolução espacial de 30m, desde 1985 até 2022. O conhecimento do uso e da cobertura vegetal, bem como suas alterações ao longo do tempo, são fundamentais para o entendimento dos processos de geração de sedimentos em bacias hidrográficas.

Modelos digitais de elevação (MDE) também constituem-se em dados que podem ser obtidos por sensoriamento remoto, como por exemplo o MDE da missão SRTM (Farr et al., 2007), com resolução de 30m, Copernicus DEM, com resolução de 30 m, ou o MDE da Alos Palsar (Laurencelle et al., 2015), com resolução espacial de 12,5m. Estes dados também são disponibilizados gratuitamente, e são importantes na extração de informações fisiográficas das bacias hidrográficas, que, por sua vez, são importantes nos estudos hidrossedimentológicos.

Além disso, a própria concentração de sedimentos em suspensão pode ser estimada indiretamente por meio de imagens multiespectrais de satélite. As estimativas se baseiam na relação estatística entre a concentração observada em suspensão na água e as bandas espectrais de refletância das imagens no visível. Essa relação é possível porque partículas suspensas causam um aumento na refletância, ou seja, a radiação refletida aumenta à medida que a concentração aumenta (Kirk, 1994). A absorção, espalhamento e reflexão da luz visível e

infravermelha próxima pelas partículas em suspensão são influenciados por propriedades como tamanho, forma, concentração e composição dos sedimentos. A partir dessas interações, os sensores multiespectrais dos satélites captam diferentes assinaturas espectrais, permitindo a correlação das variações espectrais com a concentração de sedimentos, empregando modelos físicos e/ou modelos baseados em dados para estimar a quantidade desses sedimentos nos corpos d'água (Jensen, 2009).

Além disso, a física da interação luz-matéria também envolve a compreensão das características atmosféricas que afetam a aquisição das imagens multiespectrais pelo satélite. Fenômenos como absorção atmosférica, dispersão e reflexão também influenciam as informações recebidas pelos sensores a bordo do satélite. Assim, é necessário considerar e corrigir esses efeitos atmosféricos para obter estimativas precisas dos sedimentos em suspensão (Jensen, 2009).

Vários estudos têm utilizado a reflectância da superfície em imagens multiespectrais de satélite para avaliar parâmetros de qualidade da água, como sedimentos em suspensão, turbidez e clorofila-a (Lobo et al., 2012; Martinez et al., 2015; Fassoni-Andrade e Paiva, 2019; Pereira et al., 2020), provando sua aplicabilidade. No entanto, não foram encontrados estudos disponíveis para a região do Pantanal durante o desenvolvimento desta Tese.

3. ARTIGO 1 - Estimation of suspended sediment concentrations in ungauged heterogeneous basins with scarce *in situ* data by using a regional ANN-based model

Este capítulo aborda sobre estimativas indiretas de concentração de sedimentos suspensos na região hidrográfica do Alto Paraguai, com enfoque na obtenção de estimativas em locais que não possuem dados de sedimentos, mas possuem outros dados mais fáceis de serem obtidos, como a turbidez e a vazão. Embora a CSS seja mensurada em alguns rios dessa região, a frequência de amostragem normalmente é baixa (duas coletas por ano em média) 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.

A região hidrográfica do Alto Paraguai caracteriza-se por uma elevada heterogeneidade fisiográfica, apresentando sub-bacias com diferentes comportamentos hidrossedimentológicos, desde bacias com elevada produção de sedimentos, até regiões onde há grande predomínio de deposição, como no caso das planícies de inundação do Pantanal. Neste sentido, a estimativa da CSS em locais sem monitoramento dessa região hidrográfica requer o uso de ferramentas computacionais com elevado poder preditivo, que, neste capítulo, foram as redes neurais artificiais. As estimativas foram realizadas por meio de diversas variáveis qualitativas e quantitativas, que são facilmente obtidas por meio de técnicas de sensoriamento remoto, mapas de uso e ocupação do solo, mapas de tipo de solo e dados hidrométricos e pluviométricos.

O presente capítulo é apresentado em inglês, baseado no primeiro artigo científico desta Tese de doutorado, publicado na revista *Hydrological Sciences Journal* (março de 2021): CAMPOS, Juliana Andrade; PEDROLLO, Olavo Correa. **A regional ANN-based model to estimate suspended sediment concentrations in ungauged heterogeneous basins.** v. 66, p. 1222–1232, 2021. <https://doi.org/10.1080/02626667.2021.1918695>.

Abstract

The high costs of monitoring suspended sediment concentration (SSC) in rivers calls for development of indirect estimation methods, based on relationships with other variables which are easier and cheaper to obtain. We present an original approach to investigate the capacity of regional models to extrapolate SSC to ungauged basins, in a heterogeneous region with scarce *in situ* data and complex hydrography. The estimates were based on qualitative variables (drainage area, soil type, land use and mean catchment

slope) to represent spatial variability, and quantitative variables (turbidity, flow, precipitation and exponentially weighted moving average of past rainfall) to represent temporal variability. We used artificial neural network (ANN) based models, applied to the Brazilian part of the Upper Paraguay River Basin, covering an area of 362 380 km². This research proved that the proposed methodology allows the regional extrapolation of SSC to ungauged basins with very good performance, even in heterogeneous regions.

Keywords: artificial neural networks; Pantanal wetland; soil type and land use; turbidity; satellite rainfall product; exponentially weighted moving averages of past rainfall.

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.

The monitoring of the SSC generally consists of field collection of water samples in previously determined sections and subsequent laboratory analysis. Due to high costs, technical constraints and difficulties in accessing remote sites, the sampling frequency and spatial coverage are usually low, and the spatio-temporal representation of the sediment dynamics is limited (Bayram et al., 2012, 2014; Sari et al., 2017; Fagundes et al., 2020). The lack of information about suspended sediment concentration in rivers stimulates the development of indirect estimation methodologies based on the relation between sediment and other variables which are easier to determine over time.

Several approaches to estimate sediment transport have been developed over the last decades, from the traditional sediment rating-curve which consists of a logarithmic regression that relates the liquid discharge to the solid discharge, to sophisticated data-driven approaches involving different types of input variables. Artificial Neural Network (ANN) is one of the most common and well-known data-driven approach that lately has found applications in a variety of areas, including sediment estimations (Afan et al., 2016). Its high ability for modelling nonlinear and complex relationships is widely known and accepted around the world.

Discharge, previous suspended sediment load and precipitation (since precipitation is the main agent in hydro-sedimentological processes) are the main input variables used in sediment estimations. Generally, these studies use long-term data series from single or few hydrometric stations, producing satisfactory results (Jain, 2001; Tayfur, 2002; Kisi et al., 2012; Lafdani et al., 2013; Singh et al., 2013; Pektas e Cigizoglu, 2017; Khosravi et al., 2018; Adnan

et al., 2019; Nhu et al., 2020; Salih et al., 2020). However, most rivers around the world do not have a long-term data series of SSC for such applications.

Despite the widespread use of sophisticated data-driven approaches in sediment estimations, few studies addressed ungauged basins and applications that deal with data scarcity. Heng and Suetsugi (2013) used ANN to estimate monthly suspended sediment load at ungauged sites of the Lower Mekong basin using climatic and flow data from 7 hydrometric stations. Atieh et al. (2015) applied ANN models to estimate sediment transport in ungauged basins of Ontario, Canada. The authors integrated 94 basins to estimate the parameters of the traditional sediment rating curve using input variables that physically characterize the basins, as well as the climatic and hydrometric parameters, leading to satisfactory results. Although the applications involved ungauged sites, these studies used hydrometric stations with long-term data series to calibrate the models.

In the last decades, the use of turbidity as an indirect measure of SSC has gained prominence in the monitoring programs of sediment transport in rivers due to high correlation with SSC, and since turbidity measurement is less expensive than traditional sediment collection (Bayram et al., 2012; Harrington e Harrington, 2013; Shellenbarger et al., 2013; Haimann et al., 2014; Tananaev e Debolskiy, 2014; Sari et al., 2015, 2017). Bayram et al. (2012) estimated SSC using turbidity data from six stations (144 records including all of stations) along the Harsit River in Turkey through ANN models. 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. Even with small amounts of data (59 records of SSC), the ANN models yielded satisfactory results. The high correlation between turbidity and SSC allows satisfactory estimates even with limited data.

To deal with data scarcity, Teixeira et al. (2020) developed regional models based on ANN and fuzzy inference system (FIS) to estimate SSC and turbidity using discharge, watershed area and hourly precipitation aggregated through the exponentially weighted moving average (EWMA) of past rainfall as predictive variables. The data monitoring was performed in four homogeneous watersheds within the same region in southern Brazil. Several FIS and ANN models performed very well for SSC prediction due to the inclusion of the EWMA variable. The results allow to conclude that it is possible to estimate SCC with few data for the individual basin through a regional empirical model, as long as the basins have similar physical and climatic characteristics. In addition to the restriction regarding to physically homogeneous regions, the extrapolation capacity of the model to ungauged basins (basins that have not been used in the training of the models) was not tested in that work.

The objective of this research is to investigate the capacity of regional models to extrapolate SSC to ungauged basins in a heterogeneous region with scarce *in situ* data, using qualitative variables to represent spatial variability and quantitative variables to represent temporal variability in each basin, thus filling important gaps in previous studies. ANN modelling was chosen to undertake this research, since it is one of the most used and well-known data-driven approaches due to its simplicity and high capacity of approximating any nonlinear relationship (Hornik et al., 1989).

The present study is conducted in the Upper Paraguay River Basin (UPRB), Brazil, where the Pantanal biome is located, the largest tropical wetland area in the world. This region is largely lacking in hydro-sedimentological monitoring, with approximately one station per 8000 km² and low collection frequency (average of four records per year). Development of sediment rating-curves, as well as estimates from only hydrometric and climatic data is unreliable due to insufficient SSC data. Turbidity is spatially and temporally monitored to a larger extent than SSC in the UPRB, allowing the use of this variable in SSC estimates.

The heterogeneity of the basins requires the use of qualitative variables that physically characterize the watersheds, such as soil type, land use, drainage area and mean catchment slope, as well as quantitative variables such as turbidity, discharge and previous rainfall. Due to the low density of precipitation gauges in this region, another novelty of this research is the use of a satellite rainfall product combined with the EWMA of past rainfall to aggregate temporal data and catch the dynamics of sediment formation from rainfall, even in ungauged regions.

3.2. Study area and data

3.2.1. Pantanal wetland

This study was carried out for the Brazilian part of the Upper Paraguay River Basin (UPRB), covering an area of 362,380 km², where one of the largest wetland areas on the planet is situated: The Pantanal. The region (Fig. 8) is subdivided into two areas according to distinct topographic and hydrological characteristics: the high-altitude Planalto region, and the lower Pantanal wetland region. Pantanal is also the name given to the biome of the plain.

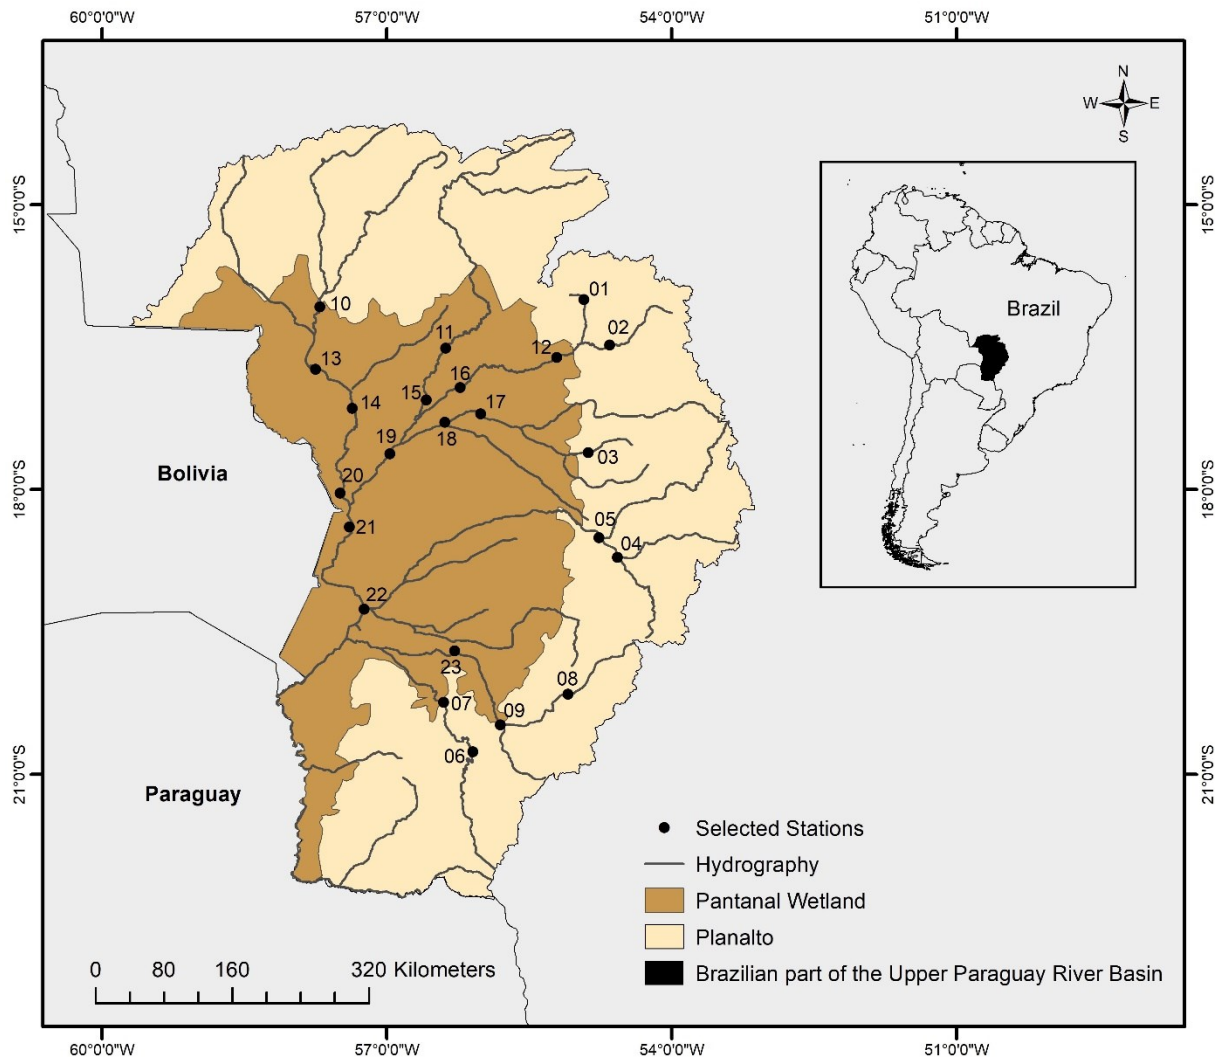


Fig. 8 - Localization of the study area, showing the selected hydrometric stations

The Planalto region corresponds to 59 % of the basin area, with lands above 200 m of altitude, reaching above 1100 m, mainly in eastern and northern parts. This part of the basin presents deep soils and high slopes, favouring rapid drainage and high sediment production.

The Pantanal plain corresponds to 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 quickly transmit the water received from the Planalto, and extensive areas are flooded, resulting in complex hydrological and hydro-sedimentological dynamics (Bravo et al., 2012).

According to the Köppen-Geiger climate classification, the predominant climate in the UPRB is 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).

3.2.2. Data

For this study, 23 stations with hydrometric data were selected for model construction due to the coincident availability of SSC, turbidity and flow data. The data were provided by the Brazilian National Water Agency (ANA), through the national hydrological information system (Hidroweb – <https://www.snirh.gov.br/>).

In Tab. 1, the information of the 23 stations is shown. The period of records starts in 2009, the year in which ANA started a water quality monitoring program in the UPRB. Most of the sediment data collection has been performed during the rainy season (October to April).

Tab. 1 - Selected hydrometric stations

	Station Name	River	Region	Drainage Area (km ²)	Period of Record
1	São Pedro da Cipa	São Lourenço	Planalto	3 267	2009-2018
2	Rondonópolis	Vermelho	Planalto	12 297	2009-2017
3	Estrada BR-163	Correntes	Planalto	3 969	2009-2014
4	Garimpagem	Jauru	Planalto	6 328	2009-2016
5	Coxim	Taquari	Planalto	27 573	2009-2016
6	Estrada MT-738	Miranda	Planalto	11 552	2009-2016
7	Miranda	Miranda	Planalto	15 189	2009-2016
8	Ponte do Grego	Aquidauana	Planalto	6 318	2009-2018
9	Aquidauana	Aquidauana	Planalto	15 707	2009-2016
10	Cáceres	Paraguay	Pantanal	32 373	2010-2016
11	Porto Cercado	Cuiabá	Pantanal	37 024	2009-2018
12	Acima do Córego Grande	São Lourenço	Pantanal	23 105	2009-2018
13	Descalvados	Paraguay	Pantanal	48 179	2010-2016
14	Porto Conceição	Paraguay	Pantanal	65 879	2010-2016
15	Ilha Camargo	Cuiabá	Pantanal	39 006	2009-2017
16	São José do Boriréu	São Lourenço	Pantanal	24 844	2009-2017
17	São Jerônimo	Piquiri	Pantanal	23 315	2009-2017
18	São José do Piquiri	Piquiri	Pantanal	29 388	2009-2017
19	Porto do Alegre	Cuiabá	Pantanal	102 580	2009-2017
20	Amolar	Paraguay	Pantanal	72 642	2009-2013
21	São Francisco	Paraguay	Pantanal	185 113	2009-2018
22	Porto da Manga	Paraguay	Pantanal	261 480	2009-2016
23	Porto Ciriaco	Aquidauana	Pantanal	17 190	2009-2016

The elevation of UPRB 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). 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.

The land use was characterized using a map from the Brazilian Agricultural Research Corporation, made specifically for the UPRB. The map was made by images from 2014 taken by the Landsat 8 satellite, with a spatial resolution of 30 m. (Embrapa, 2015).

Although the Brazilian part of the UPRB has 92 conventional precipitation gauges, which corresponds to 3938 km² per station, this density is considered low. According to the World Meteorological Organization (WMO, 2008) the recommended density for plains is 575 km² per station. On the other hand, satellite rainfall products are becoming increasingly available and accessible in near-real time with almost global coverage. Temporal and spatial resolution, as well as measurement accuracy, are continuously improving owing to steady advances in sensor technology and new methods for merging various data sources. Several high-resolution products are at an operational stage, with a rapidly growing scientific community using these data to supplement or even replace rain gauge observations (Gebremicael et al., 2017).

For this reason, the precipitation data used in this study were obtained from the MERGE product, which is a combination of observed rainfall data and satellite information, made available to all South America. The MERGE comes from the Brazilian National Institute of Space Research (CPTEC/INPE).

The MERGE product uses rainfall data estimated 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 the precipitation data estimated through satellite are used to fill the missing information. The rainfall estimates are 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) since 2015 until current time. Further details are found in Rozante et al. (2010).

The daily data are available in grids of 20 km, whose precipitations are accumulated every 24 hours. The MERGE product was downloaded for the period from January 2008 to December 2017, covering the data period of the SSC measurements. The data were extracted for each station, covering an area with radius of 100 km. Subsequently, the data were interpolated to the stations using the inverse square distance method (Burrough e McDonnell, 1998).

3.3. Model development

3.3.1. Input and output model variables

For the development of the regional SSC estimation model, 346 suspended sediment concentration records from the 23 selected stations were used as output variable.

Data of turbidity, discharge, and rainfall comprise the input quantitative variables, used to enable SSC estimates in the different rivers of the hydrographic region. Turbidity and flow data were obtained from the same hydrometric stations as the SSC data and refer to the same day. The rainfall data were extracted considering the same day as the SSC data, as well as previous days (rainfall data from day t , $t-1$, $t-2$, $t-3$, $t-4$, and $t-5$).

The EWMA technique was proposed by Moore (1982) 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, promoting a synthesis of recent precipitation information in the form of a representative value, resulting in more parsimonious models.

The EWMA is applied in time series of precipitation with constant intervals, according to Equation 1.

$$EWMA_t = \sum_{i=0}^{\infty} w_i P_{t-i} \quad (1)$$

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

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

$$\alpha = 1 - 0,5^{(1/h)} \quad (2)$$

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 3):

$$EWMA_t = (1 - \alpha) EWMA_{t-1} + \alpha P_t \quad (3)$$

The EWMA was applied to the precipitation data obtained from the MERGE product for the 23 points of analysis, considering the half-life parameters $h = 1, 2, 5, 10$ and 15 days. The half-life parameters were chosen from preliminary analysis of linear correlations with SSC.

The transformation of turbidity readings into SSC depends on factors such as size, shape, colour, refractive index, density, and mineralogical composition of the sediment particle (Sari et al., 2015). Since the model data are from different parts of a very heterogeneous hydrographic region, the other attributes inserted (mainly qualitative variables) give the models the ability to differentiate these factors.

The variables used to represent the heterogeneity of the UPRB, which in this study we named qualitative variables, comprise the drainage area (km²), soil type (13 different classes) land use and cover (14 different classes) and mean catchment slope (%), for all the 23 selected stations.

The soil type and land use and cover were included as proportions of the basin area (i.e., (percentages divided by 100)). Each soil type and land use and cover class was included in the regional ANN-based model as an input variable.

In Fig. 9, the summary of the assessed input variables to estimate the SSC (output variable) in the UPRB rivers is presented.

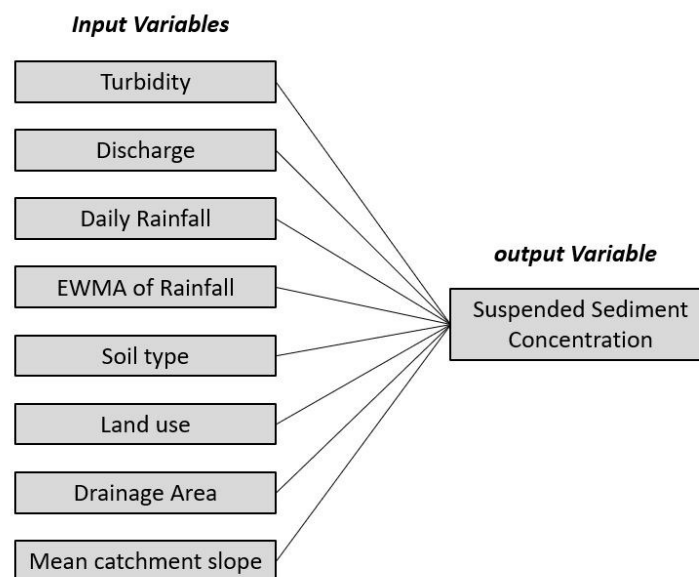


Fig. 9 - Summary of the input and output variables

3.3.2. ANN models

Several ANN models were developed to estimate SSC from the reported input variables. From a complete model with all proposed input variables, other models were tested leaving out one variable each time to verify its importance.

Multilayer perceptron models were used with a three-layer architecture, constituting an input layer, an intermediate layer and an output layer, all with a unipolar sigmoid activation

function. The adoption of a single intermediate layer is based on the existence theorem (Hecht-Nielsen, 1990), which states that an ANN with a single inner layer is capable of approximating any continuous numerical relationship. The backpropagation algorithm (Rumelhart et al., 1986) were custom programmed in the Matlab[®] R2012b environment. Overfitting was avoided using the cross-validation technique (Hecht-Nielsen, 1990).

Regarding the number of neurons in the intermediate layer, we followed the concept of parsimony presented by (Sari et al., 2017), in which each ANN model was trained with cross-validation by reducing the number of neurons in the inner layer until a performance reduction in the validation sampling occurred. Then, the previous alternative with enough degrees of freedom was chosen. This approach provides more parsimonious ANN models.

The adopted approach to divide the data sample for cross-validation was to separate 11 stations for training, 6 stations for validation and 6 stations for verification (Tab. 2). Stations with extreme values (maximum and minimum) were included in the training samples. Stations from Planalto and Pantanal are present in all training, validation, and verification samples, to provide spatial balance to the model.

Tab. 2 - Sample separation

Sample	Records	Station number
Training	166	1, 4, 5, 6, 8, 11, 16, 18, 20, 22 and 23
Validation	85	2, 9, 10, 14, 17 and 21
Verification	95	3, 7, 12, 13, 15, and 19

Each cross-validation training was performed with fifteen repetitions using random initiations of the synaptic weights. The training with the best final performance in the validation sampling was selected. This procedure was performed to minimize the influence of random initialization on the results.

3.3.3. Model performance statistics

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

$$NS = 1 - \frac{\sum_{i=1}^N (T_i - Y_i)^2}{\sum_{i=1}^N (T_i - \bar{T})^2} \quad (4)$$

where: T_i are the observed data; \bar{T} 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 performance; values \leq zero indicate that the \bar{T} is a better approximation than the calculated values of Y_i .

To interpret the performance of the model via the NS, we used the classification proposed by Moriasi et al. (2015) specifically for sediments, in which the model is considered “very good” for $NS > 0.8$; “good” for $0.7 < NS \leq 0.8$; “satisfactory” for $0.45 < NS \leq 0.7$; and “not satisfactory” for $NS \leq 0.45$.

3.4. Results and discussion

3.4.1. Data analysis

In this section, an analysis of all qualitative and quantitative data is performed, to provide conceptual understanding of the results of the models.

The maps of soil types (a), land use (b) and the digital elevation model (c) in the UPRB are presented in Fig. 10. The classes of soil type, land use, as well as the drainage area and mean catchment slope for each hydrometric station were obtained through these maps. In both maps it is possible to observe very different characteristics between the Planalto region and the Pantanal region.

Regarding the soil type classes, the Argissolos, Neossolos and Latossolos are more frequent in the Planalto. This region presents soils with high depths and strong drainage, with colours ranging from reddish, yellowish, and more rarely brownish or greyish.

The most common soil classes in the Pantanal region are the Gleissolos, Espodossolos and Planossolos. These soil types have poor drainage and are periodically or permanently water saturated and are, therefore, very different from the soils of the Planalto region.

Concerning land use, the Planalto region is predominantly used for pasture and agriculture, and the Pantanal, as it is a preservation area, has a greater number of natural areas than the Planalto.

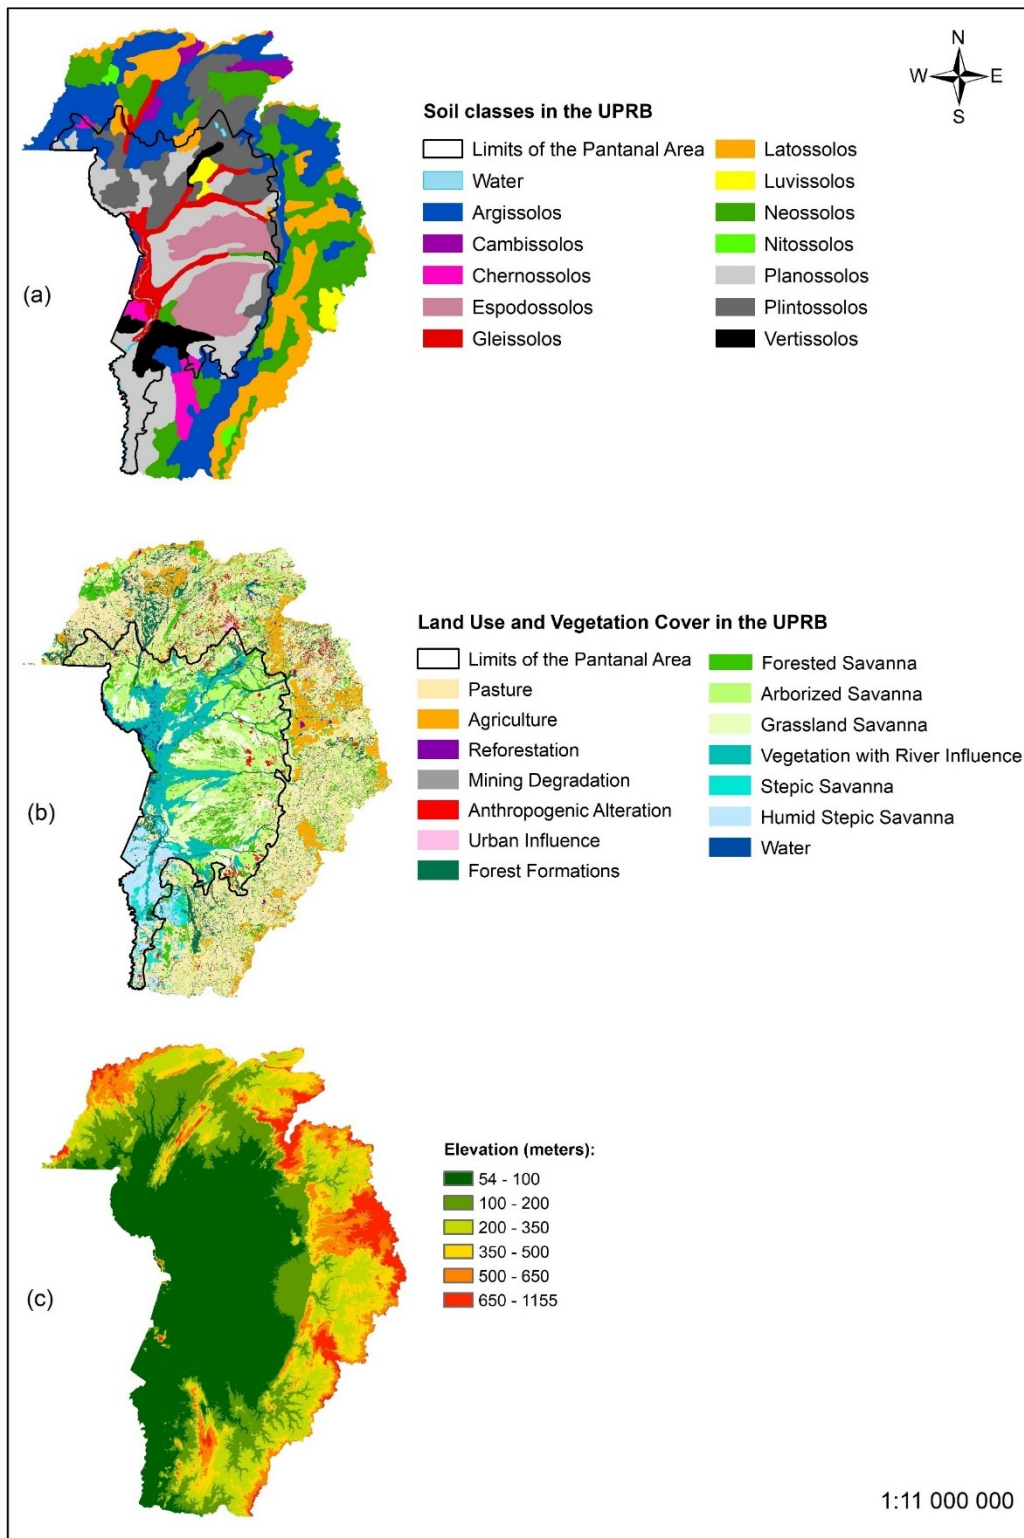


Fig. 10 - Soil type classes (a), land use classes (b) and digital elevation model (c) in the UPRB

The most common land use classes in this region are Arborized Savanna and Forested Savanna in parts without frequent flooding, and Vegetation with River Influence and Humid Stepic Savanna in flooded regions.

The elevation also has very distinct characteristics between Planalto and Pantanal, with elevated lands ranging from 200 to 1 155 m in the Planalto, while the Pantanal presents flatter lands, below 200 m.

Tab. 3 shows the descriptive statistics of the quantitative variables, turbidity, discharge, rainfall and EWMA of rainfall, and the calculated Pearson correlation coefficient with SSC.

Tab. 3- Descriptive statistics of quantitative variables used in the ANN models

	Model input and output variables	Min	Max	Mean	Median	Standard Deviation	Linear Correlation with SSC
1	Turbidity (NTU)	0	1262	76.56	37.5	126.14	0.69
2	Discharge (m ³ /s)	9.08	2 488.89	370.96	214.82	454.71	-0.17
3	Daily Rainfall t (mm)	0	109.47	3.13	0	9.92	0.06*
4	Daily Rainfall t - 1 (mm)	0	119.42	3.77	0	10.52	0.16
5	Daily Rainfall t - 2 (mm)	0	102.18	5.18	0	9.36	0.17
6	Daily Rainfall t - 3 (mm)	0	121.44	4.02	0	9.98	0.14
7	Daily Rainfall t - 4 (mm)	0	115.36	4.13	0	10.02	0.12
8	Daily Rainfall t - 5 (mm)	0	108.98	4.55	0	10.11	0.08*
9	EWMA of Rainfall h=1 (mm)	0	55.23	3.03	0.79	5.79	0.19
10	EWMA of Rainfall h=2 (mm)	0	33.61	3.08	1.67	4.29	0.31
11	EWMA of Rainfall h=5 (mm)	0	17.08	3.05	2.37	3.02	0.37
12	EWMA of Rainfall h=10 (mm)	0	13.76	3.04	2.55	2.46	0.33
13	EWMA of Rainfall h=15 (mm)	0	12.07	3.07	2.68	2.27	0.22
14	Suspended Sediment Concentration (mg/L)	0	1 736	128.68	51.45	200.59	1

* p-value > 0.05

The turbidity presented the best positive correlation with SSC ($R = 0.69$, $p < 0.05$), which was already expected due to the intrinsic relationship between this variable and the presence of sediments in the rivers. The discharge presented negative correlation with SSC ($R = -0.17$, $p < 0.05$). Although it is a weak negative linear correlation, this value indicates 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 in the Pantanal region, where flows are higher and the flat lands favours deposition, the SSC magnitudes are smaller.

The effect of past rainfall is observed in the value of the EWMA median. For the daily rainfall, more than 50 % of the rainfall data is zero (medians equal to zero), but for EWMA of rainfall it is higher than zero. Even if rainfall is zero in the day or previous days of SSC collection, the EWMA of rainfall aggregate information that occurred in longer previous periods.

The EWMA of rainfall provides an increase in the linear correlation coefficient compared to the original rainfall data, which shows that this technique is providing additional information for the SSC estimate.

Descriptive statistics and linear correlations between the SSC and Turbidity in each station are presented in Tab. 4.

Tab. 4 - Descriptive statistics and linear correlations between SSC and Turbidity for each station

	Station Name	Region	Drainage Area (km ²)	SSC (mg/L)			Turbidity (NTU)			Linear Correlation
				Min	Max	Mean	Min	Max	Mean	
1	São Pedro da Cipa	Planalto	3 267	6.7	1 736.0	309.8	4.4	1 262.0	196.5	0.91
2	Rondonópolis	Planalto	12 297	19.4	593.2	259.4	14.4	770.0	229.2	0.76
3	Estrada BR-163	Planalto	3 969	2.0	162.7	23.9	4.4	146.0	22.0	0.72
4	Garimpagem	Planalto	6 328	98.1	1 327.0	475.5	0.0	454.0	106.5	0.88
5	Coxim	Planalto	27 573	11.4	844.0	391.6	0.0	314.5	73.9	0.76
6	Estrada MT-738	Planalto	11 552	12.6	687.0	133.3	8.0	367.0	83.8	0.76
7	Miranda	Planalto	15 189	41.7	210.0	90.6	0.0	148.0	58.0	0.72
8	Ponte do Grego	Planalto	6 318	15.0	284.9	120.2	2.5	275.0	67.7	0.85
9	Aquidauana	Planalto	15 707	19.3	337.6	116.7	15.9	297.0	76.6	0.81
10	Cáceres	Pantanal	32 373	9.5	83.5	33.1	0.0	74.2	34.5	0.80
11	Porto Cercado	Pantanal	37 024	27.5	182.1	59.3	12.1	218.0	61.9	0.66
12	Acima do Córrego Grande	Pantanal	23 105	39.5	481.0	163.3	33.7	489.0	154.7	0.95
13	Descalvados	Pantanal	48 179	11.5	77.1	32.5	0.0	109.0	29.6	0.30
14	Porto Conceição	Pantanal	65 879	6.6	71.0	32.4	0.0	79.4	25.9	0.43
15	Ilha Camargo	Pantanal	39 006	16.1	156.2	64.7	10.4	224.0	61.1	0.59
16	São José do Boriréu	Pantanal	24 844	76.0	432.0	201.2	2.5	368.9	120.6	0.67
17	São Jerônimo	Pantanal	23 315	3.7	179.0	31.0	5.5	85.1	21.5	-0.16
18	São José do Piquiri	Pantanal	29 388	4.0	180.0	31.0	8.7	25.5	17.9	-0.20
19	Porto do Alegre	Pantanal	102 580	24.6	110.1	48.6	10.3	224.6	63.9	0.47
20	Amolar	Pantanal	72 642	0.0	90.5	34.9	10.9	109.0	36.0	0.34
21	São Francisco	Pantanal	185 113	0.0	57.0	28.1	0.0	94.6	30.2	0.38
22	Porto da Manga	Pantanal	261 480	7.3	88.7	38.9	0.0	131.0	34.1	0.26
23	Porto Ciriaco	Pantanal	17 190	20.7	487.0	104.4	0.0	144.0	55.0	0.33

Both SSC and turbidity presented higher values at stations located on the Planalto than stations located in Pantanal (for both minimum, medium and maximum values). This difference occurs since sediment production processes are intensified in the Planalto region due to steeper slopes, land use and soil type. In the Pantanal, the extremely flat topography favours deposition processes, resulting in lower suspended sediment concentrations.

Regarding linear correlations, Planalto stations present strongest positive linear relationships between SSC and turbidity, while linear correlations are lower in Pantanal stations, and in some cases negative. Sari et al. (2015) observed negative linear correlations between Turbidity and SSC for concentrations below 50 mg/L, i.e. lower values of turbidity would be associated with higher concentrations of sediments, which does not reflect reality. According to the authors, linear adjustments are limited to concentrations equal to or greater than 50 mg/L. For smaller values, second-degree polynomial functions would be necessary to determine the SSC through turbidity.

According to Sari *et al.* (2015), in basins characterized by spatial variability in geology, soils and land cover, the characteristics of sediments that reach the rivers are heterogeneous, representing a mixture of materials from different origins and resulting in more complex relationships. However, if the properties of the sediment particles are constant, the relationship between turbidity and SSC may be linear.

These characteristics are observed at all the 23 analysed stations. The stations located in the upstream parts of the basin show stronger linear relationships between SSC and turbidity while the stations downstream, in the Pantanal, have lower linear correlation coefficients, indicating relationships of more complex degrees. This could be due to great spatial variability of soil and land use characteristics and the flat topography in the Pantanal which favours deposition, leading to low turbidity and SSC.

The complex hydrologic system and the great heterogeneity in the UPRB endorse the choice of a spatial approach to estimate SSC within the rivers of the basin, with the use of qualitative variables to characterize spatial variations and quantitative variables to characterize temporal variations, as well as the use of ANN, which are models with high approximation capacity of complex and non-linear relationships.

3.4.2. ANN models for estimation of SSC in the UPRB

Thirteen regional ANN-based models were developed to estimate suspended sediment concentrations in the Upper Paraguay River Basin. From a complete model, other models were tested by leaving variables or groups of variables out and evaluating the final performance of the ANN, in order to establish an understanding of the importance of each variable or group of variables, and to identify the related physical-conceptual causes. The main discussions concern these causes, and how they are best represented for modelling the process, with the purpose of extrapolating to unsampled locations. Tab. 5 presents the performance statistics for the ANN models developed to estimate the suspended sediments concentration in the Upper Paraguay River Basin.

Tab. 5 - Statistical performance of ANN models

Model	M01	M02	M03	M04	M05	M06	M07	M08	M09	M10	M11	M12	M13
nni¹	5	4	4	4	4	3	4	4	3	4	3	3	3
Variables excluded	None	Turbidity	Discharge	Rainfall	EWMA of Rainfall	Rainfall and EWMA	Drainage area	Average slope	Soil type	Land use	Soil type and land use	All, except Turbidity	All, except Turbidity and Discharge
Training													
E_a(mean)	39.29	72.98	51.10	51.41	54.16	57.23	52.58	51.77	49.88	50.93	63.16	87.70	84.66
NS	0.943	0.499	0.822	0.825	0.774	0.742	0.813	0.818	0.828	0.819	0.748	0.511	0.519
Verification													
E_a(mean)	41.21	78.14	69.70	49.24	67.29	69.16	51.01	50.84	49.20	49.91	63.99	81.55	79.96
NS	0.854	0.419	0.612	0.781	0.689	0.512	0.783	0.781	0.772	0.774	0.628	0.382	0.404

¹ Number of neurons in inner layer

The NS efficiency coefficient ranged from 0.499 to 0.943 during training and from 0.382 to 0.854 during the verification. We observed that the other performance parameters, constituted by error statistics, always presented values consistent with those of NS, with smaller errors for larger NS, and larger errors for smaller NS. A number of the models were considered at least “good”, according to the classification of Moriasi et al. (2015) for sediment models ($NS > 0.70$), both in training and in verification.

The first model (M01), in which all input variables were included, resulted in the best performance among all the performed tests, with NS of 0.943 during training, and NS of 0.854 during verification (“very good”, according to Moriasi et al. 2015) and lower error statistics ($E_a(\text{mean})$ of 39.29 mg/L during training and 41.21 mg/L during verification), in comparison with the other models. In Fig. 11, the distribution of errors and the approximation of observed and simulated data for this model in training and verification are presented.

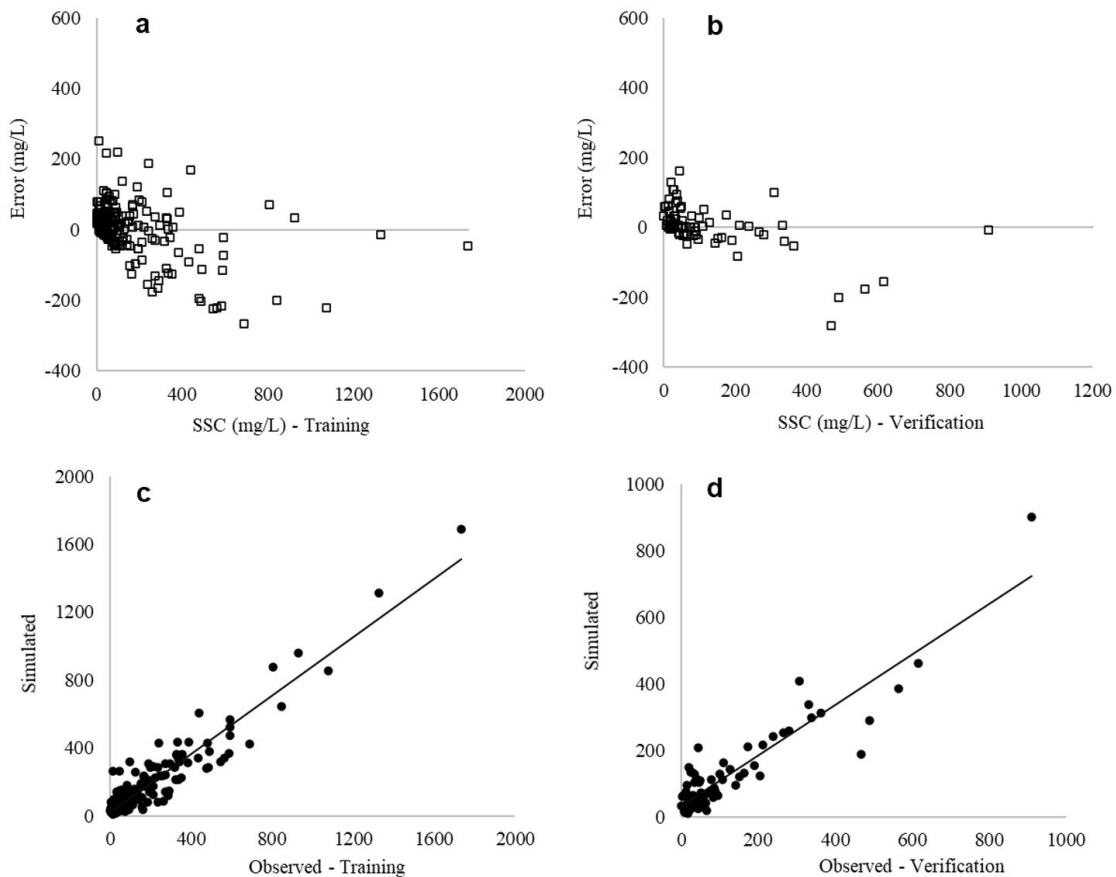


Fig. 11 - Verified error between the calculated and observed SSC values (a, b) and observed and calculated SSC in relation to the ideal fit (c, d), from model M01

The M02 model, in which turbidity was left out, presented a considerable reduction in performance ($NS=0.419$ and $E_a(\text{mean})=78.14$ mg/L during verification, therefore “not satisfactory”) compared to M01 (and also compared to most of the other models), showing that

turbidity is a very important variable for the main model. However, in the simplest models, in which only turbidity was used as an input (M12), or turbidity and discharge (M13), the performance for the verification sample was also “not satisfactory” (NS=0.382 and $E_a(\text{mean})=81.55$ mg/L). This confirms that the accuracy of the model for heterogeneous regions depends on the combination of several variables, not only turbidity.

The M03 model showed a reduction in performance statistics (only “satisfactory” for the verification sample, with NS=0.612 and $E_a(\text{mean})=69.70$ mg/L), lower than that of the M02, but also quite significant, which means that discharge is also important for the models.

The model in which the EWMA of past rainfall (M05) was excluded showed worse results than the model in which daily rainfall data were excluded (M04). The NS coefficient of 0.689 and $E_a(\text{mean})$ of 67.29 mg/L were observed for M05 (only “satisfactory”), and the NS coefficient of 0.781 and $E_a(\text{mean})$ of 49.24 mg/L for M04 (“good”), both with the verification sample.

The model without the inclusion of any rainfall data (M06) showed even greater errors and an NS coefficient of 0.512 with the verification sample, discouraging its use. This result shows that the rain data, mainly the transformations using exponential moving average are fundamental to obtain more accurate SSC estimates in the UPRB.

In models M07 to M10, qualitative variables were excluded, one at a time. Both models presented a small performance reduction within error statistics and NS coefficient, in relation to the complete model (M01), but keeping “good” performances (NS > 0.75 in the training and the verification). However, when more than one qualitative variable was left out, the reduction in the model's performance with the verification sample became substantial, as observed in the M11 model (NS=0.628 and $E_a(\text{mean})=63.99$ mg/L), without soil type and land use and cover, classified as only “satisfactory”. These results also confirmed the importance of qualitative variables.

For future use, we have made available in Appendix 1, a table containing turbidity data from various stations along the UPRB converted into SSC using the main model developed in this research.

3.5. Conclusions

We investigated the capacity of regional models to extrapolate SSC to ungauged basins in a heterogeneous region, using quantitative variables (turbidity, flow, precipitation and EWMA of past rainfall) to represent temporal variability in each basin and qualitative variables (drainage area, soil type, land use and mean catchment slope) to represent spatial variability.

Using ANN-based regional models, applied to the Brazilian part of the Upper Paraguay River Basin (362 380 km²), we provided unprecedented answers to questions regarding not only the possibility to extrapolate SSC, but also the relative importance of the variables for modelling.

A complete model, with all qualitative and quantitative variables, proved to be adequate for predicting SSC, obtaining “very good” performance classification. However, models using only turbidity and discharge proved unsuitable for extrapolation to other basins, resulting in “not satisfactory” performances. On the other hand, the exclusion relative to the complete model of only one of these variables resulted in “not satisfactory” and “satisfactory” classifications, respectively, which confirmed their importance when used in conjunction with the other variables. The exclusion of rainfall, in turn, especially the EWMA of past rainfall variable, resulted in models with only “satisfactory” classification, confirming the importance of precipitation, which ultimately is the main agent of the hydro-sedimentological processes.

Regarding the importance of the qualitative variables, the models were still capable of achieving “good” performances when any of these variables were excluded individually. However, “good” classifications were not achieved if soil type and land use and cover were excluded simultaneously.

We have shown that it is possible to estimate SSC in ungauged heterogeneous basins with “very good” performance, as long as turbidity and flow measurements are available, in combination with data from satellite products, including spatially varied data (drainage area, soil type, land use and mean catchment slope) and rainfall data.

4. ARTIGO 2 - Modelling and Assessing How Small Hydropower Facilities Affect Sediment Transport by Using Fuzzy Inference Systems

Este capítulo trata da avaliação e compreensão dos efeitos de pequenos empreendimentos hidrelétricos no transporte de sedimentos da BAP. Os efeitos foram modelados por meio de sistemas de inferência fuzzy, e as regras desses sistemas foram utilizadas interpretações posteriores. A principal contribuição desse capítulo é a identificação de algumas relações entre o efeito causado por pequenas barragens no transporte de sedimentos e outras variáveis relacionadas às características da bacia hidrográfica, características da barragem ou variações hidrológicas. Foi desenvolvida uma metodologia original, baseada em sistemas de inferência fuzzy, cuja pesquisa de conhecimentos sobre como essas variáveis interferem e/ou interagem com as alterações sedimentológicas causadas pelas barragens foi realizada por meio da interpretação das regras dos SIFs.

O presente capítulo também é apresentado em inglês, e baseia-se no segundo artigo científico desta Tese de doutorado, publicado na revista *Journal of Hydrology* (janeiro de 2023): CAMPOS, Juliana Andrade; PEDROLLO, Olavo Correa. **Modelling and assessing how small hydropower facilities affect sediment transport by using fuzzy inference systems.** v620, 129374, 2023. <https://doi.org/10.1016/j.jhydrol.2023.129374>.

Abstract

Small dams for power generation are increasingly being built around the world, and the reported impact caused by these structures on sediment transport varies widely, ranging from substantial to minimal or non-existent alterations among different dams. Such variability is still poorly understood. In this study, we present an original application of fuzzy inference systems (FIS) to extract knowledge concerning the effect of small dams on sediment transport, providing understandings of how different variables related to watershed characteristics, dam characteristics and hydrological variations can affect sedimentological responses of these structures. Numerous small dams have been built, and many more are in development or proposed, in rivers that drain into the Pantanal, a world-renowned tropical wetland, where we apply the methodology. Data on 23 hydropower facilities from the uplands of the Pantanal region were used, with a total of 535 records. The models presented very good results (NS equal to 0.92 for the most detailed FIS model) and provided a better understanding of the phenomenon through their explicit linguistic rules. The upstream suspended sediment concentration (SSC) is the most determinant variable for the alteration caused by dams. Higher SSC entering the reservoir is related to higher sediment retention. Vegetation cover and soil type of the drainage area of dams also influence the alterations on SSC caused by these structures. Dams located in basins with greater vegetation cover tend to affect less sediment transport, and dams located in basins with high percentages of agriculture and pasture tend to alter more. FIS models also confirmed that the size of dams is directly proportional to their capacity to alter sediment transport. The methodologies developed for the interpretation of fuzzy rules proved to be useful for assessing how small dams affect sediment transport along river systems.

Keywords

suspended sediment concentration; small dams; fuzzy association rules; data mining; Pantanal

4.1. Introduction

Dams are known for causing severe effects on hydrologic, geomorphic, and ecological systems (Brandt, 2000; Nilsson et al., 2005). The barrier caused by dams disrupts the longitudinal connectivity of the river, causing discontinuities in the flux of sediment and nutrients, and blocking the upstream mobility of migratory fishes (Nilsson e Svedmark, 2002; Fantin-Cruz et al., 2016; Campos et al., 2020). Concerning sediment transport, the effects of large flow-regulating dams are well documented (Erskine, 1985; Dai e Liu, 2013; Wang et al., 2018; Wei et al., 2021), however, less attention has been given to the impact of smaller dams, even though they are the most common type of dam being built around the world (Fantin-Cruz et al., 2020; Casserly et al., 2021; Magilligan et al., 2021), especially in tropical rivers (Chong et al., 2021).

Some studies suggest that even run-of-river and small storage capacity dams may affect the sediment transport and the channel morphology, causing sedimentation upstream and, in some cases, erosion downstream of the dams (Wildman e MacBroom, 2005; Csiki e Rhoads, 2010; Baker et al., 2011; Couto e Olden, 2018). However, they are commonly considered to be much less environmentally harmful than larger dams and, therefore, many countries established policies that promote small hydropower (SHP) facilities, with minimal environmental reviews (Couto e Olden, 2018; Fantin-Cruz et al., 2020).

Relatively few studies have investigated the effects of smaller dams on sediment transport (Csiki e Rhoads, 2010; Fantin-Cruz et al., 2020; Casserly et al., 2021; Magilligan et al., 2021), and the impact reported in these studies varies widely, ranging from substantial (Wildman e MacBroom, 2005; Orr et al., 2006; Baker et al., 2011; Fantin-Cruz et al., 2020; Casserly et al., 2021) to minimal or non-existent alterations among upstream and downstream of these structures (Lindloff, 2003; Ashley et al., 2006; Velinsky et al., 2006; Csiki e Rhoads, 2014). Such variability is still poorly understood and depends on the watershed characteristics, the sediment supply, the rainfall patterns, the characteristics of the dam and the capacity of river hydraulics to transport sediment over the dam (Csiki e Rhoads, 2010).

In the Upper Paraguay river basin (UPRB), specifically in the upland watersheds that drain into the Pantanal floodplains, the largest wetlands of the world, there is a great environmental concern regarding the increase in SHP facilities being built over the last few years. There are 55 hydropower facilities in operation (mostly SHP), with an additional 138 projects under construction, planned, proposed, or identified by the government as prospective sites (Oliveira et al., 2020). In the last two years, some studies have investigated the possible

effects of these small dams on the Pantanal tributaries, including hydrological effects (Ely et al., 2020; Jardim et al., 2020; Figueiredo et al., 2021), effects on sediment transport (Fantin-Cruz et al., 2020), nutrient transport and water quality (Silva et al., 2019; Oliveira et al., 2020), and fish and fisheries (Campos et al., 2020).

Fantin-Cruz et al. (2020) analysed the suspended and bedload sediment transport upstream and downstream of 29 current hydropower facilities in the uplands of the UPRB. The results indicated great variability among the analysed facilities, including retention, null alteration, and release of sediment in some cases. Bedload sediment transport was a small component of total sediment transport, representing less than 10% in most cases. In addition, a predictive model using artificial neural networks (ANN) estimated the impact of 80 future SHPs on suspended sediment transport based on observations at current facilities. The prediction indicated that the future SHPs would reduce the suspended sediment transport by ~62% towards the Pantanal wetland.

Another important research related to sediment transport in the UPRB is Campos and Pedrollo (2021). This study presented an ANN-based model to estimate suspended sediment transport in ungauged basins within the UPRB, by using qualitative variables that physically characterize the watersheds (soil type, land use, drainage area and mean catchment slope), and quantitative variables to represent temporal variability of the sediment transport (turbidity, discharge, and previous rainfall). This study highlighted the wide variation in the sediment transport among the watersheds of the UPRB, which is a consequence of its complex hydrological system and the great heterogeneity between the uplands and the floodplains of the Pantanal. This study provided information about the most important variables related to the variations of sediment transport in this region, which can be useful for understanding the variations of the effects from different small dams.

AI models have been successfully applied to sediment transport estimations, such as ANN models (Jain, 2001; Atieh et al., 2015; Sari et al., 2017; Gholami et al., 2018; Campos e Pedrollo, 2021; Jimeno-Sáez et al., 2022), Fuzzy rule-based models (Kisi e Shiri, 2012; Buyukyildiz e Kumcu, 2017; Sirabahenda et al., 2017; Shoaib et al., 2018; Kumar et al., 2019; Teixeira et al., 2020), and genetic programming (Aytek e Kişi, 2008; Kisi et al., 2012; Yadav et al., 2018). However, these studies generally are focused on obtaining high and accurate performances for the estimations.

Although the study of Fantin-Cruz et al. (2020) provided important information regarding the effects of current and future SHPs in the UPRB, a gap still remains concerning

how different watershed characteristics, dam characteristics and hydrological variations affect the sedimentological responses caused by the dams. In order to overcome this gap, an alternative way to assess these effects could be achieved by using data from the most important variables related to the sediment transport in this region, as well as dam characteristics, and applying artificial intelligence (AI) models focused on discovering knowledge or detecting patterns within data (data mining). So far, studies applying AI models on data mining or discovering knowledge about sediment transport in rivers and the effects of small dams were not found in the present literature.

Fuzzy Inference Systems (FIS) are considered universal approximators, meaning that they can be designed to approximate any continuous function with any chosen precision (Hornik et al., 1989; Wang, 1992). These models can also be used as a tool for understanding data and their relationships. The main advantage of FIS models is their similarity to human reasoning (Kaya e Alhaji, 2003), providing human-friendly representation through their linguistic variables and explicit fuzzy association rules (Lucchese et al., 2021). The existence of explicit rules and linguistic descriptions provide interpretability to FIS models and therefore provide a better understanding of the physical behaviour of the system (Guillaume, 2001; Pancho et al., 2013; Lucchese et al., 2021).

Therefore, the aim of our research is to use FIS models for modelling the effects of current small hydroelectric facilities on suspended sediment transport within the UPRB, focusing mainly on their ability to discover knowledge and patterns within data. For this, we propose to experiment FIS models focusing on capturing relationships through the fuzzy association rules, regarding how different watershed characteristics, dam characteristics and hydrological variations affect the sedimentological responses of these dams. This objective requires the development of original methodologies for the interpretation of fuzzy rules.

4.2. Materials and methods

4.2.1. Study area and hydroelectric facilities

This study was carried out on the rivers of watersheds that feed the Pantanal wetland, in the Upper Paraguay River Basin (UPRB). In the last decades, this region has seen the number of hydroelectric facilities grow rapidly, and currently has hundreds of projects being considered for the future (Fig. 12).

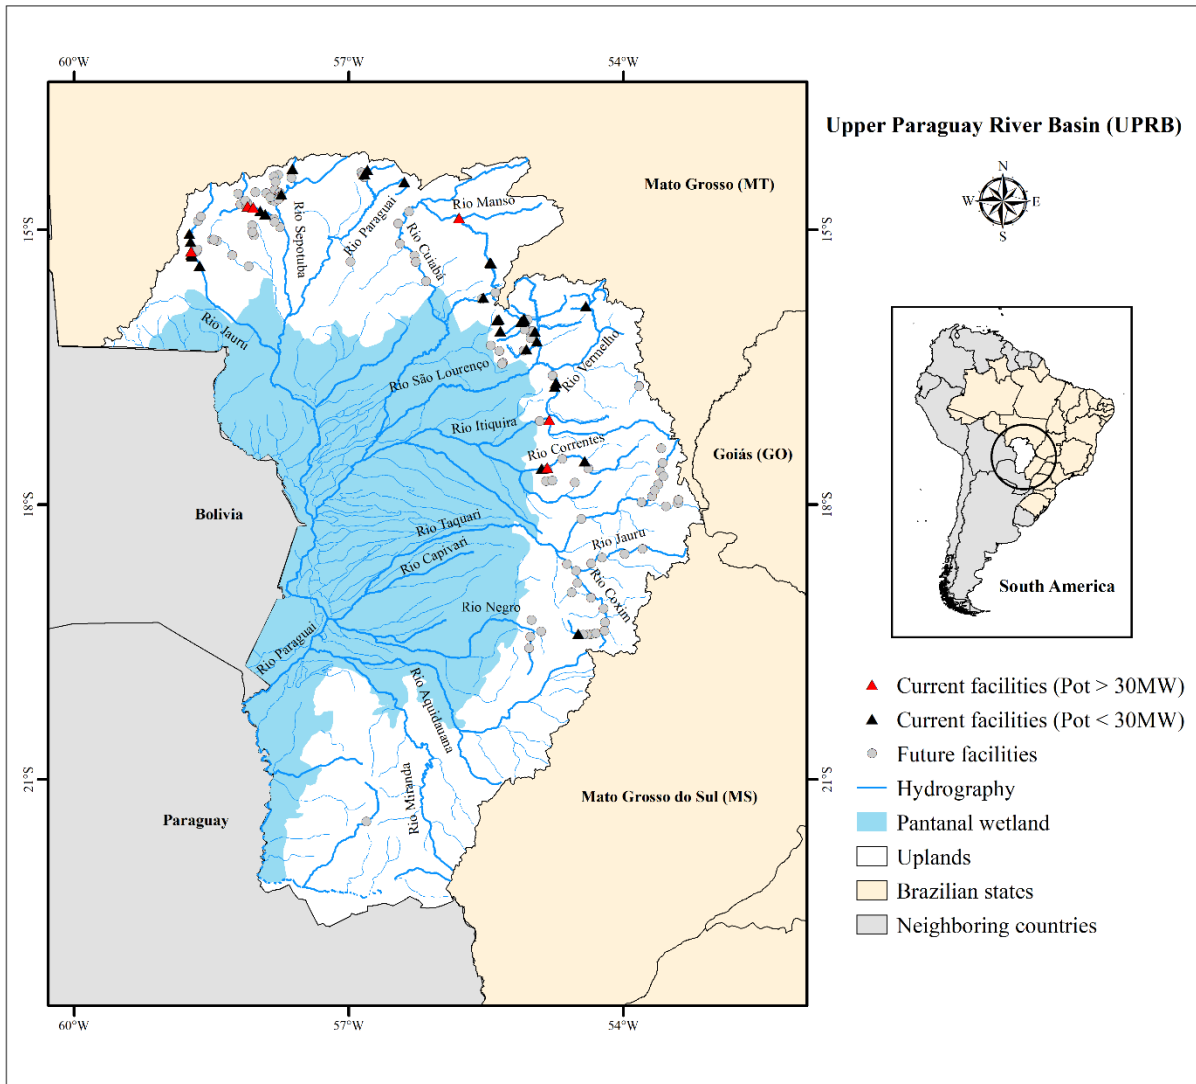


Fig. 12 - Study area and hydroelectric facilities in the Pantanal watershed

In Brazil, hydropower plants are classified as small when they have installed electrical generation capacities of less than 30 MW. In the UPRB 55 hydroelectric facilities are operating, of which 48 are categorized as small hydropower plants (SHPs - installed capacity < 30 MW) and 7 as large hydropower facilities (LHPs - installed capacity > 30 MW). More than half of the facilities are designed as run-of-river, which generally have little storage, and the rest are designed with conventional storage (ANEEL, 2022).

The UPRB has two distinct regions with different topographic and hydrological characteristics: the uplands and the Pantanal floodplains.

The uplands (altitudes ranging from 150 m to 1400 m) are situated mainly in the north and east of the Pantanal, representing 59% of the basin area. This region comprises deep soils and high slopes, favouring rapid drainage and high sediment production. The native vegetation is the Cerrado, a type of savannah, but extensive areas were converted to agriculture or pasture.

Currently, 29% of the upland watershed area is being used for agriculture and 22% for pasture. Problems regarding water quality mostly involve diffuse pollution by soil erosion and agrochemicals from agriculture, as well as local pollution by wastewater effluents, usually in urban areas (Oliveira *et al.* 2020).

The Pantanal floodplain comprises 41% of the basin area and presents altitudes below 150 m. This region has complex hydraulic and hydrosedimentological dynamics due to the low, flat, and humid lands, and the low riverbanks, which make the drainage system unable to quickly transmit the water received from the uplands (Campos e Pedrollo, 2021).

The Pantanal is globally recognized as an important wetland ecosystem that contains unique aquatic habitats and landscapes, with several endangered mammals and birds (Tomas *et al.*, 2019). The major economic activities within the Pantanal are cattle ranching, subsistence and recreational fishing, and ecotourism (Fantin-Cruz *et al.*, 2020).

According to the Köppen-Geiger climate classification, the climate of the UPRB is tropical savanna, with rainfall concentrated in the summer. The annual average precipitation in the UPRB ranges from 1200 to 1600 mm, with the highest values occurring in the uplands. About 80% of the annual rainfall occurs in the rainy season from October to April (Campos e Pedrollo, 2021). Regarding evapotranspiration, the UPRB presents high values, about 85% of the annual average precipitation (ANA, 2018).

4.2.2. Data sources

We selected 23 current hydropower facilities within the uplands of the UPRB for this study, based on availability of upstream and downstream SSC data. The characteristics of the selected hydropower facilities are shown in Tab. 6.

From the selected facilities, 18 are considered SHPs and 5 exceed 30 MW (LHPs). However, the large facilities selected have dams and reservoirs similar in size to the SHPs, and one of the SHPs (São Lourenço, 29 MW) creates a reservoir comparable in size to the facility with the highest installed capacity (Ponte de Pedra, 176 MW). Therefore, all the analysed facilities are considered small in this study, which of 13 are run-of-river dams and 10 are conventional storage dams.

We used data on SSC and flow sampled upstream and downstream of the hydroelectric facilities. Most of the data used in this research were collected on 13 dates spanning the wet and dry seasons, from October 2018 to May 2019. Data from reports submitted by hydropower

companies to the state environmental agencies were also included, ranging from 2003 to 2019. The sample collection and analysis of SSC and discharge, as well as the characteristics of current and future hydropower facilities, were provided by the Brazilian Corporation for Agricultural Research (EMBRAPA), and the Federal University of Mato Grosso (UFMT) through a project funded by the Brazilian National Water Agency and the Eliseu Alves Foundation. More detailed descriptions of the sample collection and analysis are found in Fantin-Cruz *et al.* 2020.

Overall, the selected facilities have a minimum of 10 pairs of data (which means data on SSC and flow upstream and downstream of the hydroelectric facilities measured on the same date), but several have more pairs of data. In total, we used 535 pairs of data. Data regarding the facility characteristics; reservoir area, reservoir volume and detention time, and data regarding the facility watersheds, such as drainage area, land use and land cover, soil type and rainfall were also employed.

Tab. 6 - characteristics of the selected hydropower facilities

	Name	Sub-catchment	Drainage area (km ²)	Reservoir volume (dam ³)	Pot (MW)	Design	SSC records
1	Ponte de Pedra*	Itiquira river	4000	111000	176	Conventional	47
2	Itiquira*	Itiquira river	5137	4800	157	Run-of-river	45
3	Jauru*	Jauru river	2620	20140	122	Run-of-river	36
4	Juba I*	Juba river	1550	4700	42	Run-of-river	21
5	Juba II*	Juba river	1808	9400	42	Run-of-river	22
6	São Lourenço	São Lourenço river	5775	100630	29	Conventional	28
7	Indiavaí	Jauru river	2320	2050	28	Conventional	16
8	Pampeana	Juba river	2057	40300	28	Conventional	27
9	Graça Brennand	Juba river	1974	64400	27	Conventional	40
10	Rondonópolis	São Lourenço river	1767	146	27	Run-of-river	10
11	Ombreiras	Jauru river	2207	49360	26	Conventional	35
12	José Gelásio	São Lourenço river	1698	2100	24	Run-of-river	18
13	Sete Quedas Alta	São Lourenço river	392	1600	22	Conventional	19
14	Antônio Brennand	Jauru river	1590	420	21	Conventional	22
15	Figueirópolis	Jauru river	2960	34936	19	Run-of-river	24
16	Salto	Jauru river	2657	3300	19	Run-of-river	26
17	São Tadeu	Aricá Mirim river	256	3660	18	Conventional	19
18	Santana 1	Santana river	804	5150	15	Run-of-river	12
19	Água Prata	São Lourenço river	333.7	4	13	Conventional	11
20	Jonas Pinheiro	São Lourenço river	26	5532	6	Run-of-river	13
21	Sucupira	São Lourenço river	356	240	5	Run-of-river	19
22	Diamante	Santana river	564	750	4	Run-of-river	14
23	Poxoréu	Poxoréu river	1340	270	1	Run-of-river	11

* Large hydropower facility (installed capacity > 30MW)

The land use and land cover in the UPRB was based on the Mapbioma project. This project is a multi-institutional initiative to annually map the coverage and use of land in Brazil and monitor changes in the territory (Souza et al., 2020). Since most of the SSC data were

collected between 2018 and 2019, the map was made using images from 2019 taken by the Landsat 8 satellite, with a spatial resolution of 30 m.

The soil types of the UPRB were characterized by following the Brazilian soil type map at a scale of 1:5 000 000 (Santos et al., 2018). Initially, the Brazilian soil map had 13 classes for the UPRB. All the previous classes were simplified into five classes: “Water Bodies”, “Sandy Soil”, “Medium Soil”, “Clayey Soil”, and “Outcrop”. In Fig. 13, the final maps of the land use and cover, and the soil type of the UPRB are presented.

Precipitation data was taken from the MERGE product, which is a combination of observed rainfall data and satellite information, made available to all of South America. The MERGE data come from the Brazilian National Institute of Space Research (CPTEC/INPE).

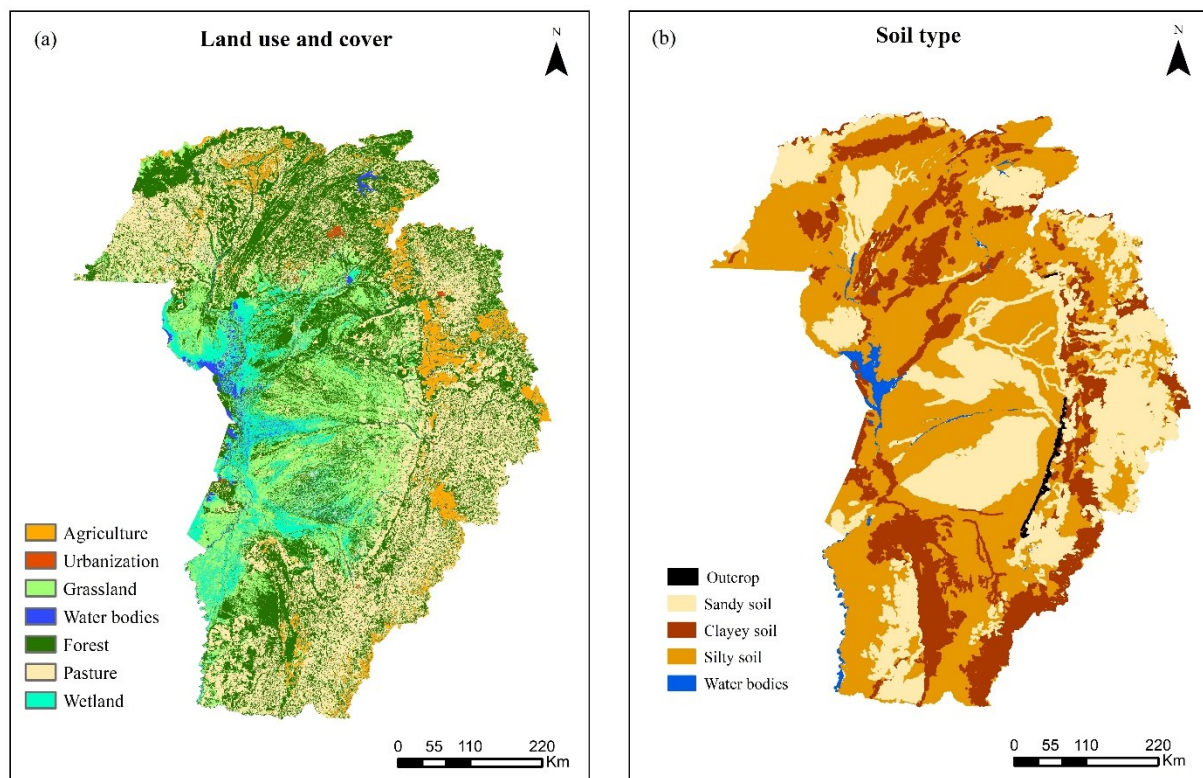


Fig. 13 - Land use and cover (a) and soil type (b) in the Upper Paraguay River Basin

The MERGE product uses rainfall data estimated by remote sensing to fill in rainfall information in locations with insufficient *in situ* monitoring. Daily and hourly data are available in grids of 10 km. Further details can be found in (Rozante et al., 2010). The daily MERGE data were downloaded for the period January 2003 to July 2019, which encompasses the data period of the SSC and flow measurements. Then, the precipitation data were extracted for the drainage area of the facilities.

4.2.3. Modelling and data mining

A summary of the methodological framework used in this research is presented below (Fig. 14). First, we selected several variables that are directly and indirectly related to the sediment transport in the UPRB, and variables related to the characteristics of the hydroelectric facilities. Mamdani Fuzzy Inference Systems were used to model the effects caused by small dams over the sediment transport, and to provide information on the variability of these effects by taking advantage of the inherent interpretability of these models. The knowledge discovery/data mining was performed by an original methodology developed in this research to assess fuzzy associative rules. All models and procedures were custom programmed in Matlab® R2012b, which favours occasional improvements to the methods.

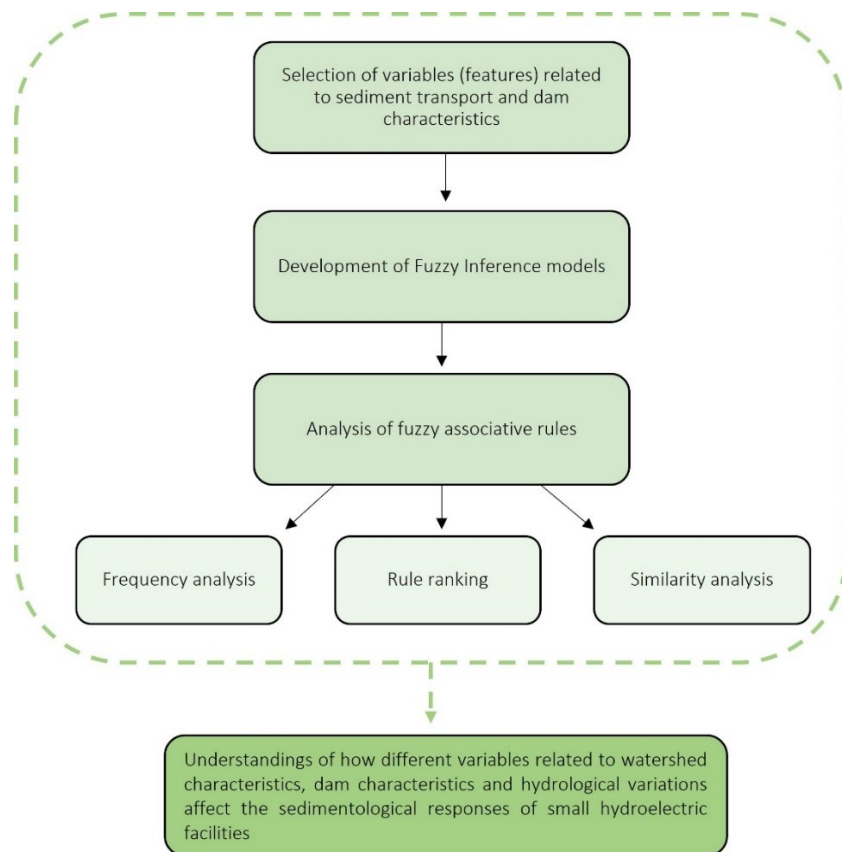


Fig. 14 - Methodological framework

4.2.3.1. Input and output model variables

The selection of input variables was based on previous studies of sediment transport and small dams within the UPRB (Fantin-Cruz et al., 2020; Campos e Pedrollo, 2021). We selected several variables related to watershed characteristics, dam characteristics and hydrological

variations to represent the great variability of the sediments in the region, aiming to research how the facilities in this region variably affect the sediment transport. 535 pairs of data on SSC and flow upstream and downstream of the 23 studied facilities were used. The output variable was the alteration of SSC, given by the following equation:

$$\text{Alteration of SSC} = \text{downstream SSC} - \text{upstream SSC} \quad (1)$$

where the values of SSC are given in mg/L, and the Alteration of SSC can assume negative and positive values, depending on retention or release of sediment.

Variables related to the watershed characteristics of each dam comprise watershed area (km²), land use/cover (only the forest, grassland, pasture, and agriculture classes) and soil type (only the sandy soil, silty soil, and clayey soil classes). The classes of urbanization, water bodies and wetlands of land use/cover, and classes of outcrop and water bodies of the soil type were not included in the models. Wetlands and water bodies mostly occur in the floodplain, and since the SHPs are in the uplands, these classes are not relevant to the models. Outcrops and urbanization appear only in specific small parts of the basin and represent less than 0.01% of the area of the study region, therefore, they are also not relevant to the models. The selected classes of soil type and land use/cover were included as proportions of the basin area. Each class of soil type and land use/cover was included in the models as an input variable.

Regarding dam characteristics, we used data on reservoir area (km²), reservoir volume (dam³) and detention time (days). The detention time was calculated by the following equation:

$$\text{Detention time (days)} = \frac{\text{Reservoir volume (m}^3\text{)}}{\text{Inflow (m}^3\text{/s)} \times 86400} \quad (2)$$

Furthermore, we used inflow (m³/s), exponentially weighted moving averages (EWMA) of past rainfall (mm) and upstream SSC (mg/L) as input variables. These variables refer to the hydrological variations, which can influence the sedimentological responses of the dams.

The EWMA of past rainfall has been used in several studies involving data-driven models and sediment transport (Oliveira et al., 2017; Teixeira et al., 2020; Campos e Pedrollo, 2021) and provides better estimates than those obtained using only rainfall data without this resource. The EWMA of past rainfall assigns greater weight to more recent precipitation in the composition of the moving average, promoting a synthesis of recent precipitation information in the form of a representative value. The EWMA is applied to precipitation time series with constant intervals, according to Equations (3) and (4):

$$EWMA_t = (1 - \alpha) EWMA_{t-1} + \alpha P_t \quad (3)$$

$$\alpha = 1 - 0.5^{(1/h)} \quad (4)$$

where P_t is the precipitation at time t , and h is the half-life parameter, given in days.

The EWMA was applied to the precipitation data obtained from the MERGE product for the 23 watershed areas of the analysed SHPs. We used EWMA of rainfalls with the half-life parameter $h=1$, which means that a resulting value of the EWMA of rainfall gives 50% importance weight to the current day value, and 50% to past days, decreasing exponentially towards the past. Higher values of the half-life parameter will give greater weight to past rains. Overall, the EWMA of past rainfall is a function that can represent single rainy days as well as long rainy periods. The value of the half-life parameter was chosen from a preliminary analysis of linear correlations between the time series of EWMA of rainfalls and upstream SSC of the dams. We tested different half-life parameters and $h=1$ day showed the strongest linear correlation with the upstream SSC variable.

Fig. 15 presents a summary of the input variables selected to estimate the alteration of SSC (the output variable) among the hydroelectric facilities within the UPRB. The entire dataset is available in the supplementary files.

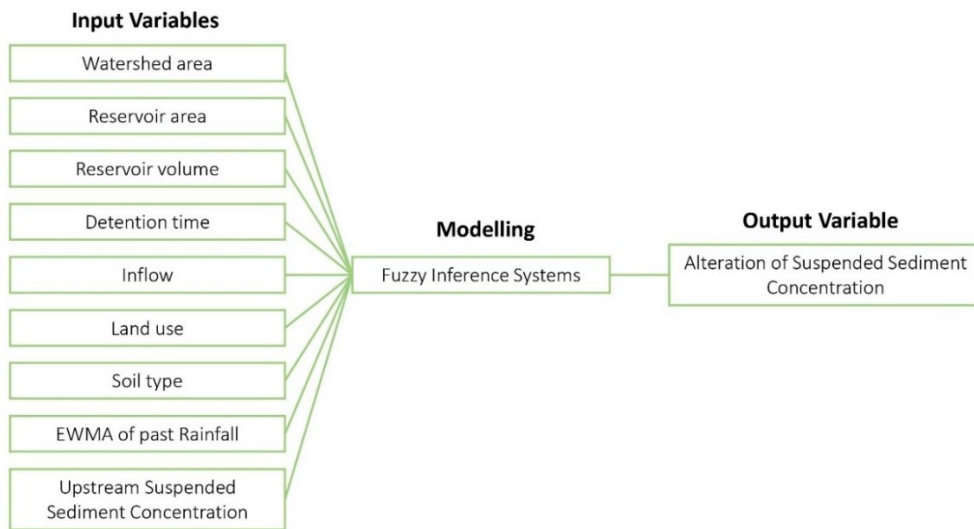


Fig. 15 - Summary of the selected input and output variables

4.2.3.2. Partition data

For the modelling stage, data were divided into three samples: training, validation, and verification. The dataset was divided by selecting data from 2/4 of the facilities for the training, 1/4 for the validation, and 1/4 for the verification. Facilities with extreme values (maximum and minimum) were included in the training samples. To provide spatial balance, facilities from different sub-catchments were included in both training, validation, and verification samples.

4.2.3.3. Fuzzy model design

A fuzzy inference system is a qualitative modelling scheme in which the system behaviour is described by using natural language (Lohani et al., 2007). Mamdani fuzzy inference systems (Mamdani, 1977) are the most comprehensible and interpretable FIS due to their linguistic terms in the antecedent and in the consequent, maintaining verbal formalization during their whole inference process (Casillas, 2003). The Mamdani FIS are generally composed of the following components (Lucchese et al., 2021): (1) fuzzification of the input and output variables; (2) a rule base or knowledge base; (3) fuzzy inference mechanism; and (4) defuzzification of the fuzzy output into a crisp number (Fig. 16).

The fuzzification process is performed through membership functions (MFs), which can be designed in different formats, such as triangular, sinusoidal, or trapezoidal. All the MFs have a prototype, which is the point where the fuzzy set achieves maximum membership value, corresponding to the point where the next fuzzy sets have a null membership value (MV). Through the MFs, each variable belongs to a maximum of two fuzzy sets, whose sum of values always results in 1 (Lucchese et al., 2021).

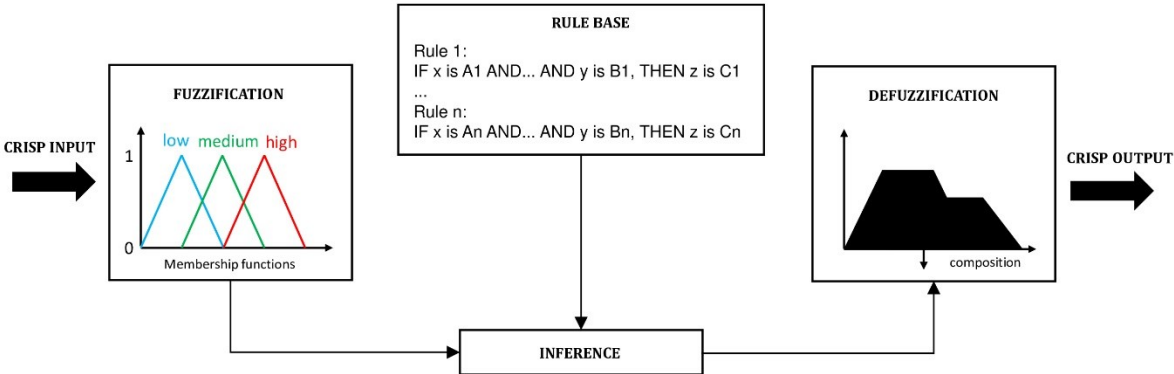


Fig. 16 - Scheme of the general Mamdani FIS structure

The rule base is the most important aspect of a FIS design since the interpretability and accuracy of the model heavily rely on it. Fuzzy rules are simple relations between fuzzy

variables, e.g., “IF x is low THEN y is high”, where “low” and “high” are labels of fuzzy sets, and “ x ” and “ y ” are crisp values (Zadeh, 1973).

The rule base can be designed through expert-driven approaches or data-driven approaches. Among the data-driven approaches, many algorithms have been developed in the last decades, from simple and non-iterative methods which generate complete linguistic rules from data (Wang e Mendel, 1992) to methods based on computational intelligence, such as adaptative-network-based fuzzy inference systems (Jang, 1993), fuzzy wavelet networks (Ho et al., 2001), and support vector machine FIS (Jeng e Lee, 1999). Although advanced data-driven approaches for rule base designs tend to increase the accuracy of the model, they make it more difficult to interpret the system (Chen et al., 2018).

The fuzzy inference mechanism refers to the fuzzy implication methods and the fuzzy composition operators. After the fuzzification of crisp data, rules are fired for each membership degree and the implication method is performed to evaluate the rules and produce output fuzzy values; the implication of the fired rules are aggregated to finally obtain the fuzzy output. Then, the fuzzy output is converted into a specific value; this process is carried out by the defuzzification process through multiple options, such as centroid of area or bisector of area (Matía et al., 2011).

FIS are mainly characterized by two features that assess the quality of the obtained model (Zadeh, 1973): (i) interpretability – which refers to the ability of the FIS model to express the behaviour of the system in an understandable way; (ii) accuracy – which refers to the ability of the FIS model to faithfully represent the modelled phenomena, with high precision.

Interpretability and accuracy are contradictory issues and achieving both criteria with a high degree is a difficult task (Pancho et al., 2013). However, FIS offer the possibility of trading these features, until the desired trade-off is achieved (Dutu et al., 2018), although, when concerning the applications within the hydrological sciences, more priority has, until now, been given to the accuracy of the models to provide good numerical estimations.

We developed five FIS models with different fuzzy sets, ranging from three to seven fuzzy sets, to obtain both precise and interpretable FIS models. We used the inference method proposed by Mamdani (1977) due to its fuzzy output set, which provides more interpretability. The rule base was generated from data, based on the approach presented by Wang and Mendel (1992), which consists of fuzzification, assigning rules and assigning weights to the rules by multiplying the membership values of the variables that generated the rule. After this process, extra rules can be added by the expert. However, unlike the original method, we kept rules that

indicate the same inputs but different outputs, to provide an interpolation for these cases, and, therefore, an intermediate position between two conceptual responses. Instead of eliminating the conflicting rule with the least weight, all of them are maintained, but with their weights multiplied by the relative frequency of the number of records that contributed to each conflicting rule. Thus, conflicting rules incorporate frequency, and less frequent rules tend to have their values reduced.

After the generation of the fuzzy rules, adaptive training (Teixeira et al., 2020; Lucchese et al., 2021) was also used, which consists of optimizing, by trial, the types of functions and the values of their prototypes, to find the best fit to the outputs (by searching the lowest quadratic error). The possible modification of the membership functions was to triangular, sigmoidal, trapezoidal, and exponential. The values of the prototypes were tested in partitions of 1/20 spacing between the adjacent prototypes, to maintain the physical meaning of the verbalization adopted for each fuzzy set.

The training procedures (generation of rules and adaptive training) were performed using the sample selected for training. The validation sampling was used at the end of the adaptive training as a criterion for accepting the results to favour the model's generalization capacity.

4.2.3.4. Performance evaluation of the models

The performance analysis of both FIS and ANN models were evaluated within the verification sample, by calculating the Nash-Sutcliffe efficiency coefficient (NS), the percent bias (PBIAS) and the mean absolute error (MAE).

The NS is one of the most used performance statistics in modelling, which facilitates comparison with other works. The NS represents the proportion of data variance that is explained by the model (Nash e Sutcliffe, 1970).

The PBIAS measures the average tendency of the simulated data, which may be larger or smaller than the observed tendencies; the ideal PBIAS value is 0. Positive values indicate model underestimation, and negative values indicate model overestimation.

The MAE is also widely used for predicting errors and corresponds to the mean absolute difference between observed and simulated values. The lower its value is, the better the model's performance.

To interpret the quantitative performance of the model via the NS and PBIAS, the classification proposed by Moriasi *et al.* (2015) specifically for sediments was used, in which the model is considered “very good” for $NS > 0.8$ and $PBIAS < \pm 10$; “good” for $0.7 < NS \leq$

0.8 and $\pm 10 \leq \text{PBIAS} < \pm 15$; “satisfactory” for $0.45 < \text{NS} \leq 0.7$ and $\pm 15 \leq \text{PBIAS} < \pm 20$; and “not satisfactory” for $\text{NS} \leq 0.45$ and $\text{PBIAS} > \pm 20$.

4.2.3.5. Feature importance analysis

The relative importance of each input variable was calculated using the recursive feature elimination technique, which consists of excluding one or more input variables from the model and evaluating the model's performance statistics without them.

From a complete FIS model, other models with the same architecture as the complete model were generated, leaving one variable out at a time. The performance statistics (NS, PBIAS and MAE) of the complete model and the models with eliminated features were normalized through the min-max normalization, where the minimum value corresponds to the performance statistics produced by the complete model, and the maximum value corresponds to the values produced by the worst model.

Lastly, the normalized performance statistics were summed and weighted, resulting in the factor of relative importance (FRI), which corresponds to the percentage of the performance reduction of the model in relation to the complete model.

4.2.3.6. Mining fuzzy association rules

Despite the inherent simplicity and interpretability of FIS models, an issue still remains regarding the interpretation of a large number of rules (Lucchese et al., 2021), which generally occur in cases of managing high-dimensional problems with a large number of input variables. Therefore, we developed a technique to interpret a large set of fuzzy associative rules in high-dimensional FIS models.

The analysis and interpretation of FIS rules were performed by three distinct approaches. The first is the analysis of the frequencies of occurrence of each input fuzzy set in each output fuzzy set. The point is to investigate how the inputs, acting as independent variables, relate to each observed result. The second approach is the selection of some rules generated during the FIS training, according to an established criterion. The criterion is based on the weights and occurrences of the rules. Although the weights of the rules indicate the most reliable rules, they do not include the frequency with which each rule will be activated when submitted to a representative set of input-output samples. Therefore, a factor that simultaneously contemplates the weight and frequency of each rule is proposed, to select the most important rule for each

output fuzzy set. Finally, the third approach is carried out by searching for rules similar to each other, in order to identify the differences observed, in both input and output sets.

The fuzzy rule mining was therefore performed through the following steps: (1) Frequency analysis of fuzzy sets; (2) Rule ranking based on a factor; and (3) Similarity analysis of fuzzy rules.

- (1) By using the rules generated for a FIS model, the frequency distribution of each input fuzzy set was calculated for each output fuzzy set. In this way, it is possible to observe which classes of input variables are more frequent in certain types of alterations of SSC caused by small dams. The frequency distribution was calculated by using all samples (training, validation and verification together) since this step no longer involves model calibration, but analysis of the behaviour of the data sample identified by the model.
- (2) The number of times each rule has been activated (hereafter called occurrences) multiplied by its weight is a factor which produces a score for each rule generated previously in the model training. The rules are ordered according to this score, and then a number of rules for each output set are selected for analysis.
- (3) The similarity (number of coincident fuzzy sets) to a chosen rule was used as a criterion for ordering the other rules, whose most similar rules with up to one different variable are analysed. If the output fuzzy set of the other rules is different, it can be verified, from the differences in the input fuzzy sets, which of them caused the difference in the output set. If the output set is the same, it is possible to identify the differences within the input sets that do not change the output. The similarity analysis was performed for some of the best rules of each output fuzzy set, according to the factor score defined in (2).

4.3. Results and discussions

4.3.1. Quantitative performance

Five FIS models were generated with different numbers of fuzzy sets (Tab. 7). All selected input variables are included in the models. The same partition of fuzzy sets is used for the input upstream SSC and the output alteration of SSC, but not necessarily for other input variables.

Tab. 7 - Quantitative performances in the verification sample, and resulting fuzzy sets of the FIS models

Model	Output Fuzzy Sets	Input Fuzzy Sets		Number of rules	MAE (mg/L)	PBIAS (%)	NS
	Alteration of SSC	Upstream SSC	Other input variables				
FIS 01	5 fuzzy sets	5 fuzzy sets	3 fuzzy sets	154	8.4	7.0	0.787
FIS 02	6 fuzzy sets	6 fuzzy sets	4 fuzzy sets	237	7.0	-6.9	0.846
FIS 03	7 fuzzy sets	7 fuzzy sets	3 fuzzy sets	200	6.7	-6.3	0.870
FIS 04	7 fuzzy sets	7 fuzzy sets	5 fuzzy sets	266	6.8	-5.5	0.915
FIS 05	7 fuzzy sets	7 fuzzy sets	7 fuzzy sets	362	6.4	-1.9	0.917

The metrics of the models indicated that FIS models can predict the alterations of SSC caused by small dams with very satisfactory performance when using input variables related to watershed characteristics, dam characteristics and hydrological variations. The FIS 01, where the smallest partition of fuzzy sets was employed, is considered “good”, according to the classification of Moriasi *et al.* (2015) for sediment models ($0.7 < NS \leq 0.8$). The FIS 02, 03, 04 and 05 are considered “very good” ($NS > 0.8$ and $PBIAS < \pm 10$). The more discretization for the fuzzy sets is employed, the better the performance of the FIS models.

In Fig. 17, the observed and calculated alterations of SSC from three of the most important models within the verification sample are shown.

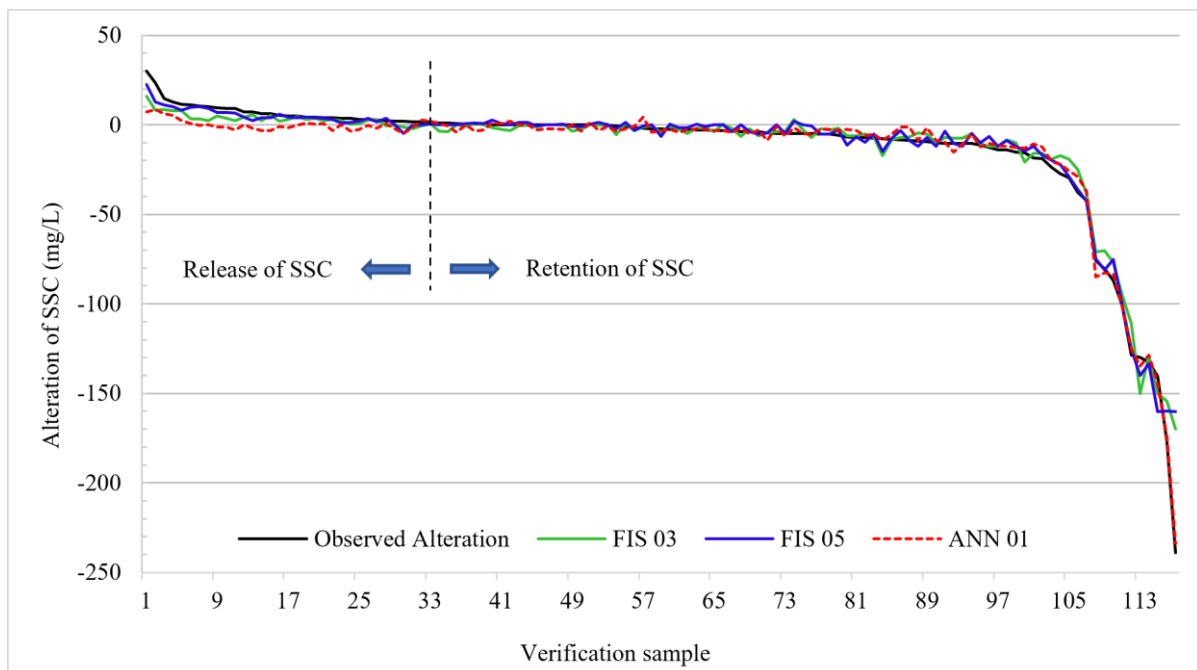


Fig. 17 - Observed and calculated alteration of SSC by FIS 01, FIS 03, and FIS 05

The three main models can satisfactorily represent the alterations of SSC caused by the dams in the Pantanal basins. However, the models with more partitions of the fuzzy sets better represent the extreme changes, both in the retention and in the release of sediments.

4.3.2. Fuzzy sets and qualitative performance

Among the developed FIS models with “very good” classifications, FIS 03 is the chosen model for further analysis and interpretation of the rules due to its smaller number of generated rules and smaller number of fuzzy sets in most input variables (3 fuzzy sets). In Fig. 18 and Fig. 19 membership functions and prototype locations of the FIS 03 are shown.

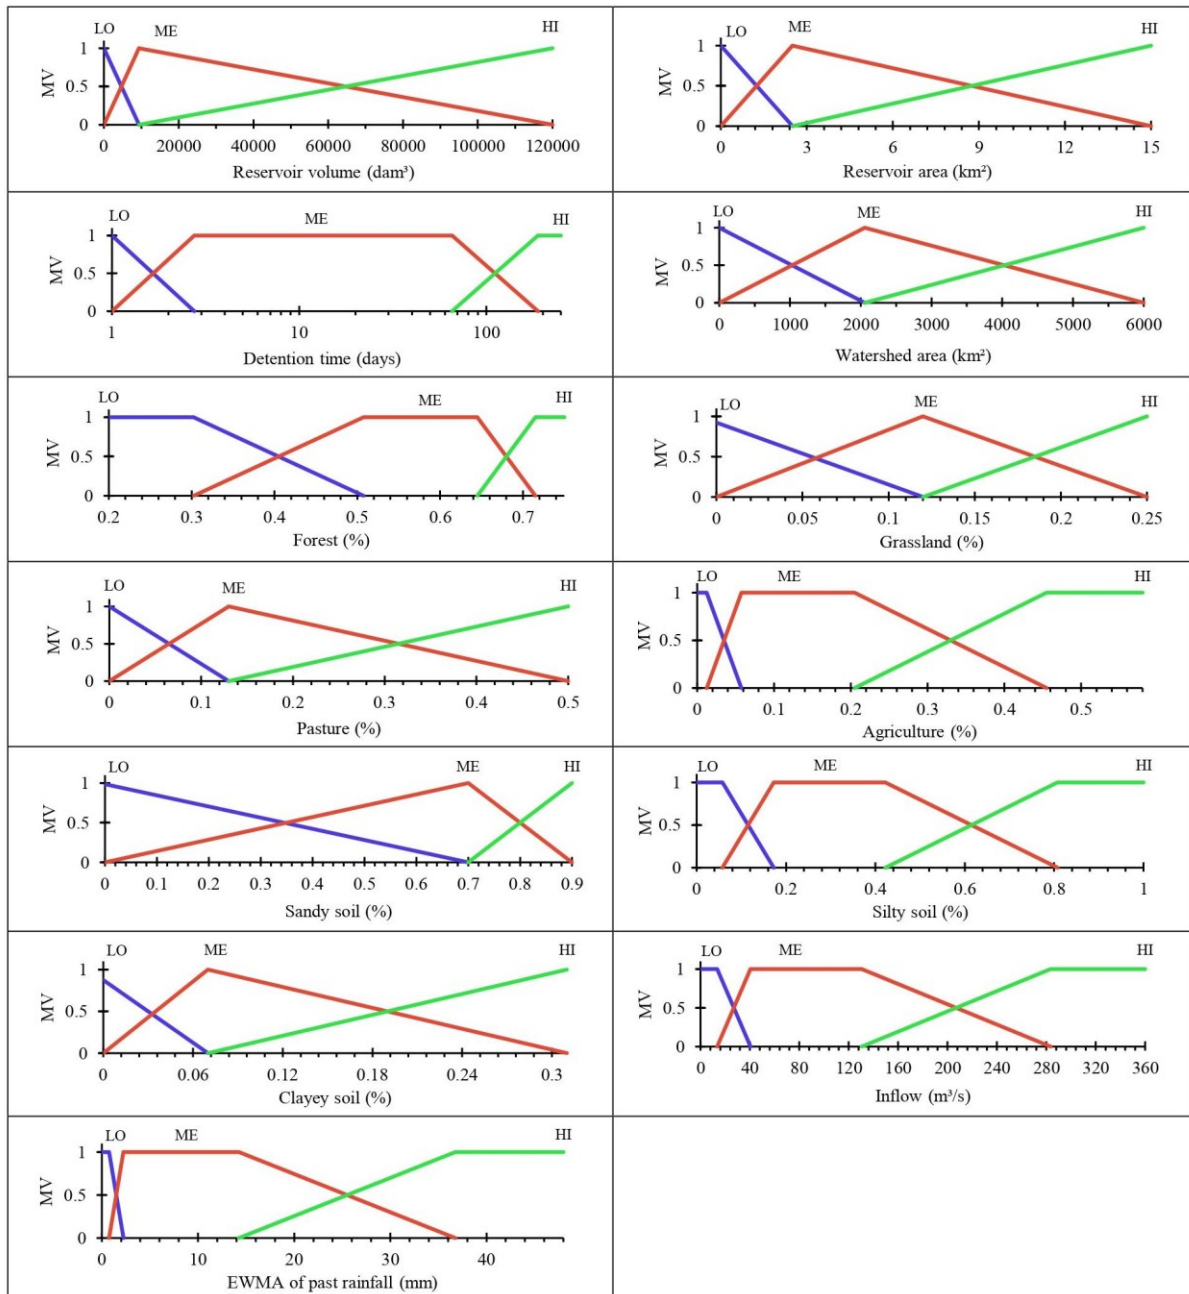


Fig. 18 - Fuzzy sets of input variables of FIS 03. Blue: Low fuzzy set; Red: Medium fuzzy set; Green: High fuzzy set

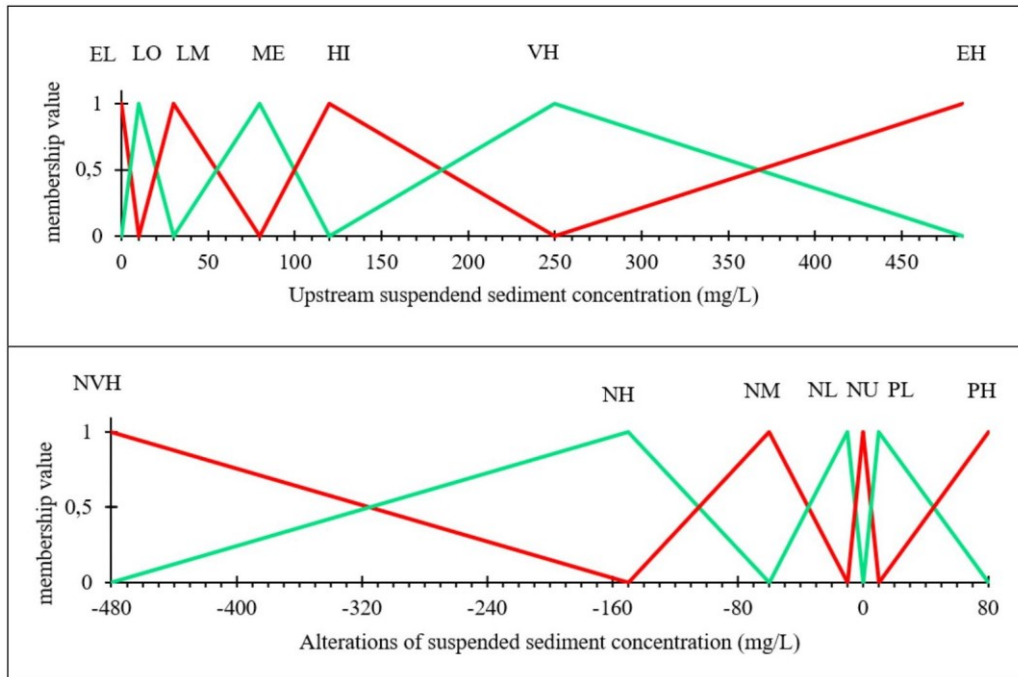


Fig. 19 - Fuzzy sets of the sediment variables of FIS 03

For most of the input variables, the fuzzy sets used were: Low (LO), Medium (ME) and High (HI). For the Upstream SSC, the fuzzy sets used were: Extremely Low (EL), Low (LO), Low Medium (LM), Medium (ME), High (HI), Very High (VH) and Extremely High (EH). For the alteration of SSC, the fuzzy sets used were: Negative Very High (NVH), Negative High (NH), Negative Medium (NM), Negative Low (NL), Null (NU), Positive Low (PL) and Positive High (PH).

The qualitative performance of FIS 03 is shown in Tab. 8. The total estimates, the correct estimates, and the proportion of correct estimates in each fuzzy set were calculated and compared with the observed occurrences. It is possible to observe that the proportions of correct estimates are above 90% for most fuzzy sets. For the NVH and NH sets, the model can correctly estimate all occurrences. The model tends to overestimate the NU set, and on the other hand, it tends to underestimate the occurrences of the NL and PL sets. This happens because the prototypes of these three sets are numerically closer. It is also observed that the model does not estimate most of the occurrences of the PL set, indicating model difficulties to explain positive alterations downstream of dams. Part of the positive alterations probably occurs due to the erosion of the channel downstream of the dam, which is a consequence of the environment trying to re-establish the balance interrupted by the dam. However, there are no input variables in the model that represent this phenomenon.

Regarding the frequency of occurrences in each fuzzy set, most occurrences (about 61%) are classified as NU, 30% of occurrences indicate some level of retention caused by dams

(ranging from NL to NVH), and about 9% indicate higher SSC downstream of dams (PL and PH). Although most of the occurrences indicate null alterations, negative low alterations, with are the second most frequent occurrences, can cause significant loss of sediment and nutrients downstream over time, and represent economic costs for the operation of these dams, which will have problems related to silting.

Tab. 8 - Qualitative performance of FIS 03

Prototype value (mg/L)	Output Fuzzy sets	Observed occurrences	Total estimates	Correct estimates	Proportion of correct estimates
-480	Negative very high (NVH)	2	2	2	1.00
-150	Negative high (NH)	15	15	15	1.00
-60	Negative medium (NM)	25	25	23	0.92
-10	Negative low (NL)	121	110	101	0.92
0	Null (NU)	325	364	320	0.88
15	Positive low (PL)	45	18	17	0.94
80	Positive high (PH)	2	1	1	1.00
TOTAL		535	535	479	0.90

Furthermore, our analyses investigated the individual alterations caused by the dams, based on watershed characteristics, dam characteristics and hydrological variations. However, many of these small dams form cascades in the same river, which enhance their negative effect, as shown by Fantin-Cruz et al., (2020).

4.3.3. Feature importance analysis

The feature importance analysis (Fig. 20) indicates that the upstream SSC is the most important input variable of the model, with the highest FRI. Detention time is also very important. When these two variables are excluded from the complete model, the performance, in terms of NS, PBIAS and MAE, decreases considerably. Reservoir area and volume are at the bottom of the list as the model doesn't lose as much performance when we remove those. This happens because the detention time continues to indirectly explain the size of the dam. However, even if these variables are correlated, models without one of them still lose performance and, therefore, we kept all the variables in the analysis. In addition, we also wanted to confirm the individual influence of the variables related to the size of the dam on the SSC alteration. The exclusion of all other input variables causes some degree of performance reduction, compared to the complete model, indicating that the best estimate of SSC alterations caused by dams is made when using all the input variables selected in this study.




Fig. 20 - Feature importance analysis for FIS 03

4.3.4. Frequency analysis

The results of the frequency analysis are shown in Fig. 21. The extreme fuzzy sets of the output variable (negative very high and positive high) were disregarded because both are rare occurrences, having only two observed pairs of data within the dataset. Therefore, the frequency analysis is presented for the alterations of SSC classified as negative high, negative medium, negative low, null, and positive low.

The input variables related to dam characteristics (Fig. 21 a, b and c) presented clear patterns along the fuzzy sets of the output. Both reservoir volume, reservoir area and detention time have more frequencies in the HI and ME fuzzy sets for negative high and negative medium alterations. They also present higher frequency in the LO fuzzy set for null, negative low and positive low alterations. These results confirm that larger reservoirs, with greater volume and area, and longer detention times, cause more alterations due to more reduction of the velocities in the water flux entering the reservoir. Conversely, smaller dams, whose classifications for reservoir area, reservoir volume and detention time are LO, are more frequent in null and low alterations. However, there are about 25% of dams classified as LO in the negative medium and negative high alterations, indicating that smaller dams can also cause great SSC alterations in some cases.

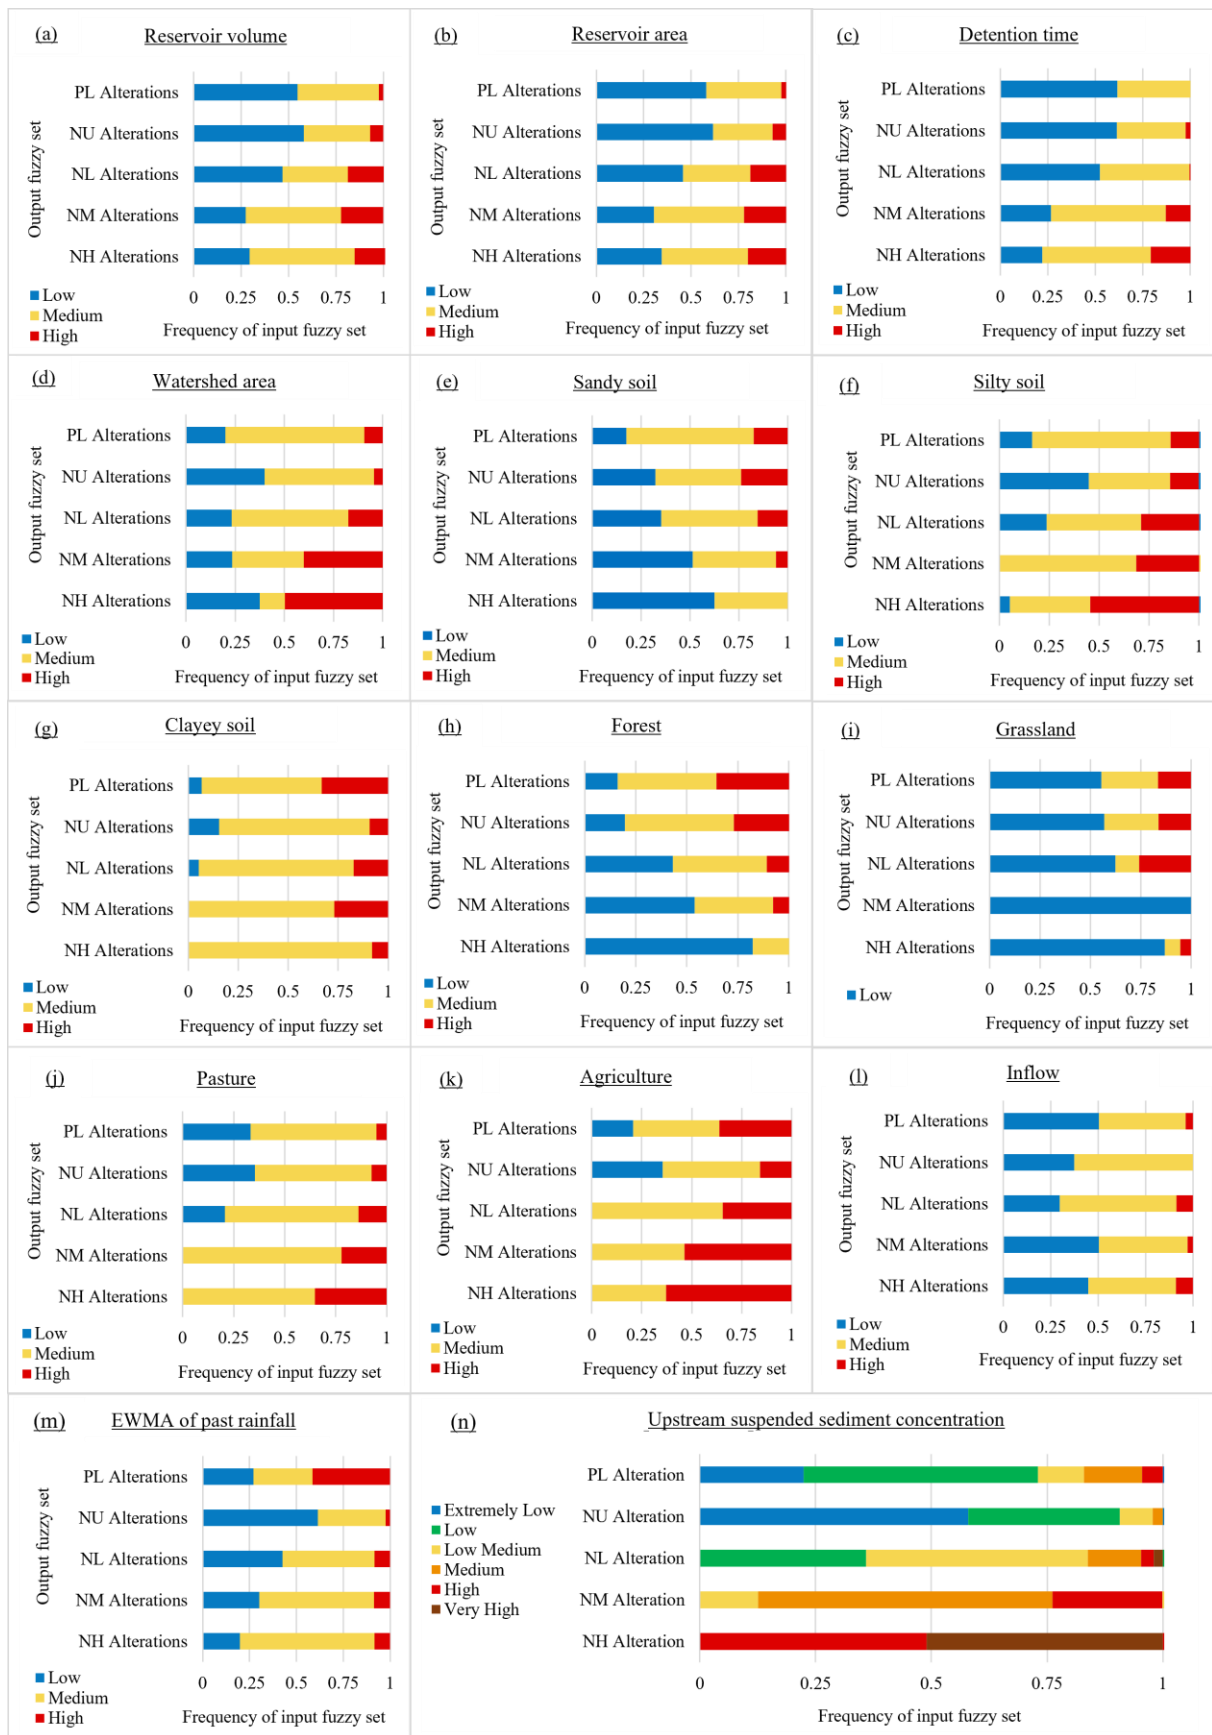


Fig. 21 - Frequency analysis of the input variables – FIS 03

For the variable watershed area (Fig. 21 d), it is noted that negative high and negative medium alterations are more frequent in larger drainage basins (classified as HI), but also occur with a smaller proportion in small basins (LO sets). Watershed basins classified as ME tend to alter less than watershed basins classified as HI. Watershed basins classified as LO do not show a clear pattern and may cause null, low or high alterations. In general, dams located in larger catchments tend to alter SSC more. This can be explained by the fact that larger dams, which are more related to great negative alterations, are usually located in larger basins.

Regarding soil type (Fig. 21 e, f and g), sandy soils and silty soils presented clear correlations with the alterations caused by dams. No evident pattern was observed for clayey soils. Sandy soil and silty soil show opposite patterns. The presence of sandy soils within the watershed of small dams is more related to null and low alterations in SSC, while dams located in basins with more silty soils are more related to negative high and negative medium SSC alterations. These results confirm that the types of sediment in the river system, which depend on the watershed characteristics, affect the reservoir sedimentation and the SSC downstream. This opposite characteristic between sandy soils and silty soils might be related to the differences in the size of the particles. Silty soils are smaller, and therefore easier transported in suspension. On the other hand, sandy soils are composed of bigger particles (> 0.2 mm) and might move mostly near the streambed, moving, rolling, and sliding in contact with the streambed (Cantalice et al., 2015; Vercruyssen et al., 2017). Thereby, basins with silty soil might have greater suspended material, while sandy soil basins tend to have less suspended material in the water, and more material being transported in the bedload.

For the land use variables (Fig. 21 h, i, j and k), it is possible to notice an opposite pattern between areas with natural land cover (forest and grassland) and anthropic uses (agriculture and pasture). Most of the dams that cause negative high alterations have less percentage of forest and grassland within their basin (more than 75% of the forest fuzzy sets are classified as LO) and more percentage of pasture and agriculture (more than 60% of the agriculture fuzzy sets are classified as HI). Forest and grassland present a similar pattern, indicating that dams with high percentages of natural areas within their watershed tend to cause less effect on sediment transport. Oppositely, agriculture and pasture occur more in drainage areas of dams which cause greater SSC alterations. Therefore, this result confirms that the presence of vegetation cover protects the environment against dams and reduces the disruption of sediment transport caused by dams. The vegetation canopy directly decreases the amount of rainfall reaching the ground, and vegetation on the ground can weaken the gravitational energy of raindrops, diffusing the

runoff energy. Moreover, the root system of plants can also reduce soil erosion, by enhancing its porosity, increasing the penetrability of precipitation, and reducing runoff. The root systems of plants interlace which may enhance the soil's anti-erosion power (Yu et al., 2006). Conversely, agricultural expansion is well recognized for its effects of increasing soil erosion. In the Brazilian Cerrado, where the study area of this research is located, the agricultural expansion from 2000 to 2012 increased sediment production by 16% (Gomes et al., 2019).

Regarding the input variables related to hydrological variations, inflow (Fig. 21 l) did not present a clear pattern with the alterations caused by dams. The effects of the studied dams, whether null or pronounced, are not related to the magnitude of the inflows. LO and ME inflows are frequent in all output classes, with some unclear variations. This result might indicate that the rivers studied in our research are similar, with similar flow magnitudes and few measurements performed at high flows (HI fuzzy sets). Therefore, when inflows are analysed individually in relation to the changes in SSC caused by dams, it does not show influence. However, sediment transport is a consequence of flows and SSC and, therefore, higher flows under the same SSC transport more sediments. Thus, for dams with conventional storage, where flows are regulated and often reduced, even if the dam produces null changes in SSC, sediment transport downstream is affected.

The EWMA of past rainfalls (Fig. 21 m) appears to influence the alterations caused by dams. The frequency of moderate rainfall (ME fuzzy sets) increases in the fuzzy sets that represent greater SSC alterations. Null alterations are more related to LO classifications of EWMA of rainfall, which means little or no rainfall. Interestingly, positive low alterations are more related to HI classes of EWMA of rainfalls, which represent heavier rainfalls, although, 25% of occurrences are classified as LO. Overall, these results indicate that rainy periods provide an increase in the supply of sediments and are therefore related to alterations in SSC caused by dams.

Precipitation and subsequent runoff are the main agents of soil erosion and sediment transport. Precipitation also influences the erosion of the riverbed and banks. Furthermore, erosion hotspots such as gullies can form on fields during storm events, causing an increased contribution of sediment from a specific source (Vercruyssen et al., 2017). Herewith, it is expected that rainy periods are related to greater retention of sediments in the reservoir since there is an increase in the sediment supply in the river during this period. Extreme rain events produce a larger input of sediments into the river, as well as the resuspension of part of the bedload, therefore causing positive alterations.

Ultimately, the upstream SSC (Fig. 21 n) was found to be the input variable most related to the variability of the alterations caused by dams. When the SSC is high in the inflow entering the reservoir, the dam tends to alter more the downstream SSC, causing greater differences. Negative high alterations resulted from upstream SSC always classified as VH or HI. On the other hand, null and low alterations resulted from upstream SSC mostly classified as EL and LO. Overall, the higher the SSC entering the reservoir, the bigger the retention caused by small dams.

4.3.5. Rule ranking

The FIS models developed in this research have an average of 243 rules (FIS 03 has 200 rules), making it difficult to directly interpret all the rules. In the rule generation method used in this research, some rules have high weights but are rarely activated, while others, even if they have lower weights, are widely used. Therefore, the use of the proposed factor was justified, as an alternative to combining both effects, providing a score for all rules generated. Based on this factor, the best 6 rules for each output fuzzy set are highlighted for FIS 03 (Tab. 9).

The rule number corresponds to the order of the rule in the complete rule base. Regarding the 200 rules of FIS 03, rules 1 and 2 correspond to negative very high alterations (rare occurrences, therefore only two rules), rules 3 to 13 belong to the negative high alterations, rules 14 to 29 belong to the negative medium alterations, rules 30 to 84 belong to the negative low alterations, rules 85 to 168 belong to the class null, rules 169 to 199 belong to the positive low, and rule 200 refers to the positive high alterations (also rare occurrences).

Null alterations of SSC have more occurrences and weightier rules, followed by negative low, positive low, negative medium, and negative high. The number of rules generated for each fuzzy output set is directly related to the number of occurrences in the dataset.

The best rules of the output fuzzy sets have similar patterns to those observed in the frequency analysis. The upstream SSC is directly related to the output. The higher the classification of upstream SSC, the greater the alteration indicated by the rule.

HI classifications for watershed areas appear more in the negative high and negative medium rules, and ME and LO watershed areas appear more in negative low, positive low and null alterations.

Tab. 9 - The best 6 FIS rules for each fuzzy output set – FIS 03. Input features: (a) Watershed area; (b) Reservoir area; (c) Reservoir volume; (d) Detention time; (e) Inflow; (f) Forest; (g) Grassland; (h) Pasture; (i) Agriculture; (j) Sandy soil; (k) Silty soil; (l) Clayey soil; (m) EWMA of past rainfall; (n) Upstream SSC

rank	Rule number	Input														Output	Rule weight (w)	Occurrence (o)	w*o
		(a)	(b)	(c)	(d)	(e)	(f)	(g)	(h)	(i)	(j)	(k)	(l)	(m)	(n)				
1	6	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	VH	Negative High	0.05	6	0.30
2	12	HI	HI	HI	HI	ME	ME	LO	HI	ME	LO	HI	ME	ME	VH	Negative High	0.05	4	0.20
3	9	LO	ME	ME	ME	LO	LO	LO	ME	HI	LO	HI	HI	ME	HI	Negative High	0.07	2	0.14
4	5	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	HI	VH	Negative High	0.04	2	0.08
5	4	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	HI	Negative High	0.015	4	0.06
6	13	HI	HI	HI	HI	ME	ME	LO	HI	ME	LO	HI	ME	LO	HI	Negative High	0.03	2	0.06
1	25	ME	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	HI	ME	ME	Negative Med	0.12	2	0.24
2	27	HI	HI	HI	ME	ME	ME	LO	HI	ME	LO	HI	ME	ME	HI	Negative Med	0.04	4	0.18
3	16	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	HI	Negative Med	0.02	7	0.15
4	22	ME	HI	HI	ME	ME	LO	LO	HI	ME	ME	ME	ME	ME	ME	Negative Med	0.02	6	0.12
5	26	LO	LO	LO	ME	LO	LO	LO	ME	HI	LO	ME	ME	LO	ME	Negative Med	0.05	2	0.09
6	17	HI	ME	ME	ME	ME	LO	LO	ME	HI	LO	ME	ME	HI	HI	Negative Med	0.02	5	0.09
1	37	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	LM	Negative Low	0.09	20	1.77
2	54	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	LM	Negative Low	0.06	26	1.66
3	79	HI	LO	LO	LO	ME	ME	LO	HI	ME	LO	ME	ME	ME	LO	Negative Low	0.05	20	1.05
4	33	ME	LO	LO	LO	ME	ME	HI	LO	ME	LO	LO	ME	ME	LM	Negative Low	0.08	12	0.91
5	53	ME	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	ME	LO	LO	Negative Low	0.03	22	0.74
6	71	LO	LO	LO	LO	LO	LO	LO	ME	HI	LO	ME	ME	LO	LM	Negative Low	0.10	7	0.68
1	99	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	EL	Null	0.13	48	6.47
2	93	ME	LO	LO	LO	ME	ME	ME	ME	ME	ME	LO	ME	LO	LO	Null	0.07	88	5.98
3	147	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	ME	ME	LO	LO	Null	0.15	27	4.16
4	98	ME	LO	LO	LO	ME	HI	ME	ME	ME	ME	LO	ME	ME	LO	Null	0.06	66	4.10
5	100	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	LO	EL	Null	0.15	28	4.07
6	149	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	ME	ME	LO	EL	Null	0.17	18	3.11
1	171	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	HI	LO	Positive Low	0.04	11	0.45
2	192	ME	LO	LO	LO	LO	LO	LO	ME	HI	ME	ME	HI	LO	LO	Positive Low	0.12	3	0.36
3	178	ME	LO	LO	LO	ME	ME	LO	ME	HI	ME	ME	HI	HI	LO	Positive Low	0.03	6	0.20
4	173	ME	LO	LO	LO	ME	HI	ME	ME	ME	ME	ME	ME	ME	LM	Positive Low	0.03	6	0.16
5	191	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	ME	ME	ME	ME	Positive Low	0.05	3	0.16
6	193	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	HI	ME	HI	LO	Positive Low	0.04	2	0.08

General fuzzy sets: LO: Low; ME: Medium; HI: High.

Fuzzy sets for Upstream SSC (n): EL: extremely low; LO: low; LM: low medium; ME: medium; HI: high; VH: very high; EH: extremely high

For the variables related to dam characteristics, both reservoir area, volume and detention time are classified as HI and ME in the best rules related to negative high and negative medium alterations, while LO classifications appear more in the rules of the negative low, null, and positive low alterations. The dam characteristics were classified in the same input fuzzy set, i.e., if the reservoir area is low, the reservoir volume and detention time are also classified as low. This correlation makes physical sense, since smaller dams generally have reduced detention times, also depending on the inflow entering the reservoir.

HI and ME classes of vegetation cover appear more in the null and low alterations, while low classes appear more in the alterations of greater magnitude. In contrast, HI and ME classifications of agriculture and pasture appear more frequently in the alterations of greater magnitude.

For the soil type, the main rules also indicate that silty soil is more related to negative high and negative medium alterations, and sandy soils appear more in null and low alterations.

Regarding EWMA of rainfall, HI classes are more present in the rules for positive low alterations. ME classes appear more in the negative high, negative medium, and negative low alterations. Null alterations have more EWMA of rainfall classified as LO.

4.3.6. Similarity analysis

Some of the best rules for each output fuzzy set were selected for the similarity analysis (rules 6, 25, 37, 54, 147, 171). From the selected rule, the ordering of other rules was done, according to the similarity (proximity). The presentation of all ordered rules, from the most similar to the most different, is not practicable, therefore, similar rules with up to one different variable are presented (Tab. 10). This analysis allows the identification of the differences in the input fuzzy set that do or do not change the output fuzzy set.

For most of the analysed rules, the upstream SSC is the main responsible for changing the output fuzzy set. For Rule 6 the upstream SSC is VH. When this variable is classified as ME (rule 15), the level of alteration changes from negative high to negative medium. Equally, when the upstream SSC is classified as LO (rule 46), the alteration of SSC is negative low instead. A similar pattern is found for the analysed rules 25, 37, 54 and 147. When the classification of upstream SSC changes within similar rules, the output fuzzy set also changes in most cases.

Tab. 10 - Similarity analysis. Input features: (a) Watershed area; (b) Reservoir area; (c) Reservoir volume; (d) Detention time; (e) Inflow; (f) Forest; (g) Grassland; (h) Pasture; (i) Agriculture; (j) Sandy soil; (k) Silty soil; (l) Clayey soil; (m) EWMA of past rainfall; (n) Upstream SSC

Rule		Input													Output	Weight		
		(a)	(b)	(c)	(d)	(e)	(f)	(g)	(h)	(i)	(j)	(k)	(l)	(m)			(n)	
Analysed	6	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	VH	Negative High	0.05	
Similar	4	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	HI	Negative High	0.01	
Similar	5	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	HI	VH	Negative High	0.03	
Similar	15	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	ME	Negative Med	0.01	
Similar	16	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	HI	Negative Med	0.02	
Similar	46	HI	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	ME	ME	LO	Negative Low	0.02	
Analysed	25	ME	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	HI	ME	ME	Negative Med	0.12	
Similar	65	ME	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	HI	ME	LM	Negative Low	0.06	
Similar	111	ME	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	HI	ME	LO	Null	0.07	
Similar	142	ME	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	HI	ME	LM	Null	0.03	
Similar	143	ME	ME	ME	ME	ME	LO	LO	ME	HI	ME	ME	HI	ME	EL	Null	0.07	
Analysed	37	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	LM	Negative Low	0.09	
Similar	39	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	ME	Negative Low	0.03	
Similar	99	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	EL	Null	0.13	
Similar	38	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	LO	Negative Low	0.03	
Similar	97	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	ME	LO	Null	0.06	
Similar	63	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	LO	ME	LO	LM	Negative Low	0.07	
Analysed	54	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	LM	Negative Low	0.06	
Similar	160	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	LM	Null	0.01	
Similar	7	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	VH	Negative High	0.02	
Similar	76	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	ME	Negative Low	0.04	
Similar	127	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	EL	Null	0.07	
Similar	130	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	ME	LO	Null	0.04	
Similar	159	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	LO	LM	Null	0.02	
Similar	188	ME	ME	ME	ME	ME	ME	HI	ME	ME	HI	LO	ME	HI	LM	Positive Low	0.02	
Analysed	147	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	ME	ME	LO	LO	Null	0.15	
Similar	8	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	ME	ME	LO	VH	Negative High	0.04	
Similar	70	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	HI	ME	LO	LO	Negative Low	0.04	
Similar	149	LO	LO	LO	LO	LO	ME	LO	ME	LO	LO	ME	ME	LO	EL	Null	0.17	
Analysed	171	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	HI	LO	Positive Low	0.04
Similar	96	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	LO	Null	0.03	
Similar	36	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	LO	Negative Low	0.01	
Similar	94	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	ME	LO	LO	Null	0.07	
Similar	177	ME	ME	ME	ME	ME	HI	ME	ME	ME	ME	ME	ME	HI	LO	Positive Low	0.02	

General fuzzy sets: LO: Low; ME: Medium; HI: High.

Fuzzy sets for Upstream SSC (n): EL: extremely low; LO: low; LM: low medium; ME: medium; HI: high; VH: very high; EH: extremely high

In rules 5 and 67, the changes in the EWMA of past rainfall do not change the class of the output variable. However, in rules 159, 188, 96, 36, 94 and 177, the change in the classification of the EWMA of past rainfalls alters the classification of the output fuzzy set. Reduction of rainfalls also reduces the level of alteration on SSC caused by dams, whereas HI classifications for this variable result in positive low alterations. Once again, the presence of heavy rains (HI) appears to be related to positive alterations.

Some rules have the same classifications for the input fuzzy sets but different output fuzzy sets. This is the case of rules 4 and 16, 65 and 142, 38 and 97, 54 and 160, and 96 and 36. This reflects the model's interpolation. For a given occurrence, two rules can be activated, and the result will be an interpolation between them.

For the rules similar to rule 147, the increase of the silty soil in rule 70 was the factor which changed the null alteration to negative low. Furthermore, even if most of the variables that cause changes of greater magnitude are classified as LO (such as watershed area, dam characteristics, agriculture and EWMA of past rainfall), the occurrence of upstream SSC classified as very high (rule 8) makes the output to be negative high.

Overall, all analyses indicated the Upstream SSC as the most determinant variable for the alterations on SSC downstream. The results also confirmed that larger dams and larger watershed basins are more related to great negative alterations. Among the watershed characteristics, silty soils, agriculture, and pasture are more related to dams that cause greater SSC alterations. Vegetation cover and sandy soil are more related to less or null alterations. The EWMA of past rainfalls was also found to influence the alterations caused by dams. More rains tend to cause more alterations by the dams. Heavy rains can cause sediment release from the dams.

Through our fuzzy association rules analysis, we provide an alternative solution for the interpretation of FIS models with high-dimensional issues, i.e., a large number of input variables which leads to a large number of fuzzy rules. The frequency analysis allows the identification of patterns within the input fuzzy sets that are more frequent in the output fuzzy sets. Through the rule ranking and the rule similarity analysis, the most important and most used rules are highlighted and discussed, providing new and important knowledge about the effect of small dams on sediment transport within the Pantanal region.

A limitation of this research is the low availability of data (minimum 10 and maximum 47 pairs of data per dam), which leads to some uncertainties due to the lack of data. In general, the lack of long SSC time series is common in most parts of the world due to the costs involved in

sampling this variable. Therefore, we recommend that more data on SSC are sampled upstream and downstream of dams to reduce uncertainties in future studies.

4.4. Implications and recommendations for the Pantanal wetland

Dams located in rivers that drain towards Pantanal and that naturally present high SSC will tend to alter more the downstream SSC and, therefore, reduce the amount of SSC and the amount of nutrients that enter the wetland.

Most of the rivers with the highest SSC are yet undammed, including the Vermelho, Coxim, upper Taquari, Miranda, and Aquidauana rivers. Therefore, the construction of dams in these rivers would cause great reductions in sediment transport towards Pantanal.

According to Fantin-Cruz et al., (2020), there are currently 26 SHPs proposed for the Taquari subbasin (including the Coxim, Jauru and upper Taquari rivers), most forming cascades. The Taquari river transports about 1500 tons/day of suspended sediments to the Pantanal and presents the highest SSC average along the UPRB. Considering the results of the FIS models, this basin could suffer major consequences if the proposed dams are implemented. These dams would suffer high siltation processes, and the downstream wetland will lose the high input of sediments that this subbasin naturally offers.

The Cuiabá river also carries relatively high SSC (about 750 tons/day according to Fantin-Cruz et al., (2020)), and it is considered one of the most important tributaries of Pantanal due to its high flows. 6 cascade SHPs are being considered for this river. These facilities are relatively close to the beginning of the Pantanal wetland, and therefore, would cause a high reduction in the SSC that enters the wetland through this subbasin.

Rivers that already have dams near the entrance to the Pantanal, and which naturally have low SSC, such as the Correntes, Itiquira, Jauru MT, Juba and Sepotuba rivers (Ponte de Pedra, Itiquira, Jauru dams, respectively), are rivers that can be strategic for the implementation of new dams. Since these rivers are already dammed, the future dams that are proposed upstream of the existing dams may cause less impact on sediment transport towards Pantanal. The inclusion of new dams upstream of existing dams can also be interesting for reducing silting in downstream dams.

Furthermore, our results showed that the vegetation cover is an important feature that protects the basins and, consequently, the reservoirs. Dams located in basins with greater protection offered by vegetation cover tend to cause less alteration in sediment transport. Therefore, Agriculture and pasture practices, on the other hand, offer more sediment input to the rivers. Therefore, the use of sustainable land management practices in the basins that drain into the Pantanal, such as

maintaining the natural vegetation cover, and promoting more sustainable agriculture and pasture practices are essential for the preservation of the largest wetland in the world.

This research assessed the effects of small dams on sediment transport in a more general way. We recommend the continuation of this research focusing on the current scenario of hydropower plants within the Pantanal wetland, identifying relevant characteristics of each tributary river, and providing a more specific analysis for the entire region.

4.5. Conclusion

This study presents an original application of Mamdani Fuzzy Inference Systems to research knowledge of the effect of small dams on sediment transport and provides understandings of how different variables related to watershed characteristics, dam characteristics and hydrological variations can affect sedimentological responses of small hydroelectric facilities.

We provide new strategies to overcome the difficulty to interpret a large set of rules in high-dimensional FIS models by performing frequency analysis within the rules, as well as filtering out the most important rules and comparing them to similar rules. FIS rules can be directly observed and, therefore, help us to catch patterns within the variables to understand the phenomena.

Upstream SSC is the most determinant variable of the SSC alteration that can be caused by the dams. Higher concentrations of sediment entering the reservoir tend to cause more retention. Null alterations are closely related to low upstream SSC, and positive alterations occur mostly during rainy periods. The soil type within the drainage area of dams also influences the downstream SSC. Dams located in basins with more silty soil tend to alter more. Conversely, dams located in basins with more sandy soil tend to cause less alterations on SSC. Vegetation cover also proved to be important in the effects caused by dams. Dams located in basins with greater vegetation cover tend to affect less sediment transport, in comparison with dams located in basins with high percentages of agriculture and pasture. This result reinforces the importance of vegetation cover in protecting lands against accelerated erosion and, consequently, protecting the environment from the effects that a dam can cause. FIS models also confirmed that the size of dams is directly proportional to their capacity to alter sediment transport. The greater the volume, area and detention time of the reservoir, the more potential to alter the SSC.

The findings of this study may help to develop guidelines related to the implementation of future hydroelectric facilities in the Pantanal Basin. Rivers with higher risk factors for SSC alteration can be mapped, helping environmental managers in decision-making.

5. ARTIGO 3 – Mapping suspended sediment dynamics in the Pantanal wetland using artificial neural networks and remote sensing

Este capítulo corresponde ao terceiro artigo científico da Tese, cujo assunto é voltado para a caracterização da dinâmica espaço-temporal dos sedimentos em suspensão ao longo da bacia do Alto Paraguai.

Neste sentido, um mapeamento da dinâmica dos sedimentos em suspensão no sistema rio-planície do Pantanal é apresentado, utilizando a plataforma Google Earth Engine em conjunto com imagens dos satélites Sentinel-2 e Landsat-8/9, e modelos de redes neurais artificiais. A metodologia utilizada proporcionou uma caracterização espacial e temporal sem precedentes da dinâmica dos sedimentos na região estudada.

O presente capítulo também é apresentado em inglês, e baseia-se no terceiro artigo científico desta Tese de doutorado, submetido na revista *Remote Sensing of Environment*. CAMPOS et al., **Mapping suspended sediment dynamics in the Pantanal wetland using artificial neural networks and remote sensing**. In peer review, 2023.

Abstract

Suspended sediment concentration (SSC) is of vital importance in floodplain and wetland ecosystems, impacting ecological functions, water quality, nutrient cycling, and sediment deposition. However, in the case of the Pantanal wetland, the world's largest wetland, there is still a significant knowledge gap concerning the relationship between hydrological processes and sediment distribution in its river-floodplain system. This paper aims to address this gap by carrying out the first comprehensive mapping of suspended sediment dynamics in the Pantanal's rivers and lakes. To achieve this, an innovative methodology using the Google Earth Engine (GEE) platform, along with satellite observations from Sentinel-2 and Landsat-8/9, combined with artificial neural network (ANN) models was developed. The ANN-based model effectively merges data from Landsat-8/9 and Sentinel-2, enabling the retrieval of SSC across multiple rivers and lakes within the Pantanal wetland. This methodology provides an unprecedented spatio-temporal characterization of sediment dynamics in the rivers and lakes of the Pantanal region and establishes a relatively simple workflow for processing a large number of satellite images in a vast area using a free cloud-based platform. The results reveal significant spatio-temporal differences in processes between uplands and different parts of the floodplain, with upland rivers exhibiting higher SSC compared to the floodplain. Moreover, this study has demonstrated how the seasonality of rainfall and flows influences the seasonality of SSC in the Pantanal. In the upland stations, the response between rainfall, flows and SSC is more linear and immediate, while in the Pantanal floodplain, SSC increases with the onset of rainfall, but reaches its minimum value at flood peaks, and is therefore inversely correlated with floods.

Keywords: Water quality, Landsat, Sentinel-2, Google Earth Engine, Artificial Neural Networks, Floodplain, Data scarcity

5.1. Introduction

Wetlands play a crucial role in ecosystems and biodiversity conservation, but they are facing significant changes due to human activity and climate change (Jaramillo et al., 2019). The Pantanal, recognized as the world's largest continuous floodplain, is no exception. Due to its annual cycle of floods that creates conditions for a rich biodiversity of fauna and flora, the Pantanal provides vital ecosystem services, including carbon storage, fish reproduction, aquifer recharge, and local economic sustainability (Campos e Pedrollo, 2023). The flooding dynamics of the Pantanal is closely related to the plain's geomorphology and seasonal hydrological regime. Large portions of the basin are susceptible to seasonal floods that can last from 4 to 8 months in some areas due to an extremely flat relief along its floodplain, causing this region to have a very slow response to seasonal rainfall (Assine et al., 2015; Marengo et al., 2016; Oliveira et al., 2019).

Suspended sediments are an important source of nutrients and pollutants in aquatic environments, especially in wetlands (Forsberg, 1989). In the case of the Pantanal, the upland areas are the main sediment producers due to the human activities carried out (agriculture and pasture), as well as the steeper geomorphology, which favors the processes of erosion and sediment transport. The sediments produced within the uplands are then transported to the floodplain, where the most predominant process is deposition (Hamilton, 2002a). According to Oliveira et al., (2020), sediments from the uplands transport nutrients into the Pantanal, thus affecting the biological productivity of the downstream ecosystems. This dynamic directly influences the primary aquatic productivity, due to the entry of nitrogen or phosphorus, constituting an important dynamic.

Despite the great relevance of sediment transport to the productivity of the Pantanal's floodplain, the spatio-temporal dynamics of sediments within the river-floodplain system are not widely understood. Several studies have brought important contributions focusing on the characterization of the Pantanal's geomorphology and flood dynamics (Hamilton et al., 1996b; Hamilton, 2002b; Fantin-Cruz et al., 2011; Luz, 2019; Jean Milien et al., 2023), and the available studies related to sediments are generally focused on quantifying erosive processes in the uplands (Bergier, 2013; Colman et al., 2019; Roque et al., 2021), or on the assessment of sediment fluxes in specific parts of the basin (Farias et al., 2018; Mingoti et al., 2019; Pereira et al., 2020; Wosiacki et al., 2021). Therefore, there is still a significant gap related to a comprehensive assessment of the suspended sediment dynamics along the river-floodplain system, and the relationship of this dynamic with the geomorphology and hydrological seasonality of the region.

One of the main challenges in understanding the dynamics of suspended sediments in this ecosystem is the lack of *in situ* data on suspended sediments. The complexity of the drainage

network, as well as the scarcity of *in situ* data, hinders the development of studies related to sediment dynamics in this region. The river gauging stations that monitor suspended sediment concentrations (SSC) in this region generally have a very limited temporal collection frequency, with less than 4 samplings per year, and additionally not homogeneously distributed throughout the year, making it difficult to assess spatial and temporal variations of SSC along the rivers and lakes of the Pantanal (Campos e Pedrollo, 2021).

Recent efforts have been made to overcome the scarcity of *in situ* data on SSC in the Pantanal. Campos and Pedrollo, (2021) developed a regional model based on artificial neural networks (ANN) to estimate SSC in ungauged rivers, based on other available hydrological variables. The ANN model used as input rainfall, discharge, watershed characteristics obtained through satellite observations (land use and land cover, average watershed slope, soil types), as well as turbidity, which is monitored more frequently compared to SSC at the gauging stations. This study provided a significant tool for estimating SSC in rivers that only monitor turbidity, and increased the information on SSC in the region. However, monitoring turbidity in Pantanal rivers is also not continuous, and still leaving spatial and temporal gaps, particularly in areas that are difficult to access and lack *in situ* stations.

On the other hand, recent advances in remote sensing technologies have made it possible to estimate some water parameters in large and remote areas, including SSC. Remote sensing techniques provide both spatial and temporal views of surface water quality parameters that are not achieved by *in situ* measurements (Sharaf El Din et al., 2017). Estimating suspended sediments from multispectral satellite images is possible due to the well-known and accepted relationship between the concentration of suspended material in water and the reflectance of solar radiation. Particles of suspended material in water cause an increase in the backscattering of radiation, i.e., water reflectance increases as SSC increases (Kirk, 1994). The most relevant bands for these estimates are those of the green, red and near infrared spectrum, with the reflectance peak occurs between the red and the near infrared bands in most cases (Jensen, 2009; Fassoni-Andrade e Paiva, 2019). Several studies have used surface reflectance from multispectral satellite images to assess water quality parameters, such as suspended sediment, turbidity and chlorophyll-a (Lobo et al., 2012; Kallio et al., 2015; Martinez et al., 2015; Attila et al., 2018; Fassoni-Andrade e Paiva, 2019; Pereira et al., 2020). However, no studies focusing on the Pantanal region were found.

Recently, multispectral images from the Sentinel-2 (MSI-Multi-Spectral Instrument sensor), Landsat-8 (OLI-Operational Land Imager sensor) and Landsat-9 (OLI2-Operational Land Imager 2 sensor) missions have offered consistent coverage over almost the entire globe, with a high

temporal resolution of ~2-3 days, along with high spatial resolution of 10-30 m and satisfactory radiometric performance (Claverie et al., 2018). However, managing and analyzing a large volume of satellite images can be computationally demanding, which can represent a significant obstacle to routine monitoring through remote sensing.

One solution to this challenge is the cloud-based platform Google Earth Engine (GEE). GEE is designed to provide large-scale geospatial analyses and has proven to be a tool with easy access to readily available data and powerful computing capabilities for a variety of applications. Compared to conventional image processing techniques, GEE offers significant advantages in terms of speed, scalability, and accessibility. These advantages make it an attractive option for researchers and practitioners who want to use remote sensing data to monitor suspended sediments on a routine basis.

Artificial neural network (ANN) models can learn complex and nonlinear relationships that are difficult to model through conventional methods. The integration of remote sensing data and ANN-based models has become an increasingly popular tool for water quality modeling due to the complexity of the relationship between the surface reflectance and the SSC, especially when using dataset from rivers with distinct physiography, bio-geo-chemistry, and hydrology. Several studies have proved the good performance of ANN-based models to retrieve SSC from multispectral satellite images (Peterson et al., 2018; Marzano et al., 2020; Dehkordi et al., 2021; Aires et al., 2022; Mohsen et al., 2022).

Therefore, the objective of this research is to assess the spatio-temporal dynamics of suspended sediments in the rivers and lakes of the Pantanal and identify the influence of the seasonal hydrological regime of the floodplain on sediment transport throughout the region. To achieve this, we proposed an innovative approach within the GEE platform that enabled us to predict SSC along the Pantanal wetland using surface reflectance of Landsat-8/9 and Sentinel-2 images combined with ANN-based models directly in the GEE platform.

This study addresses a gap as there is no previous characterization of suspended sediment dynamics along the Pantanal river-plain system and the influence of seasonal rainfall and flooding on suspended sediment concentrations.

5.2. Pantanal – study area

The Pantanal is located on the Upper Paraguay River Basin (here after UPB). The entire basin covers an area of more than 600,000 km², occupying part of Brazilian territory as well as part of Paraguay and Bolivia - Fig. 22. The UPB can be divided into two distinct regions, according to

different topographical/geomorphological and hydrological characteristics: the uplands and the Pantanal floodplain. To analyze the hydrological differences in the UPB, we are presenting the results for 6 stations: (1) Cuiabá station - located in the Cuiabá river; (2) Acima do Córrego Grande station - located in the São Lourenço river; (3) Coxim station - located in the Taquari river; (4) Porto Conceição station – located in the Paraguay river before its confluence with the Cuiabá river; (5) Porto do Alegre station – located in the Cuiabá river before its confluence with the Paraguay river; and (6) Amolar station – located in the Paraguay river after its confluence with the Cuiabá river. Stations 1, 2 and 3 are located in the uplands, and stations 4, 5 and 6 are located in the Pantanal floodplain.

The uplands correspond to 59% of the basin's area, with terrain at altitudes varying from 200 to 1300 meters, mainly in the eastern and northern parts. This part of the basin has deep soils and high slopes, favoring rapid runoff and high sediment production. The transition zone between the uplands and the Pantanal ranges from 200 to 400 meters, while the elevation within the Pantanal itself ranges from 50 to 150 meters. The Pantanal corresponds to 41% of the basin's area. This region has low, flat and saturated terrain. Due to the gentle slope and low riverbanks, the drainage system is unable to quickly transmit the water received from the plateau, and extensive areas are flooded, resulting in complex hydrological and hydrosedimentological dynamics (Campos e Pedrollo, 2021).

Precipitation is not uniform across the UPB, with annual averages ranging from 800 to 2000 mm. The distribution of rainfall is directly influenced by the differences in topography. In the Pantanal region, annual precipitation totals range from 800 to 1200 mm, while the highest precipitation values are observed in the upland areas, achieving more than 1600 mm per year (Campos e Pedrollo, 2021). 70% of the annual precipitation is concentrated in the rainy period (October to April).

The flooding dynamics of the Pantanal is closely related to the plain's geomorphology and seasonal hydrological regime. From a hydrological perspective, the periodic floods result from the typical periodic rainfall regime, with a rainy season between October and March, and a dry season between April and September. Although the rainy season begins in October, the first signs of flooding in the floodplain are observed in January, due to the delayed response between precipitation and flooding (Padovani, 2010).

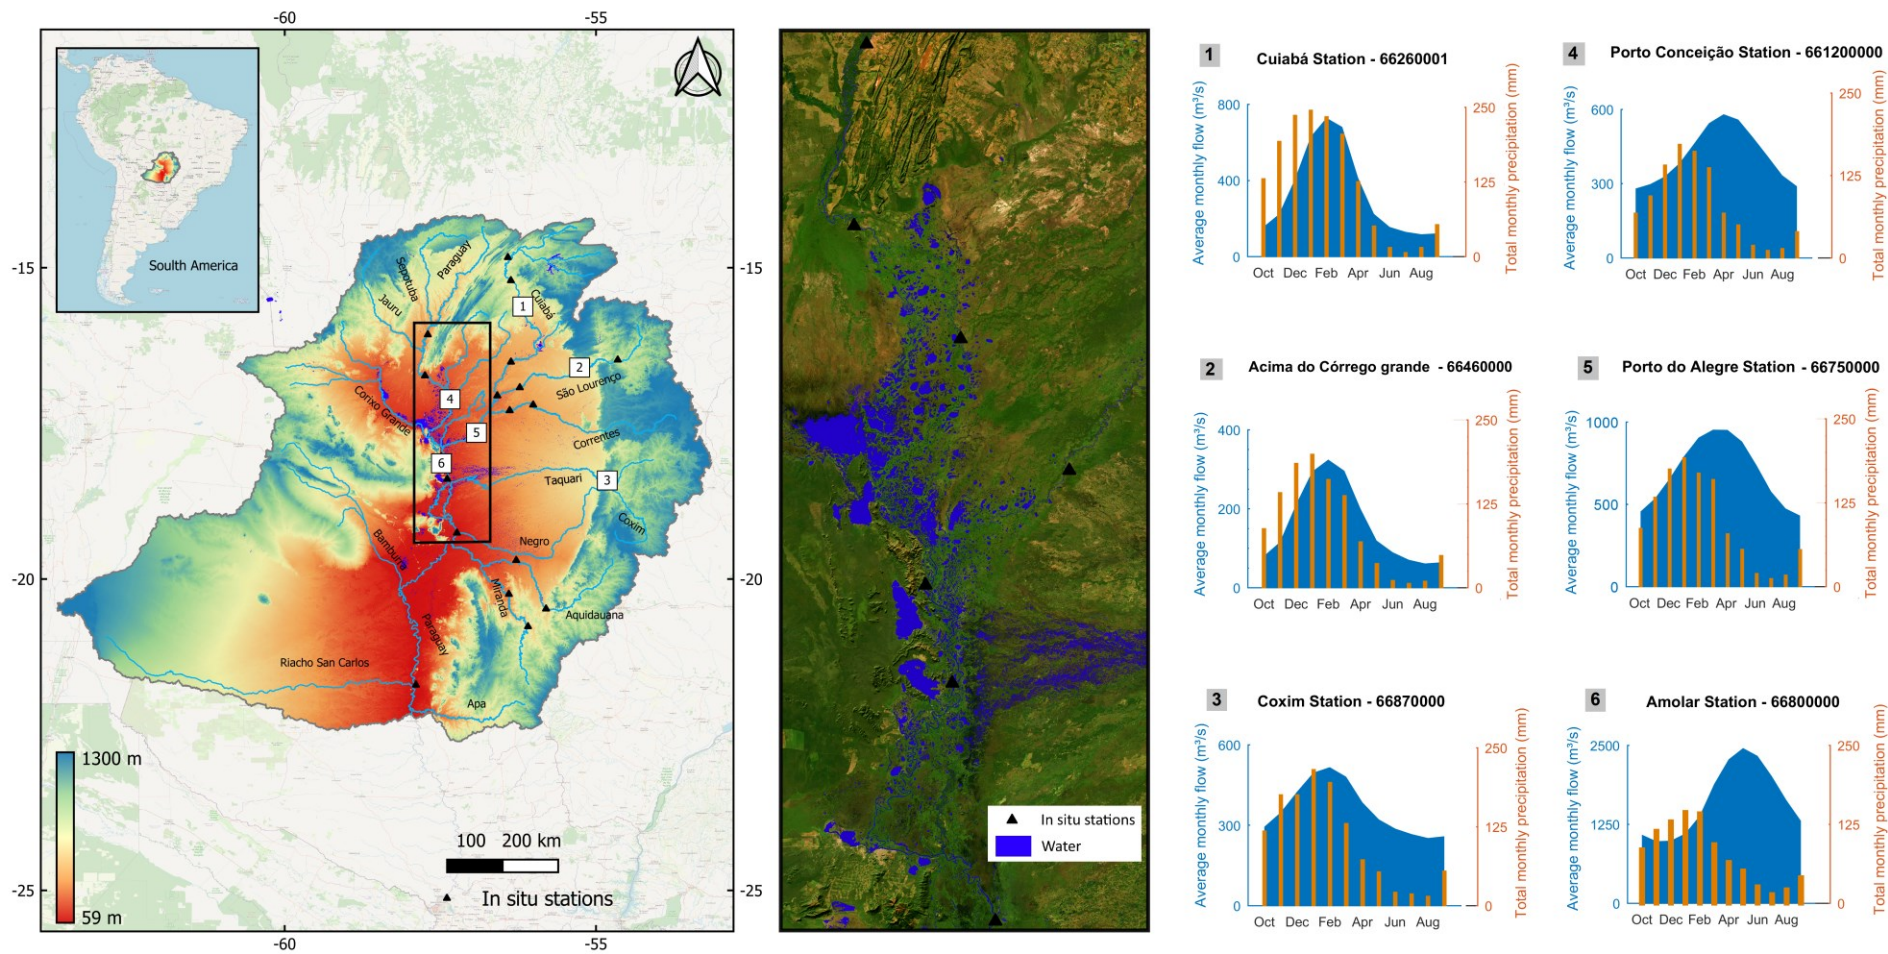


Fig. 22 - Upper Paraguay river basin (Pantanal hydrographic region).

During the dry season, water is retained in perennial rivers and lakes, while extensive and continuous grasslands are exposed in between the islands of vegetation. As a result of its geomorphology and hydrological processes, the plain area acts as a natural reservoir for water, filling up during the rainy season and slowly draining during the dry season, helping to maintain the water balance of the south Paraguay and Paraná River Basins (Paz et al., 2014; Marengo et al., 2016).

The Paraguay river is one of Brazil's major floodplain rivers and the main water contributor to the Pantanal floodplain. Its main tributaries on the right bank are the Cabaçal, Jauru, Sepotuba and Corixó Grande rivers, and on the left bank are the Cuiabá, São Lourenço, Correntes, Taquari, Negro, Aquidauana, Miranda, and Apa rivers. Both the Paraguay river and its tributaries descend from the uplands, carrying water mostly from the high parts of the north and east of the UPB and, when reaching the Pantanal, they encounter an extremely flat terrain. The main channel of the rivers presents smaller depths (lower margins) and small slopes as they advance over the Pantanal, resulting in small flow velocities. During periods of flooding, channels are unable to conduct runoff, and extensive areas of the plains get inundated, covering wetland areas that can range from 10000 to 110000 km² every year (Hamilton et al., 1996b).

At the upland stations (stations 1, 2 and 3) the response between the onset of rainfall and the increase in flows is more immediate. At the floodplain stations (stations 4, 5 and 6) there is a noticeable delay between the peak of rainfall and the peak of water flows. At stations such as Porto Conceição (4), Porto do Alegre (5), and Amolar (6), the peak water flow occurs approximately 3-5 months after the peak of the rainy season. This demonstrates the extremely slow hydrological response of the Pantanal floodplain to rainfall.

5.3. Data and Methods

In Fig. 23, the flowchart of the methodology employed in this research is presented. The processing of Landsat 8/9 and Sentinel-2 images and the obtention of time series of spectral properties were conducted within the GEE platform. Subsequently, ANN models were developed in MATLAB and later implemented in the GEE, enabling the production of SSC maps for all water pixels in the Pantanal region inside this cloud-based platform.

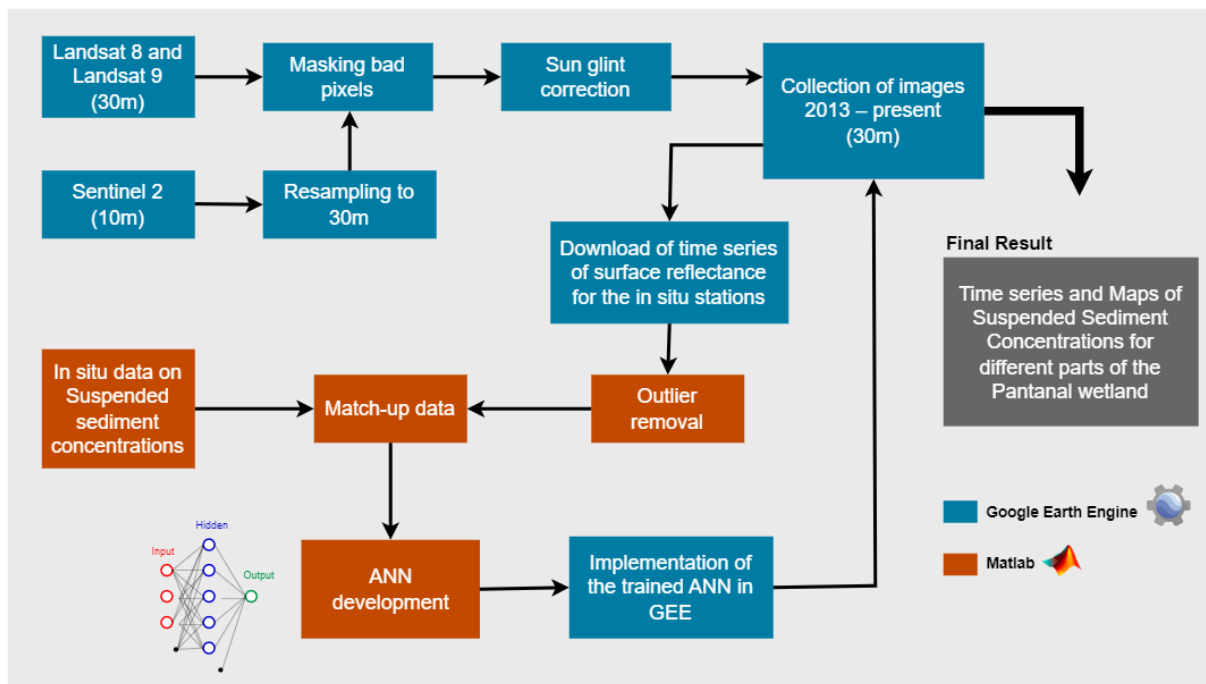


Fig. 23 - Flowchart of the methodology

5.3.1. *In situ* data

We selected 22 streamflow gauging stations located on rivers with a width greater than 70 meters. These stations have *in situ* data on SSC, flow, and precipitation, which are made freely available by the National Water and Sanitation Agency (www.hidroweb.ana.gov.br). The flow and precipitation data are available on a daily scale, but the SSC is measured about 2 to 4 times per year. Therefore, *in situ* data on SSC for each station is very limited.

Furthermore, we used data on SSC calculated by a regional ANN-based model, developed specifically for the Pantanal hydrographic region in Campos and Pedrollo (2021). In this study, the model provided highly accurate estimates of SSC by incorporating *in situ* measurements of turbidity and flow, along with remote sensing data, including rainfall data, drainage area, soil type, land use, and mean catchment slope. Despite the regional model's capability to enhance SSC information along the Pantanal rivers, it relies on the turbidity variable, which is only estimated at a few streamflow gauging stations and on a quarterly or larger temporal scale.

After combining all available SSC data, the 22 selected stations resulted in 510 records of SSC from 2013 to the present, i.e., approximately 23 SSC records per streamflow gauging station. This highlights the significant scarcity of SSC data in the Pantanal stations, which remains even when adding SSC data resulted from the application of the ANN model (Campos e Pedrollo, 2021) that uses turbidity data.

5.3.2. Acquisition and processing of satellite imagery

We used satellite images from Landsat-8, Landsat-9 (Operational Land Imager - OLI), and Sentinel-2 (Multi-Spectral Instrument - MSI) sensors. Landsat-8 and Landsat-9 are operated by NASA and the United States Geological Survey (USGS). These sensors produce multispectral images with a spatial resolution of 30 meters for most bands. Landsat-8 was launched in 2013, and Landsat-9 in 2021. The revisit time for Landsat-8 and Landsat-9 is 16 days each, or 8 days when used as a constellation. The Landsat data used corresponds to Collection 2, Level 2, providing surface reflectance values after atmospheric correction using the Landsat Surface Reflectance Code – LaSRC (Vermote et al., 2018, 2016).

Sentinel-2, operated by the European Space Agency (ESA) as part of the Copernicus program, is a constellation of two satellites (Sentinel-2A and Sentinel-2B) that capture multispectral images with a spatial resolution of 10 meters for most bands. Sentinel-2A was launched in 2015, and Sentinel-2B in 2017, providing a revisit time of 5 days together. The Sentinel-2 data used corresponds to Level-2A, which includes atmospherically corrected surface reflectance images using the Sentinel-2 Atmospheric Correction Processor - Sen2Cor (Main-Knorn et al., 2018).

The selection and preprocessing of Landsat-8/9 and Sentinel-2 images in this study were performed using the GEE platform, a free platform for geospatial data analysis and visualization based on a web code editor in JavaScript (<https://code.earthengine.google.com/>). GEE offers an extensive archive of satellite images, including Landsat-8, Landsat-9, and Sentinel-2. All available images within the study area from Landsat-8/9 Level 2 and Sentinel-2 Level 2A with up to 50% cloud cover were selected for further analysis. In total, there are 8699 images for Landsat 8/9 and 42366 images for Sentinel-2 within the study area, easily acquired using the GEE platform.

The Sentinel images were resampled to a spatial resolution of 30 meters to be consistent with the Landsat images. Bad pixels (clouds, cloud shadows, or saturated pixels) were masked based on the following approach: (1) For Landsat images, the QA_PIXEL band was used, containing pixel quality attributes generated with the CFMASK algorithm (Foga et al., 2017). Pixels with cloud, cirrus, or cloud shadow attributes were masked. Additionally, only pixels classified as water were kept. (2) For Sentinel 2 images, the Scene Classification Map (SCL), Cloud Probability Map (MSK_CLDPRB), and QA60 bands were used to mask bad pixels and to keep only pixels classified as water. Additionally, the MNDWI (Modified Normalized Difference Water Index) was used to complement the water mask (Xu, 2006).

As some of the images were identified as affected by sunglint, a simple correction method was applied by subtracting the Short-Wave Infrared (SWIR) band reflectance values of each pixel from the visible and near-infrared bands. This was based on the assumption that the radiance leaving the water in the SWIR range is zero, so any SWIR signal appearing in the image could be attributed to sunglint (Kay et al., 2009). The method proved to be efficient in visual inspection and has been applied in other studies with good results (Kuhn et al., 2019). All the preprocessing developed within GEE was programmed in JavaScript and the code is available in Appendix 2.

Finally, time series of surface reflectance in the green, red, and near-infrared bands were downloaded for the locations of the 22 streamflow gauging stations. To determine the reflectance from a satellite image, the median reflectance of pixels within a region defined with a radius of 500 meters around the location of an in-situ station was used, considering only water pixels, as shown in the region in Fig. 24.

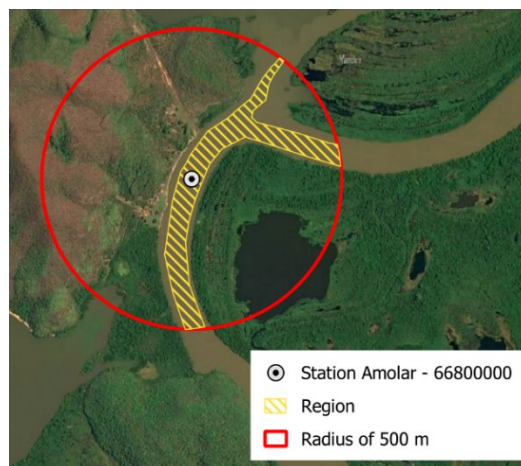


Fig. 24 - Region of influence of the streamflow gauging station

To combine Landsat-8/9 and Sentinel-2 images, many studies perform band harmonization using various methods, with the most common being simple linear regression to adjust spectral bands (Masek et al., 2015; Hafeez et al., 2022). However, although there are already harmonized products available for Landsat-8/9 and Sentinel-2, such as the NASA product titled "The Harmonized Landsat and Sentinel-2 surface reflectance dataset" (Claverie et al., 2018), these products are not available within the GEE platform. Thus, the use of these products would not align with one of the main purposes of this study, which is to utilize the GEE platform and perform all processing steps directly in the cloud.

In Appendix 3, a spectral consistency assessment is presented for matching bands of Landsat 8/9 and Sentinel 2. Pixel pairs from the same date within the regions of influence of

the in-situ stations were selected for this assessment. Spectral band differences were measured in terms of the root-mean-square error (RMSE), the mean absolute percentage error (MAPE), and the median difference (MD). Given the relatively small differences observed for water pixels in the green, red, and NIR bands, we decided to use the original spectral band sizes for the images.

Once we obtained the time series of surface reflectance, the in-situ dataset was matched with the respective reflectance data in the green, red, and NIR bands to develop the ANN models. In total, 215 match-up data points were identified. For stations in the Pantanal floodplain, we considered a tolerance of up to 5 days difference between the in-situ date and the satellite overpass date, as river concentration times in the floodplain typically span weeks. For stations upstream of the floodplain, we adopted tolerances of up to 2 days.

5.3.3. ANN model development

Multilayer perceptron models were used with a three-layer architecture, constituting an input layer, a hidden layer, and an output layer, all with a unipolar sigmoid activation function. The output corresponded to SSC, and the inputs included reflectance values from the green, red, and near-infrared bands, along with a binary indicator to identify the satellite (0 for Landsat 8/9 and 1 for Sentinel-2). We included a binary indicator in the ANN models to differentiate between the two satellite datasets. This allowed the model to internally perform spectral adjustment during synaptic weight tuning, effectively accounting for any differences in spectral characteristics between Landsat 8/9 and Sentinel 2 data.

Additionally, we included a binary indicator in the ANN models to differentiate between the two satellite datasets. This allowed the model to internally perform spectral adjustment during synaptic weight tuning, effectively accounting for any differences in spectral characteristics between Landsat 8/9 and Sentinel 2 data.

The synaptic weights and biases of the ANNs were adjusted using the backpropagation algorithm (Rumelhart et al., 1986) on the training sample, while avoiding overfitting through the cross-validation technique applied to the validation subset (Hecht-Nielsen, 1990)(Rumelhart et al., 1986). In this technique, the error obtained in the last layer is backpropagated to the previous layers progressively. It is based on the approximation given by the gradient descent of the errors, applied to progressively minimize the loss function value. We used 200,000 cycles for the training, with previous interruption when the performance of

the validation sample started to decrease, while the performance of the training sample continued to increase, indicating overfitting. Twenty repetitions of the training were performed to consider the variability resulting from the initial randomness of the synaptic weights, and the ANN whose training resulted in the best validation performance was chosen.

The training of the ANN models was performed using a k-fold cross-validation approach with $k=5$. In this approach, five ANN models were developed using different subsets of data samples. The data was divided into five subsets (or folds) of approximately equal size (20% of the total dataset in each). The 215 pairs of data were separated using systematic sampling, ensuring that all subsets contained data from all stations. The minimum and maximum values were always included in the training sample. In each iteration, four subsets were used to train the model (three subsets for training and one for cross-validation), while the remaining subset was used for final performance verification. This process was repeated five times, ensuring that each subset was used for final verification once. This approach provided a more reliable estimation, considering different combinations of training, validation, and verification data. Once trained, the ANN models were submitted to a new verification sample common to all, so that they could be compared graphically. The final estimated value for SSC was always an average of the five estimated values in each model.

Regarding the number of neurons in the hidden layer, we followed the concept of parsimony presented by Sari et al., (2017). The ANN models were trained by reducing the number of neurons in the hidden layer until a reduction in validation sample performance occurred. Then, the previous alternative with sufficient degrees of freedom was selected, providing more parsimonious ANN models that require less computational capacity.

Model performance was evaluated for the five developed models, as well as the average of the statistics resulting from the five models, using the following performance statistics:

Mean Absolute Error (MAE) - which corresponds to the average of the absolute differences between the model estimates and the observed values. Lower MAE values indicate a better fit of the model to the observed data, as it indicates that the predictions are closer to the actual values.

Coefficient of Determination (R^2) - which corresponds to the proportion of data variability explained by the model. It ranges from 0 to 1, where 1 represents a perfect match between the variance of model estimates and the observed values. R^2 is calculated as the proportion of the sum of squared deviations explained by the model relative to the total sum of squared deviations

from the mean of the observed values. A value of R^2 closer to 1 indicates a model that explains a higher proportion of data variability.

After training, the ANN functions were converted from MATLAB to JavaScript for use in the Google Earth Engine. This allowed the application of the equations to Landsat 8/9 and Sentinel-2 satellite images, enabling the estimation of suspended sediment concentration in all water pixels in the Pantanal area.

The results were presented through maps showing quarterly average SSC in pixels identified as water, as well as graphs depicting the monthly average concentrations of sediments, flow, and rainfall for specific streamflow gauging stations. This approach enabled the analysis of the relationship between seasonal rainfall, flood pulses, and suspended sediments.

5.4. Results and Discussions

5.4.1. Performance of the ANN models

The final architecture of the ANN-based models implemented in this research are presented in Fig. 25. The input variables are surface reflectance in the green band (SR green), red band (SR red), near-infrared band (SR NIR), and a binary indicator related to the satellite. The minimum complexity that the ANN-based models needed to model the SSC from the spectral bands of the satellite images was 5 internal neurons. Less complex networks lost their ability to generalize, deteriorating performance in the validation sample. The GEE JavaScript code of the 5 ANN models already trained is available in Appendix 2.

The statistical performance of the 5 trained models is presented in Tab. 11. The results are shown for the training, validation, and verification samples.

Tab. 11 - Performance statistics of the 5 ANN models

Nome	Training		Validation		Verification	
	MAE (mg/L)	R^2	MAE (mg/L)	R^2	MAE (mg/L)	R^2
ANN 01	11.05	0.95	11.04	0.96	18.72	0.83
ANN 02	12.12	0.94	14.73	0.85	9.56	0.95
ANN 03	12.45	0.92	16.31	0.93	16.25	0.82
ANN 04	16.19	0.87	16.53	0.82	17.94	0.92
ANN 05	16.52	0.88	14.99	0.89	16.91	0.81
Average	13.80	0.91	14.73	0.89	15.88	0.86

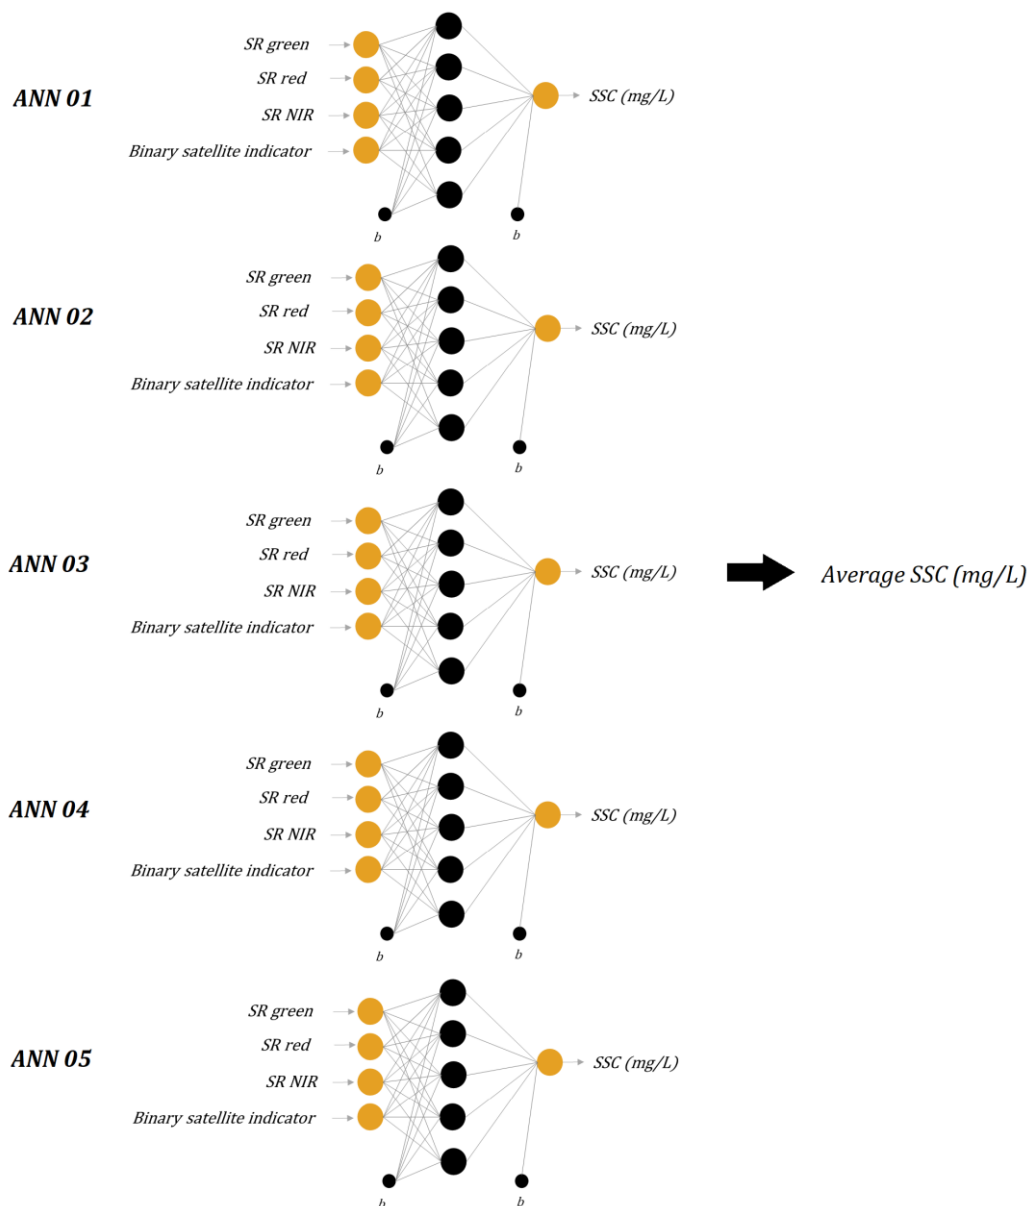


Fig. 25 - Architecture of the k-fold ANN models

The estimated SSC resulting from the average of the five models exhibits a very satisfactory performance for models related to suspended sediments (Moriasi et al., 2015), with a coefficient of determination of 0.86 and a mean absolute error of 16 mg/L, considering the verification sample. These values indicate that the models capture the variability of SSC magnitudes (which are related to spatial and temporal variations in SSC across the study area), with a reasonable average error that is comparable to the error of in-situ measurements (Carvalho, 2008).

As explained before, each ANN model was trained with a different training and validation subset, and then checked with the verification sample, resulting in the performance statistics shown in Tab. 11, according to the traditional k-fold procedure. Fig. 26 shows the observed and calculated SSC values of the 5 ANN modes in the final verification sample. The estimates of the five models are quite similar, and larger errors occur for higher magnitudes of SSC.

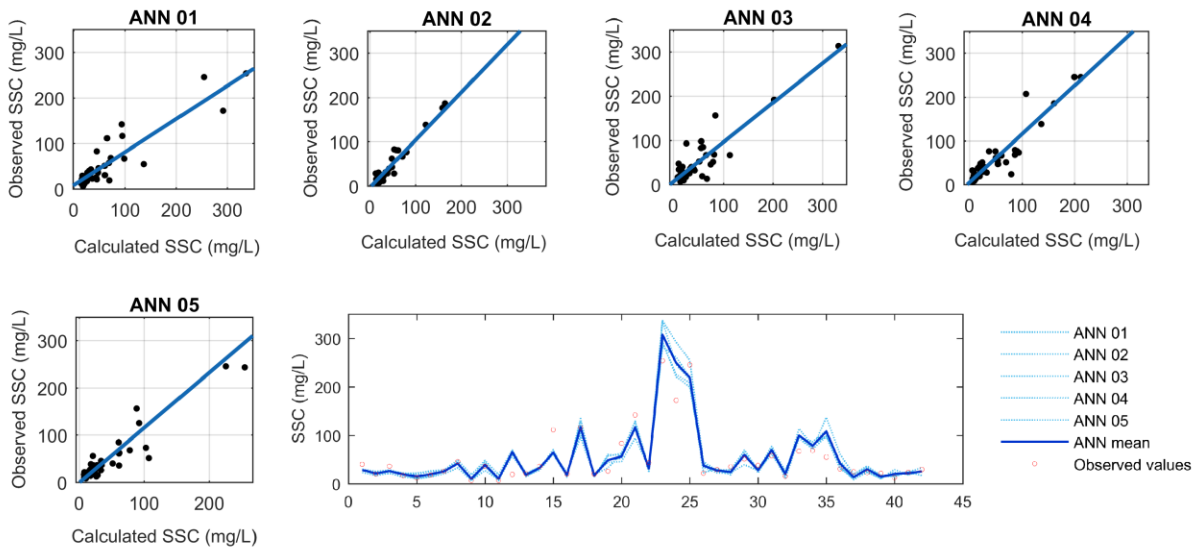


Fig. 26 - Fit between observed and calculated data for the 5 ANN models within the verification sample.

5.4.2. Spatio-temporal dynamics of SSC in the Pantanal

Fig. 27 shows the time series of SSC generated for the Cuiabá (1), Acima do Córrego Grande (2), Coxim (3), Porto Conceição (4), Porto do Alegre (5), and Amolar (6) gauging stations. The time scale of the time series is irregular, and depends on the day the satellite passed over without the interference of clouds. Each time series has approximately 360 records per station, ranging from 2013 to December 2022, which is far more than the in-situ data available. Overall, the ANN-based models satisfactory estimated time series of SSC at the analysed stations. According to the results of the ANN models in the calculated SSC time series, greater divergences between the values estimated in each model appear at the peaks, and the minimum SSC values estimated by the models are very similar.

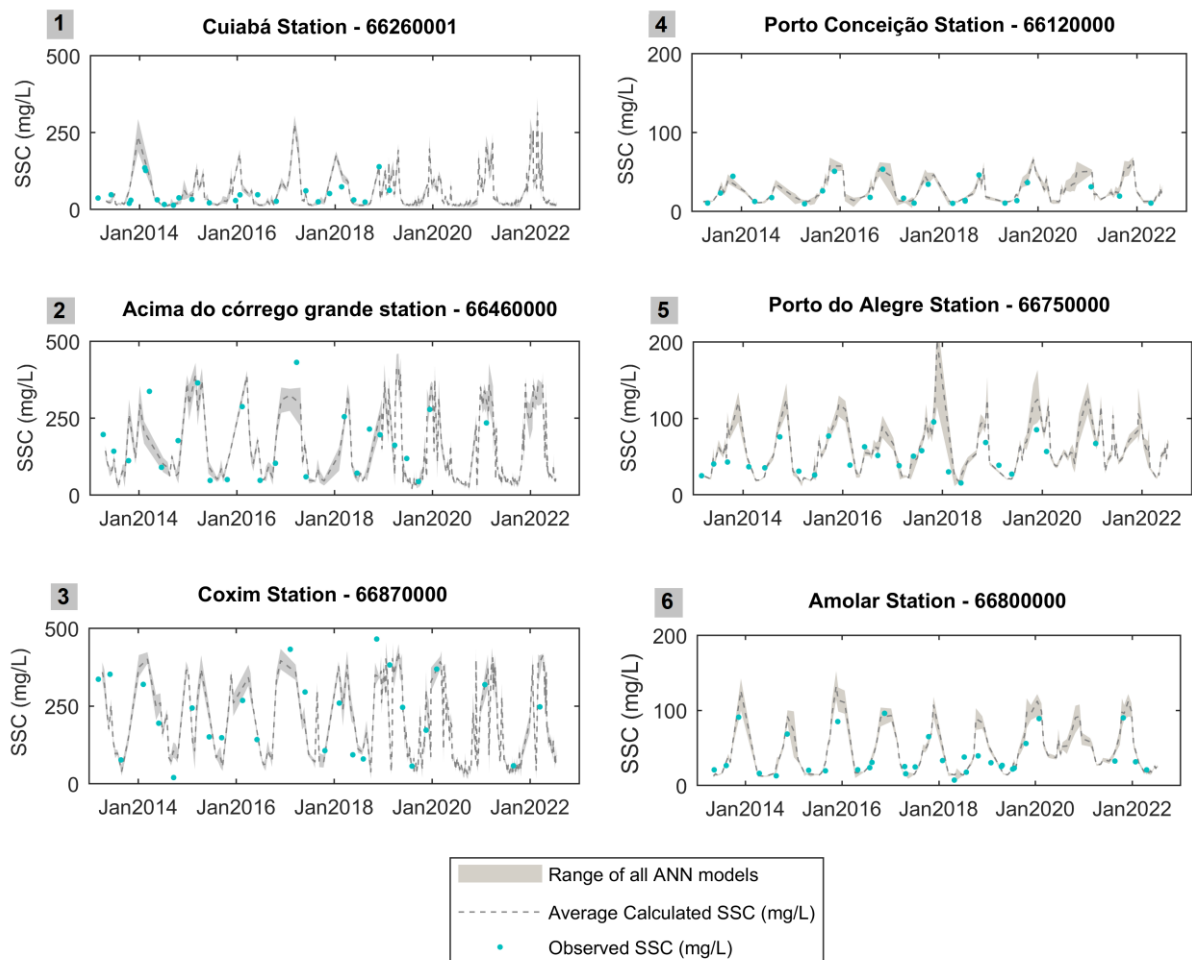


Fig. 27 - Time series of SSC calculated at the Cuiabá (1), Porto Conceição (2), Acima do Córrego Grande (3), Porto do Alegre (4), Coxim (5) and Amolar (6) gauging stations. The SSC scale on the y-axis is different for upland stations (stations 1, 2 and 3) and floodplain stations (4, 5 and 6).

An annual seasonal pattern of SSC is observed at all stations due to rainfall and flows seasonality. As rainfall is one of the main drivers of erosion and, through surface runoff, carries eroded sediments from the uplands to the rivers, it is expected that the onset of rainfall will cause an increase in SSC in the rivers of the Pantanal hydrographic region.

The magnitude of SSC at the upland stations (Cuiaba, Acima do Córrego Grande and Coxim) is higher than at the floodplain stations (Porto Conceição, Porto do Alegre and Amolar). The Taquari and São Lourenço rivers have the highest monthly SSC averages, which can reach about 400 mg/L. Even higher values can be observed in these rivers, with daily SSC of up to 1000 mg/L during intense rainfall events (Fantin-Cruz et al., 2020). The presence of more erodible soil types, associated with low vegetation cover in these basins and inadequate land use management are the factors behind the high SSC in these rivers (Campos e Pedrollo, 2023).

At the stations located on the floodplain, lower magnitudes of SSC are observed, especially at the Porto Conceição station, located on the Paraguay River before its confluence

with the Cuiabá River, with a maximum monthly average SSC of 50 mg/L. The results for the Porto do Alegre station, located on the Cuiabá River at the Northern Pantanal floodplain, indicate higher SSC magnitudes, reaching 100 mg/L average monthly SSC. Finally, the Amolar station, located on the Paraguay River downstream of its confluence with the Cuiabá River, is clearly influenced by sediment input from the Cuiabá River. The SSC magnitudes in this stretch are higher than in the upstream stretch and are similar to the SSC observed at the Porto do Alegre station in the Cuiabá River.

Corroborating the results of the time series, the quarterly maps indicate a strong seasonality for SSC, both in the upland (Fig. 28) and in the floodplain stations (Fig. 29). When we compare the results of the stations located in the upland with those in the floodplain, it is possible to observe that the amplitude of variation of the SSC is greater in the upland stations. Monthly average SSC values range from around 80 mg/L to over 400 mg/L every year in the Taquari and São Lourenço rivers. In the Cuiabá Station (1), the variation is between 30 mg/L and 350 mg/L.

In the floodplain stations (Fig. 29), the annual variation is smaller, ranging from values close to 10 mg/L in the Paraguay River stations, and not exceeding 100 mg/L. The floodplain station located on the Cuiabá River downstream (5) shows a slightly greater variation, due to the input of sediment from the Cuiabá River itself, as well as from the São Lourenço River, which joins the Cuiabá on the northwest floodplain road.

The river-floodplain system in the stretch of the Paraguay River upstream of the meeting with the Cuiabá River has a lower magnitude of SSC compared to the downstream stretch. This indicates that the Cuiabá River confluence is the main source of suspended sediment in this region of the Pantanal.

The Cuiabá River has a smaller catchment area compared to the Paraguay River, yet it produces a higher concentration of suspended sediment, with well-developed marginal dykes and a sinuous channel pattern containing coarser (sandy) bed material. In contrast, the Paraguay River has a larger hydrographic basin, retains most of the sediment in the riverbeds (river-plain system), does not have marginal dykes in some stretches, has multiple channels with a high width/depth ratio and greater interaction with lake environments than the Cuiabá River (Luz, 2019).

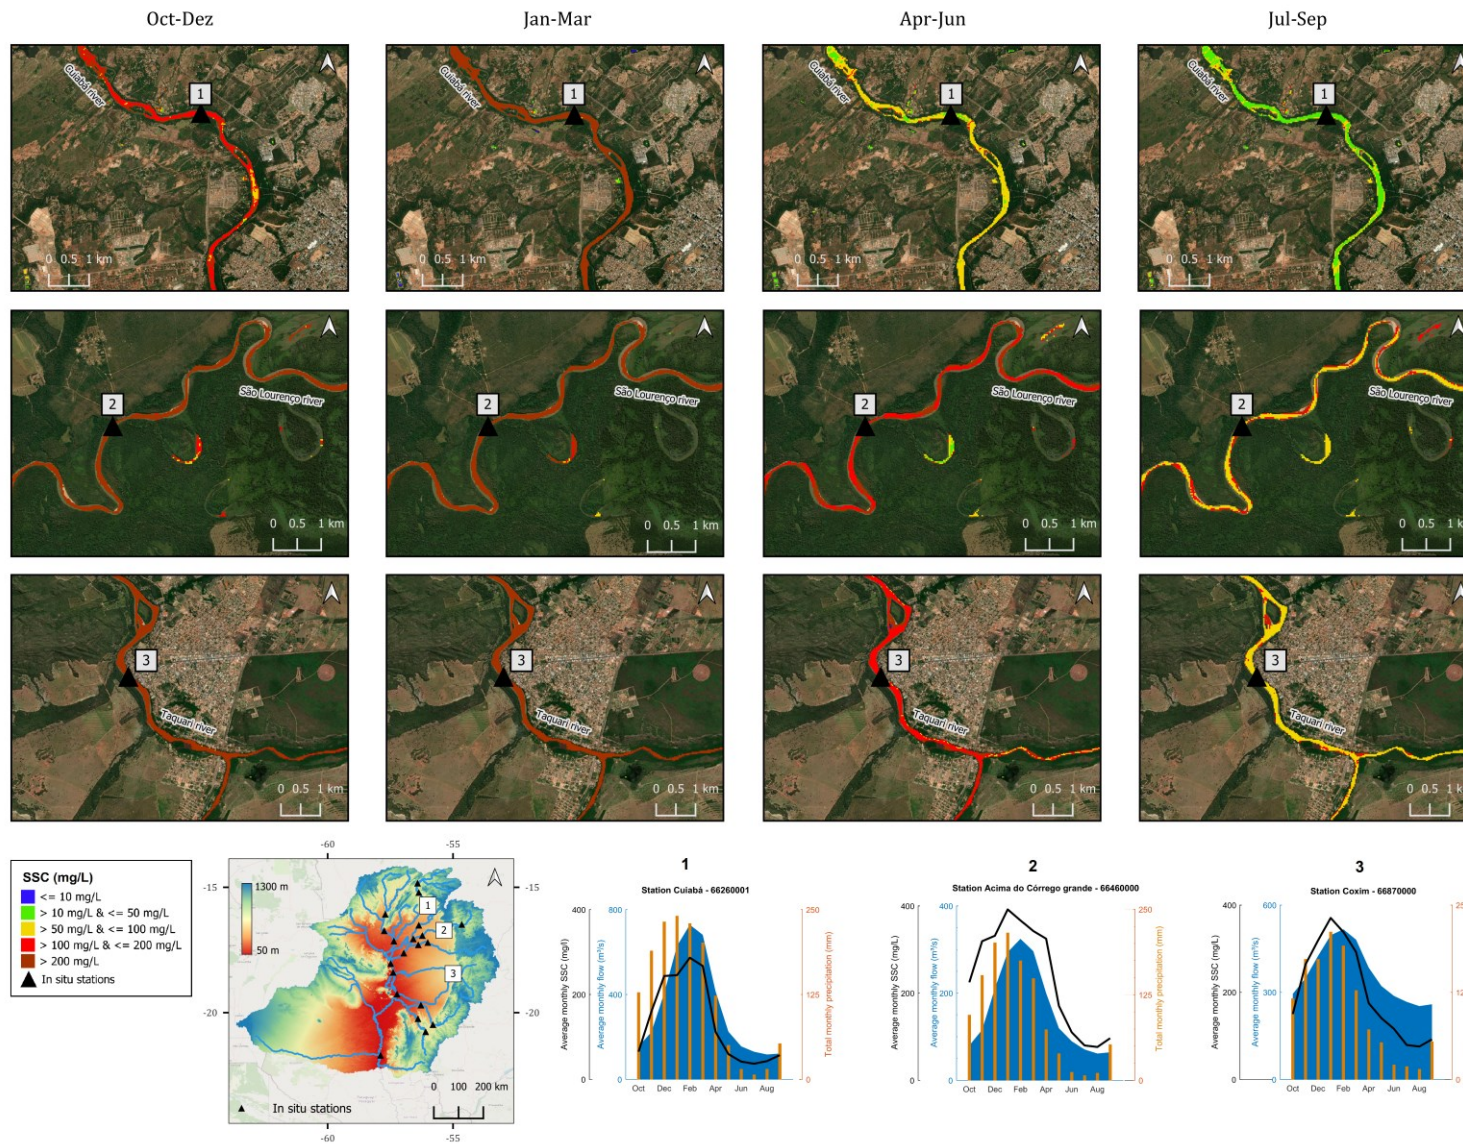


Fig. 28 - Quarterly SSC mapping for upland stations

Evaluating the quarterly SSC results, it can be seen that the upland rivers show a more immediate response to rainfall - flows - SSC. In the quarter from October to December, when the rainy season begins, both flows and SSC also begin to increase. In the quarter from January to March, when the rainy season peaks, this is also when flows and SSC peak. As the dry season approaches (April to September) flows and SSC also decrease.

For the Pantanal floodplain, SSC throughout the river-floodplain system (including lakes) also begins to increase. However, unlike the upland rivers, the peak SSC occurs in November in all three floodplain stations, while the peak in the upland rivers occurs in January-February, along with the peak rainfall. Although November is already a month within the rainy season, flows in the Pantanal floodplain are still very low (low water period). Therefore, the higher SSC observed in this period is related both to the start of the rainy season and the consequent influence of erosion caused by the rains, and to the flows which are still lower at this time in the floodplain.

Although January to March is the quarter with the highest monthly rainfall for the entire river basin, SSC begins to decrease in the Pantanal floodplain. The more the Pantanal floods, the SSC inversely decreases. The lowest SSC was observed in the quarter from April to June, which corresponds to the peak of the flooding period in the Pantanal. Floods, in turn, occur around 3-4 months after the peak of the rainy season. It can also be seen that the average monthly SSC begins to increase around April, coinciding with the start of the recession of the flow hydrograph. During this period, rainfall indices are low, so the increase in SSC during this period is probably more related to the change in flows. This seasonal and inverse relationship between flow and SSC is very specific to the Pantanal, and had never been described before this research.

The description of this process within the Pantanal wetland is important once SSC are important carriers of nutrients and pollutants to the floodplain, directly influencing water quality and the ecosystem as a whole. Therefore, changes in the quality and quantity of these sediments can have negative consequences for the Pantanal floodplain.

It is currently possible to list at least 4 possible threats to the Pantanal, which are directly or indirectly related to sediment dynamics: 1) changes in land use and increased erosion; (2) changes in the rainfall cycle due to climate change; (3) changes in sediment and water quality; (4) the construction of dams on tributary rivers, which interrupt the connectivity between upstream and downstream and can both modify the flood cycle and cause a reduction in sediment input down the river.

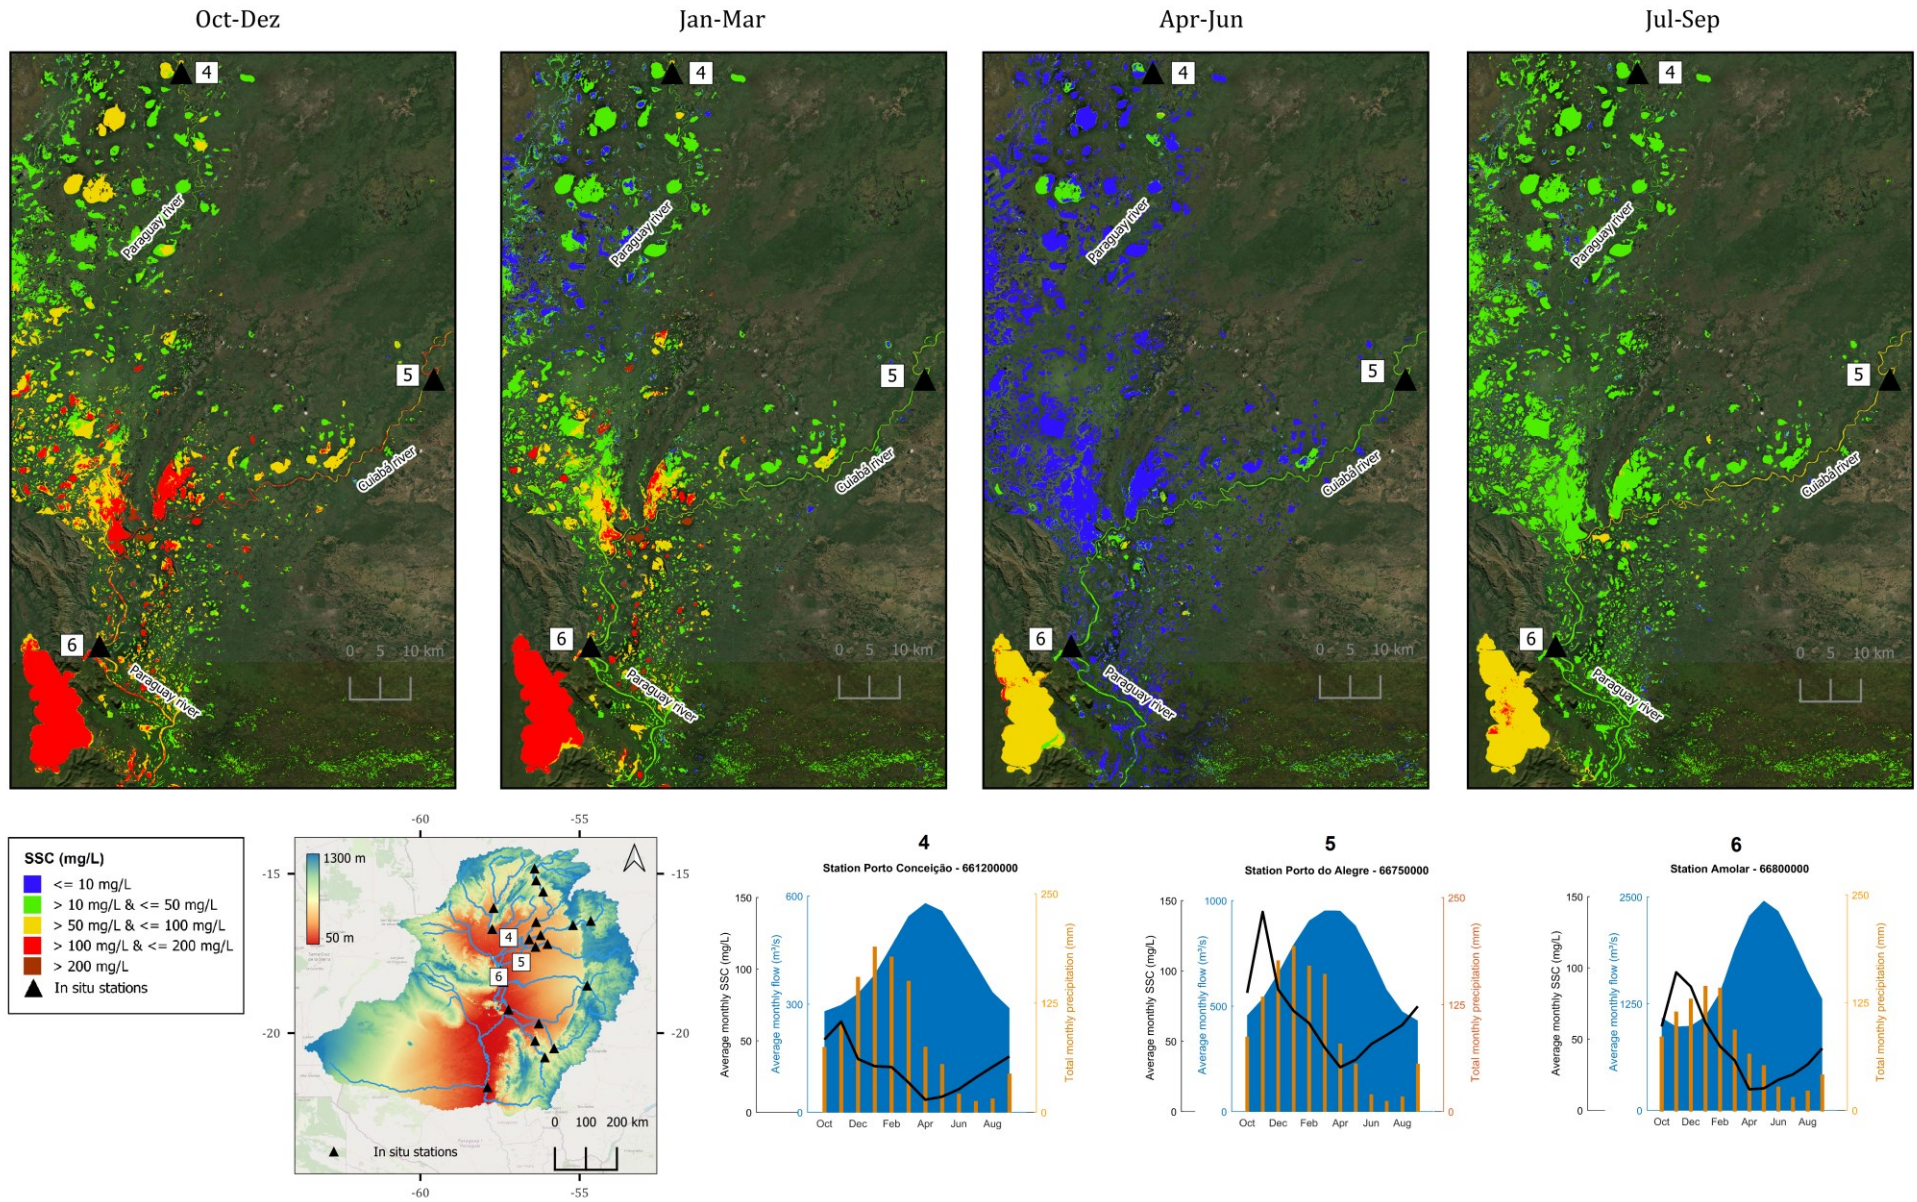


Fig. 29 - Quarterly SSC mapping for floodplain stations

In fact, the proliferation of small hydroelectric plants (SHPs) on the tributary rivers of the Pantanal has attracted research to identify the possible impacts of these projects on the lowland ecosystem. In 2018, there were already 53 projects (7 HPPs, 16 CGHs and 30 SHPs), plus another 127 new hydroelectric projects (the vast majority of which are SHPs) under construction, planned, proposed or identified by the government as potential sites, according to the RH-Paraguay Water Resources Plan (ANA, 2018, 2020). According to recent studies, future SHPs would reduce the transport of suspended sediments by around 62% (Fantin-Cruz et al., 2020; Campos e Pedrollo, 2023) and reduce the transport of phosphorus by around 29% (Oliveira et al., 2020) towards the Pantanal plain.

Therefore, the mapping of SSC dynamic presented in this study reinforces the interdependence between the upland and the floodplain, as well as the influence of the region's natural seasonality. These results constitute an important tool for the proper and sustainable planning and management of water resources in the basin.

Even with satisfactory results, the method implemented is subject to some limitations, such as the lack of in-situ data in the Pantanal lakes, so the results observed in the lakes are not validated. Another limitation is the low number of in-situ records used to train the neural networks (215 records). Another limitation is the low number of existing in-situ records to train the neural networks (215 records), which, although sufficient for modeling, could, in greater quantity, provide even more reliable results.

The crucial aspect for the development of the Pantanal biome is the relationship between the uplands and the floodplain. Most of the water supply that sustains the flood pulse in the Pantanal originates from the upland basin's areas. Similarly, the sediments deposited in the Pantanal floodplain, due to its extremely flat terrain and low flow velocities, are primarily originated in the uplands (ANA, 2018).

Given this strong interdependence between the uplands and the floodplain, any threats to the upland areas, such as unsustainable land use and occupation, especially in livestock and agriculture activities that neglect sustainable management and conservation, intense deforestation, and the installation of hydroelectric projects in the tributary rivers, also pose significant negative impacts to the Pantanal floodplain. Ecosystems within the floodplain are uniquely adapted to live with inundation. Pantanal riverine and floodplains are uniquely adapted to live with pulses of inundation. Many riparian plants have life histories dependent on floods and exploit the energy and nutritional benefits of such events. Floodplains host bird and fish

species specially tuned to floodplain conditions and annual inundation. Knowing the routine inundation and how it takes place in hydro-physical and sedimentological functioning helps to develop an adaptive framework to guide project design and restoration (Mitsch, 2023).

Therefore, comprehending the spatio-temporal dynamics of sediments in the rivers of the UPB through satellite imagery is a crucial tool for assisting managers and policymakers in addressing the challenges arising from land use and occupation advances in the upland regions, the potential impacts of future hydroelectric projects planned for the area, as well as the effects of climate change.

5.5. Conclusions

This research has mapped the dynamics of suspended sediments concentration in the river-plain system of the Northern Pantanal, using the Google Earth Engine (GEE) platform in conjunction with images from the Sentinel-2A/2B and Landsat-8/9 satellites, and artificial neural network models. The methodology used provided an unprecedented spatial and temporal characterization of sediment dynamics in the region.

The artificial neural network (ANN) models developed in this study performed satisfactorily in estimating SSC. Analysis of the time series generated for the stations located in the uplands and floodplain showed that the ANN models adequately represented the seasonal behavior of suspended sediment concentration, even in stretches of river with different geomorphological characteristics.

The results highlight the influence of hydrological seasonality on the sediment transported. The October-December quarter showed the highest concentrations of sediment in the rivers and lakes of the Pantanal floodplain. This period coincides with the onset of the rainy season, and the lowest flows. On the other hand, the April-June quarter, corresponding to the seasonal flooding in the floodplain and the lowest rainfall rates, showed the lowest SSC. Furthermore, it was observed that the Cuiabá River plays a fundamental role as the main source of suspended sediment for the Pantanal region studied.

Overall, the results obtained in this study contribute to a better understanding of the dynamics of suspended sediments in the Pantanal floodplain. Hydrological seasonality, river characteristics and the influence of tributaries proved to be determining factors in the spatial and temporal distribution of suspended sediments in the region. This information is essential

for planning adequate monitoring and management of water resources and ecosystems in the Pantanal.

Therefore, this study contributes to the understanding of the spatial and temporal dynamics of suspended sediment in the rivers draining into the Pantanal wetland, which has remained poorly characterized thus far. Furthermore, we have developed a robust and straightforward methodology using ANN-based models within the Google Earth Engine platform. This methodology enables the analysis of freely available satellite data from Landsat-8, Landsat-9, and Sentinel-2A and 2B. The combination of these four sensors provides a novel perspective in remote sensing applications for terrestrial monitoring. Together, they offer global coverage of multi-spectral data at a spatial resolution of 30 and meters, respectively, with a high frequency of temporal revisits. This enhanced dataset allows for more comprehensive and frequent monitoring of Earth's surface dynamics.

6. RIOS DO SISTEMA RIO-PLANÍCIE DO PANTANAL: DISPONIBILIDADE DE DADOS *IN SITU*, PRESENÇA DE PCHs NAS CABECEIRAS E DINÂMICA ESPAÇO-TEMPORAL DE SEDIMENTOS

Nesta Tese de doutorado foram abordadas questões relacionadas à escassez de dados *in situ* de sedimentos em suspensão nos rios da bacia do Alto Paraguai, à identificação e avaliação de como as pequenas centrais hidrelétricas afetam variavelmente o transporte de sedimentos, e a caracterizar a dinâmica espaço-temporal dos sedimentos em suspensão nos principais rios tributários do Pantanal a partir de imagens de satélite.

Neste sentido, o presente capítulo é apresentado na forma de um manuscrito final, cujos principais avanços e resultados obtidos por meio dos 3 primeiros artigos da Tese são destacados e apresentados para as principais sub-bacias da bacia do Alto Paraguai.

6.1. Introdução

A bacia hidrográfica do Alto Paraguai (BAP), que abriga o Pantanal, a maior área úmida tropical do mundo, destaca-se por seu ciclo anual de inundações e pela exuberante biodiversidade que a caracteriza. As características geomorfológicas e hidrológicas singulares conferem ao Pantanal a distinção de um dos ecossistemas mais complexos e fascinantes do planeta.

A dinâmica das inundações no Pantanal está intrinsecamente vinculada à geomorfologia da planície e ao regime hidrológico sazonal. As inundações periódicas resultam do padrão de chuvas, com a estação chuvosa de outubro a março, seguida pela estação seca de abril a setembro. Apesar do início das chuvas em outubro, os primeiros sinais de enchente na planície só se manifestam a partir de janeiro, devido à defasagem na resposta entre a precipitação e o aumento do nível da água (Padovani, 2010).

Apesar das importantes contribuições já existentes em relação à geomorfologia e à dinâmica de inundações no Pantanal (Hamilton et al., 1996b; Hamilton, 2002a; Padovani, 2010; Fantin-Cruz et al., 2011; Luz, 2019; Jean Milien et al., 2023), a dinâmica espaço-temporal dos sedimentos em suspensão nos rios, assim como os fatores determinantes dessa dinâmica, permanecem pouco explorados e descritos na literatura.

Sendo assim, nesta pesquisa buscou-se preencher lacunas relacionadas à escassez de dados hidrossedimentológicos *in situ*, por meio do primeiro artigo desenvolvido (Campos e Pedrollo, 2021). Nele, os dados de concentração de sedimentos em suspensão (CSS) foram

estimados com base em informações mais acessíveis, como os níveis de turbidez e outras obtidas por meio de dados de sensoriamento remoto. Isso permitiu um aumento significativo nos dados de CSS para a BAP. Além disso, neste estudo foram considerados os impactos atuais e futuros dos empreendimentos hidrelétricos no transporte de sedimentos ao longo da BAP (Fantin-Cruz et al., 2020), bem como a forma como esses empreendimentos afetam o transporte de sedimentos (Campos e Pedrollo, 2023). Outro avanço foi a caracterização detalhada da dinâmica espaço-temporal da CSS a partir de reflectâncias de imagens multiespectrais de satélite e modelos de redes neurais artificiais (Campos et al., 2023). Essa sequência de estudos resultou em informações inéditas e relevantes para a região em estudo.

No entanto, percebeu-se a necessidade de uma descrição e avaliação detalhada dos avanços já obtidos para cada uma das sub-bacias que drenam para a planície de inundação do Pantanal.

Neste sentido, o objetivo deste manuscrito final é destacar os avanços na compreensão da dinâmica hidrossedimentológica da BAP, alcançados ao longo dos três primeiros artigos desta Tese, para as principais sub-bacias que drenam para o Pantanal. Isso possibilita uma análise das similaridades, diferenças e discussões relacionadas à hidrossedimentologia da BAP como um todo.

6.2. Materiais e Métodos

Os aspectos abordados em cada uma das sub-bacias da BAP englobam: i) a disponibilidade de dados *in situ* de sedimentos em suspensão e turbidez, ii) os impactos das pequenas centrais hidrelétricas no transporte de sedimentos para o Pantanal, e iii) uma caracterização detalhada da dinâmica espacial e temporal da concentração de sedimentos em suspensão. Cada um desses pontos é enfatizado nas principais sub-bacias que drenam para o Pantanal, proporcionando um aumento significativo no entendimento da hidrossedimentologia da bacia do Alto Paraguai como um todo.

A seguir, é apresentada a área de estudo, bem como o método empregado para avaliar cada um dos aspectos avaliados nas sub-bacias da BAP.

6.2.1. Área de Estudo

A área de estudo desta pesquisa é a BAP. Para este último artigo, os resultados são apresentados para as principais sub-bacias que drenam para a planície de inundação do Pantanal (Fig. 30).

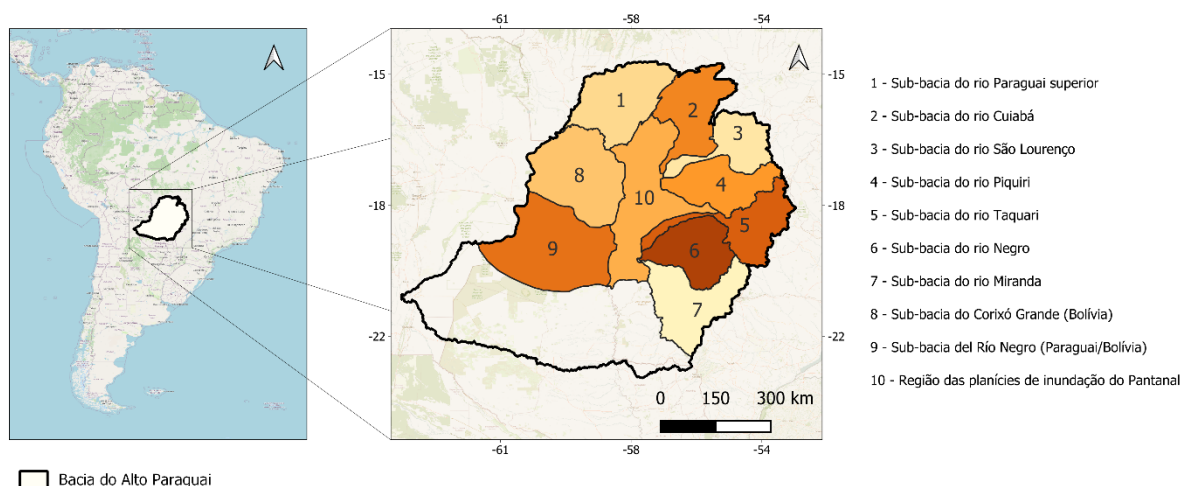


Fig. 30 – Área de estudo – Principais sub-bacias da bacia do Alto Paraguai

6.2.2. Avaliação quanto à escassez de dados *in situ* de turbidez e de sedimentos em suspensão

Para a avaliação da disponibilidade de dados *in situ*, foram consideradas todas as estações de qualidade da água e todas as estações fluviométricas com medições de sedimentos, localizadas nos rios principais de cada sub-bacia avaliada. Foram levantadas a quantidade de medições de turbidez e de concentração de sedimentos em suspensão em cada estação *in situ* identificada, e o início do período de monitoramento.

Além disso, para ampliar a disponibilidade de dados de CSS ao longo da BAP, os dados de turbidez das estações *in situ* foram utilizados para estimar CSS a partir do modelo regional, baseado em redes neurais artificiais (RNAs), desenvolvido no primeiro artigo desta Tese (Campos e Pedrollo, 2021). Todos os dados de turbidez obtidos de estações *in situ* cujas características qualitativas da área de drenagem estão dentro do domínio de estimativa das RNAs foram utilizados para calcular CSS, uma vez que o modelo regional baseado em redes neurais artificiais permite a estimativa de CSS a partir de dados de turbidez e outros dados

qualitativos que são obtidos por sensoriamento remoto. Os dados de turbidez e de CSS calculados estão disponibilizados no Apêndice 1.

6.2.3. Avaliação quanto à presença e prospecção de PCHs e à interferência no transporte de sedimentos

A bacia do Alto Paraguai possui atualmente 55 empreendimentos hidrelétricos em operação, e poderá receber mais 72 empreendimentos desse tipo, segundo dados atualizados do sistema SIGA da ANEEL, sendo que dois se encontram em fase de construção e outros 70 aguardando outras fases de análise do regulador, conforme Fig. 31.

Empreendimentos Hidrelétricos Sub-Bacia Alto Paraguai Base de Dados SIGA/ANEEL (Ago/2023)	
Estágio	Número de Empreendimentos
Em Operação	55
Construção com Outorga	2
Construção não iniciada	3
Despacho de Registro da Adequabilidade do Sumário Executivo - DRS	43
Projeto Básico Aceito	2
Registro de Intenção à Outorga de Autorização – DRI	2
Eixo Inventariado	20
Total de Empreendimentos	127

Fig. 31 – Inventário de empreendimentos hidrelétricos na bacia do Alto Paraguai. Fonte: SIGA/ANEEL (2023).

Para cada sub-bacia analisada, foram identificados os empreendimentos hidrelétricos atualmente em operação, bem como aqueles planejados para o futuro. Nessa análise foram considerados todos os projetos, desde os que estão na fase de eixo inventariado até os empreendimentos em construção com autorização concedida.

Para a identificação do impacto dos empreendimentos atuais e futuros, utilizou-se os resultados do modelo de redes neurais artificiais desenvolvido e apresentado em Fantin-Cruz et al. (2020). O modelo desenvolvido possibilitou a estimativa da alteração no transporte de sedimentos que cada barragem em operação na bacia do Alto Paraguai causa, a partir de dados de entrada de área de contribuição da bacia de drenagem, área do reservatório, volume útil do reservatório, tipos de solo, uso e cobertura da terra, e a concentração de sedimentos em suspensão à montante das barragens. As saídas dos modelos foram as alterações diárias da CSS, que foram utilizadas para estimar uma alteração mediana da CSS causada pela barragem. Sendo assim, a partir das características das barragens em operação, e de dados dos rios da BAP.

Estimou-se a alteração mediana as barragens previstas para o futuro. Maiores detalhes do desenvolvimento e performance do modelo são encontrados em Fantin-Cruz et al., (2020).

A partir do modelo, foi possível observar os impactos que as barragens atuais e futuras podem causar no transporte de sedimentos para o Pantanal. Estes resultados foram descritos para cada sub-bacia.

6.2.4. Avaliação da dinâmica espaço-temporal de sedimentos suspensos no rio principal

Por fim, foi feita uma análise mais localizada da variação temporal da CSS nas sub-bacias nos exutórios e/ou pontos de interesse nas sub-bacias que drenam para o Pantanal. As CSS foram calculadas a partir do modelo de RNAs desenvolvido no terceiro artigo desta Tese (Campos et al., 2023), que permitiu estimativas das CSS em todos os pixels de água ao longo da bacia do Alto Paraguai. Para cada sub-bacia da BAP, foram calculadas as CSS medianas mensais a partir do modelo de RNAs, e avaliadas quanto à sua variação temporal e quanto à relação com a sazonalidade hidrológica da região.

6.3. Resultados

Os resultados em relação ao panorama de disponibilidade de dados *in situ* de turbidez e sedimentos em suspensão, a presença de empreendimentos hidrelétricos e os impactos destas no transporte de sedimentos, bem como a dinâmica temporal da CSS mediana mensal nos exutórios das sub-bacias estudadas estão apresentados a seguir.

6.3.1. Sub-bacia do rio Paraguai superior

Os principais rios da sub-bacia do Paraguai superior são o próprio rio Paraguai, o rio Sepotuba e o rio Jauru. O exutório considerado para essa bacia localiza-se após a cidade de Cáceres-MT, logo após o encontro do rio Paraguai com o rio Jauru-MT. A altitude do ponto do exutório é de 112 m, ou seja, esse exutório já se encontra dentro do que é considerado Pantanal (cotas abaixo de 200 m), e o trecho do rio Paraguai nesse ponto já apresenta características bem acentuadas de rios de planície, com formação de meandros, grande largura, baixa profundidade, e baixas velocidades de fluxo. Na Fig. 32 e na Tab. 12, é possível observar a existência de 16 estações fluviométricas, sendo que apenas a estação 13, de Cáceres, monitora sedimentos. As demais monitoram apenas parâmetros de qualidade da água, incluindo a turbidez.

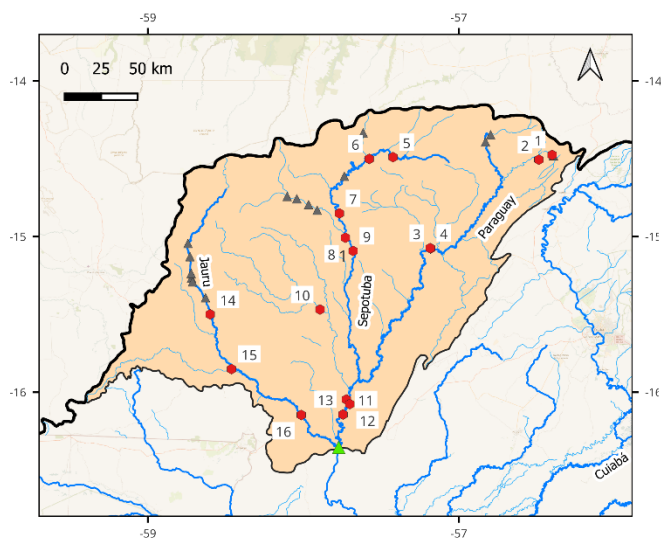
Observa-se a presença de 16 empreendimentos hidrelétricos em operação nas cabeceiras da bacia, sendo: 7 em cascata no rio Jauru-MT (de jusante para montante: PCH Figueirópolis, PCH Salto, PCH Indiavaí, UHE Jauru, PCH Ombreiras, PCH Antônio Brennand e, mais recentemente, a PCH Estivadinho 3, implementada em 2021); 4 em cascata no rio Juba (de jusante para montante: PCH Pampeana, PCH Graça Brennand, UHE Juba II e UHE Juba I), uma no rio do Sapo (PCH rio do Sapo), uma no rio Maracanã (PCH Maracanã), duas no rio Santana (PCH Santana e PCH Diamante), e uma nas cabeceiras do rio Paraguai (PCH Alto Paraguai).

Conforme as avaliações disponíveis em Fantin-Cruz et al., (2020), os empreendimentos hidrelétricos existentes no rio Jauru-MT reduzem em cerca de 22% o transporte de sedimentos em suspensão natural para jusante, e estima-se uma possível redução de cerca de 30% se os outros empreendimentos previstos fossem implantados. Para o rio Cabaçal, que atualmente não possui empreendimentos hidrelétricos, é prevista uma redução de cerca de 18% do transporte de sedimentos natural, caso os empreendimentos previstos sejam implantados. As hidrelétricas localizadas no rio Juba, no rio do Sapo e no rio Maracanã (ambos afluentes do rio Sepotuba) reduzem o transporte de sedimentos em 10% no cenário atual, e as hidrelétricas previstas para o futuro podem reduzir em cerca de 30% o transporte de sedimentos dessa sub-bacia.

Na análise da dinâmica temporal da CSS no exutório dessa sub-bacia, observa-se que abril é o mês com a CSS mediana mensal menor (12,8 mg/L), com um aumento progressivo até o pico, no mês de outubro (75 mg/L), cujas CSS são as maiores observadas.

Tab. 12 – Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 01 – Paraguai Superior

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66003000	ALTO PARAGUAI	PARAGUAI	09/05/1995	58	Não Monitora	0
2	66004000	ALTO PARAGUAI	PARAGUAI	09/05/1995	58	Não Monitora	0
3	66010000	BARRA DO BUGRES	PARAGUAI	30/06/2009	28	Não Monitora	0
4	66011000	BARRA DO BUGRES	PARAGUAI	10/01/1990	65	Não Monitora	0
5	66020000	TANGARÁ DA SERRA	SEPOTUBA	20/04/2010	18	Não Monitora	0
6	66022000	TANGARÁ DA SERRA	SEPOTUBA	20/04/2010	18	Não Monitora	0
7	66050000	TAPIRAPUÃ	SEPOTUBA	18/06/2009	26	Não Monitora	0
8	66054000	NOVA FERNANDÓPOLIS	SEPOTUBA	20/04/2010	18	Não Monitora	0
9	66055000	SÃO JOSÉ DO SEPOTUBA	SEPOTUBA	19/06/2009	24	Não Monitora	0
10	66065000	ESTRADA MT-125	CABAÇAL	20/06/2009	25	Não Monitora	0
11	66069000	CÁCERES	PARAGUAI	11/05/1995	59	Não Monitora	0
12	66070004	CÁCERES (DNPVN)	PARAGUAI	02/10/1979	40	10/06/2000	49
13	66070010	CÁCERES	PARAGUAI	11/05/1995	50	Não Monitora	0
14	66071400	ÁGUA SUJA	JAURU MT	22/06/2009	26	Não Monitora	0
15	66072000	PORTO ESPERIDIÃO	JAURU MT	20/05/2008	61	Não Monitora	0
16	66077100	CÁCERES	JAURU MT	11/01/1990	74	Não Monitora	0



- Estacoes fluviométricas in situ
- ▲ Empreendimentos Hidrelétricos em Operação
- ▲ Exutório da sub-bacia
- Rios principais
- Bacia do Alto Paraguai
- Sub-bacia 01 - Paraguai superior

01 - Sub-bacia do Paraguai Superior




Fig. 32 – Sub-bacia 01 – Paraguai superior

6.3.2. Sub-bacia do rio Cuiabá

O rio Cuiabá é o segundo afluente mais importante do Pantanal, em termos de contribuição de vazões e sedimentos. Os principais rios dessa sub-bacia são o rio Manso, rio da Casca e o próprio rio Cuiabá. A altitude do ponto do exutório é de 116 m, ou seja, esse exutório também já se encontra dentro do Pantanal.

O rio Cuiabá possui 22 estações com dados de sedimentos ou turbidez, sendo que cinco delas possuem medições de sedimentos em suspensão (Fig. 33 e a Tab. 13).

Em relação aos empreendimentos hidrelétricos, nessa bacia existem 6 empreendimentos em operação, sendo duas PCHs em um afluente do rio Casca (PCH Casca II e Casca III), duas no rio Mestre (PCH Mestre e PCH Santa Cecília), uma no rio Aricá (PCH São Tadeu I), e a UHE Manso, no rio Manso. Conforme Fantin-Cruz et al., (2020), os empreendimentos hidrelétricos na bacia do rio Cuiabá reduzem o transporte de sedimentos em cerca de 60% no rio Cuiabá. A principal responsável por essa redução é a represa da UHE Manso.

Para o futuro, estão sendo avaliadas seis PCHs em cascata no rio Cuiabá, e mais uma no rio Aricá, à jusante da PCH São Tadeu I. Se construídos, esses empreendimentos poderão reduzir em cerca de 88% o transporte de sedimentos para o Pantanal, sendo que as mais prejudiciais seriam as PCHs em cascata no rio Cuiabá. Conforme já descrito no Artigo 3 desta

Tese, o rio Cuiabá é o principal transportador de sedimentos para a região do Pantanal norte, e a redução desse aporte poderá impactar negativamente a planície aluvial à jusante, além de causar problemas de assoreamento nos reservatórios implantados. A redução no aporte de sedimentos para o Pantanal pode causar alterações na dinâmica geomorfológica do rio, potencialmente criando uma situação de escassez de sedimentos onde os canais do rio erodem mais facilmente e os bancos ficam desestabilizados, aumentando a inundação das planícies aluviais. Além disso, a redução no aporte de sedimentos também ocasiona uma redução no aporte de nutrientes, com consequências negativas diversas, como perda da produtividade natural do ecossistema aquático, impacto nas comunidades bentônicas, e consequente impactos nos peixes (Kondolf et al., 2014; Oliveira et al., 2020).

Em termos de dinâmica temporal da CSS, o trecho do exutório do rio Cuiabá avaliado também apresenta um comportamento sazonal em termos de sedimentos em suspensão. Observa-se que o mês de abril também é o mês com a CSS mais baixa (29,7 mg/L), e dezembro possui a maior CSS mediana mensal (128,3 mg/L).

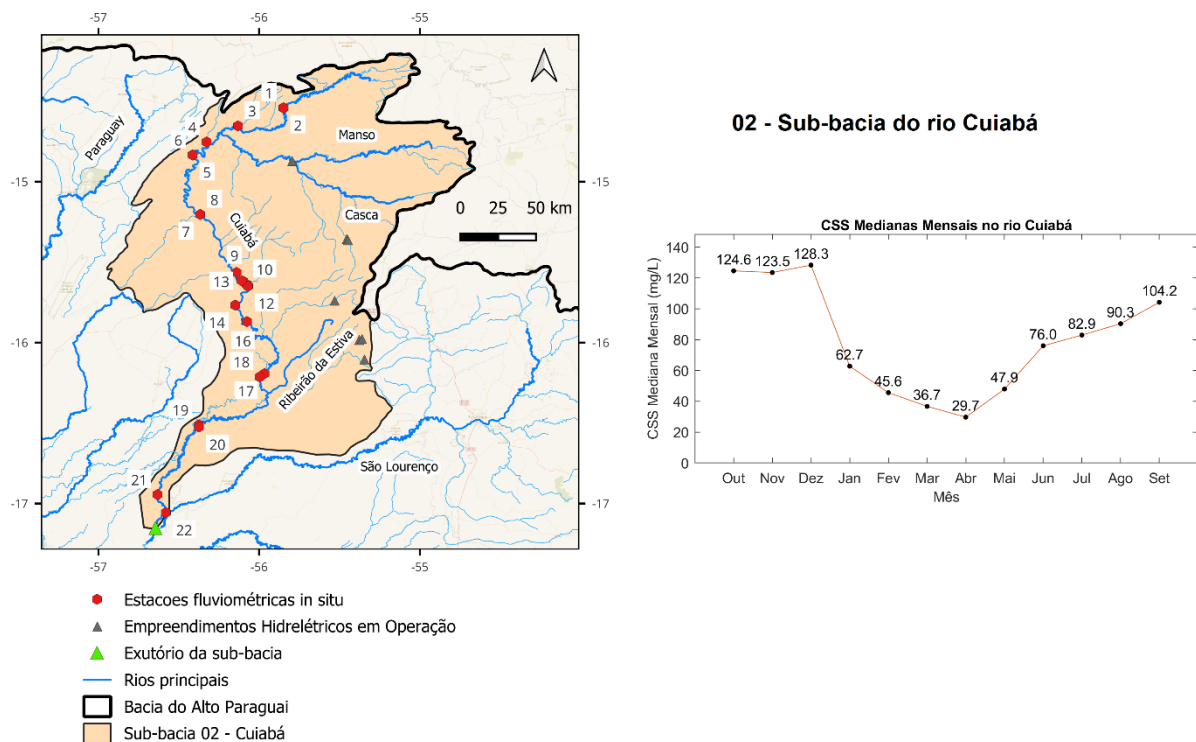


Fig. 33 – Sub-bacia 02 – rio Cuiabá

Tab. 13 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 02

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66133000	ROSÁRIO OESTE	RIO CUIABÁ	19/06/1995	129	Não Monitora	0
2	66140000	MARZAGÃO	RIO CUIABÁ	09/11/1979	26	Não Monitora	0
3	66160000	QUEBÓ	RIO CUIABÁ	23/05/2008	8	Não Monitora	0
4	66245001	NOBRES	RIO CUIABÁ	21/07/1999	104	Não Monitora	0
5	66250001	ROSÁRIO OESTE	RIO CUIABÁ	22/05/1995	119	15/09/1999	74
6	66250002	ROSÁRIO OESTE	RIO CUIABÁ	22/05/1995	91	Não Monitora	0
7	66255000	ACORIZAL	RIO CUIABÁ	22/08/1995	148	14/09/1999	75
8	66255001	ACORIZAL	RIO CUIABÁ	29/05/2017	8	Não Monitora	0
9	66259200	CUIABÁ	RIO CUIABÁ	20/06/1995	142	Não Monitora	0
10	66259301	CUIABÁ	RIO CUIABÁ	18/01/1999	114	Não Monitora	0
11	66259305	CUIABÁ	RIO CUIABÁ	01/03/1999	112	Não Monitora	0
12	66259309	CUIABÁ	RIO CUIABÁ	08/03/1999	112	Não Monitora	0
13	66260001	CUIABÁ	RIO CUIABÁ	Não Monitora	0	13/09/1999	80
14	66260151	CUIABÁ	RIO CUIABÁ	25/01/1999	113	Não Monitora	0
15	66260152	SANTO ANTÔNIO DO LEVERGER	RIO CUIABÁ	31/05/2000	95	Não Monitora	0
16	66270000	SANTO ANTÔNIO DO LEVERGER	RIO CUIABÁ	21/05/2008	30	Não Monitora	0
17	66280000	BARÃO DE MELGAÇO	RIO CUIABÁ	25/06/2009	27	Não Monitora	0
18	66296000	BARÃO DE MELGAÇO	RIO CUIABÁ	24/08/1995	129	Não Monitora	0
19	66340000	PORTO CERCADO	RIO CUIABÁ	20/07/2009	30	02/11/2005	40
20	66341000	POCONÉ	RIO CUIABÁ	24/05/1995	128	Não Monitora	0
21	66360000	SÃO JOÃO	RIO CUIABÁ	22/07/2009	30	Não Monitora	0
22	66370000	ILHA CAMARGO	RIO CUIABÁ	24/07/2009	30	26/06/2008	35

6.3.3. Sub-bacia do rio São Lourenço

Na sub-bacia do rio São Lourenço, os principais rios contribuintes são o rio Vermelho e o próprio rio São Lourenço. O trecho do exutório selecionado para esta bacia é na localidade da estação fluviométrica 10 (Código ANA 66470000), cuja altitude é de 125 m. Conforme o rio São Lourenço vai se aproximando do seu desague no rio Cuiabá, o leito do rio perde os seus diques marginais, e o leito principal do rio se subdivide em leitos menores e difusos. Não parece existir um desague único do rio São Lourenço no rio Cuiabá.

Nesta sub-bacia existem 10 estações *in situ* com dados de turbidez e de sedimentos em suspensão, sendo que apenas 3 delas monitoram sedimentos (Fig. 34 e a Tab. 14).

Além disso, existem 10 empreendimentos hidrelétricos, sendo uma no rio Poxoréo (PCH Poxoréo), sendo dois em cascata no rio Ponte de Pedra (PCH Eng. José Gelázio e PCH Rondonópolis), quatro na região do rio Tenente Amaral (PCH Pequi, PCH Sucupira, PCH Cambará e PCH Embaúba), uma no rio Prata (PCH Água prata), uma no córrego Ibo (PCH Sete quedas altas) e uma no rio São Lourenço (PCH São Lourenço).

A redução no transporte de sedimentos é estimada em 50% no cenário atual de barragens, podendo chegar a 60% se os empreendimentos futuros forem implantados. A PCH São Lourenço é a maior dentre as PCHs dessa região, e ela é a principal responsável pela

redução no transporte de sedimentos atual da bacia. O seu reservatório se equipara ao de grandes usinas, em termos de área e volume útil, embora a capacidade instalada seja considerada de PCH (potência menor que 30 MW).

A respeito da variação temporal da CSS no exutório do rio São Lourenço, é notável que esta apresenta um aumento a partir do mês de outubro, coincidindo com o início do período chuvoso na região. As maiores medianas mensais de CSS são observadas nos meses entre dezembro e março (pico em janeiro 497,7 mg/L), para posteriormente iniciar um declínio gradual, com valor mínimo em julho (77,1 mg/L).

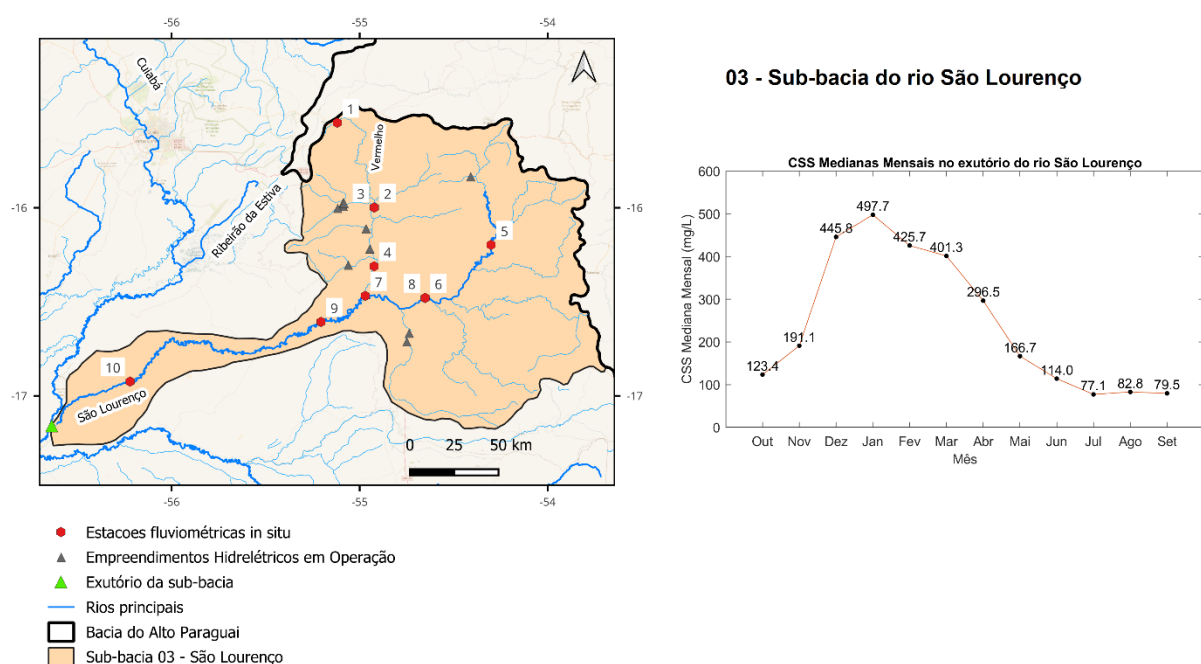


Fig. 34 – Sub-bacia 03 – rio São Lourenço

Tab. 14 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 03

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66375300	CAMPO VERDE	RIO SÃO LOURENÇO	01/08/2002	48	Não Monitora	0
2	66380000	SÃO PEDRO DA CIPA	RIO SÃO LOURENÇO	08/06/1993	26	Não Monitora	0
3	66380100	SÃO PEDRO DA CIPA	RIO SÃO LOURENÇO	21/02/1990	71	Não Monitora	0
4	66400000	SÃO LOURENÇO DE FÁTIMA	RIO SÃO LOURENÇO	26/05/2008	51	Não Monitora	0
5	66430000	JARUDORE	RIO VERMELHO	18/09/1995	83	Não Monitora	0
6	66448000	SÃO PEDRO DA CIPA	RIO VERMELHO	25/01/1990	74	Não Monitora	0
7	66449000	RONDONÓPOLIS	RIO VERMELHO	29/07/2002	46	Não Monitora	0
8	66450001	RONDONÓPOLIS	RIO VERMELHO	28/08/2009	26	18/01/2000	43
9	66460000	ACIMA DO CÓRREGO GRANDE	RIO SÃO LOURENÇO	20/09/1979	46	07/07/2000	48
10	66470000	SÃO JOSÉ DO BORIRÉU	RIO SÃO LOURENÇO	23/07/2009	31	26/06/2008	33

6.3.4. Sub-bacia do rio Piquiri/Correntes

Na bacia do rio Piquiri, os principais rios são o rio Itiquira, o rio Correntes, e o próprio rio Piquiri. O trecho do exutório encontra-se em altitude de 110 m, pouco antes do seu desague no rio Cuiabá. Existem 6 estações *in situ* com dados de turbidez e de sedimentos em suspensão, sendo que duas monitoram sedimentos (Fig. 35 e Tab. 15).

Observa-se a presença de quatro empreendimentos hidrelétricos nesta bacia, sendo um no rio Itiquira (UHE Itiquira), e três no rio Correntes (UHE Ponte de Pedra, PCH Gabriela e PCH Aquarius). Atualmente, o rio Itiquira tem o seu transporte de sedimentos reduzido em cerca de 20%, devido à presença da UHE Itiquira, e pode ter seu transporte reduzido em até 42% com a possível implantação dos empreendimentos futuros previstos. O rio Correntes transporta cerca de 25% a menos de sedimentos suspensos devido à presença dos barramentos atuais, e estima-se uma redução de até 65% se os outros seis empreendimentos hidrelétricos previstos forem implantados.

Em relação a dinâmica temporal da CSS, observa-se que este rio transporta bem menos sedimentos, em comparação com o rio Cuiabá e o rio São Lourenço. O mês de outubro é mês com a maior CSS mediana mensal (64,3 mg/L), e em abril as mínimas são observadas (19,1 mg/L).

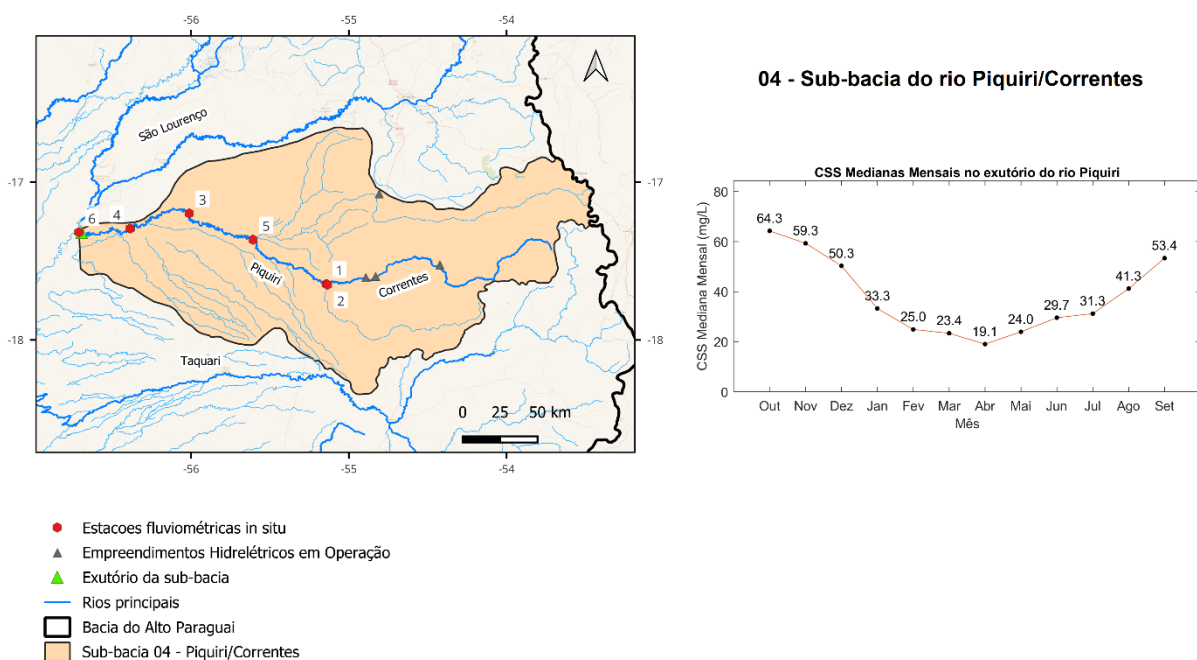


Fig. 35 – Sub-bacia 04 – rio Piquiri/Correntes

Tab. 15 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 04

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66481000	CORUMBÁ	RIO PIQUIRI	02/08/1994	73	Não Monitora	0
2	66527800	CORUMBÁ	RIO PIQUIRI	22/06/1999	50	Não Monitora	0
3	66600000	SÃO JERÔNIMO	RIO PIQUIRI	30/07/2009	32	04/04/2000	52
4	66650000	SÃO JOSÉ DO PIQUIRI	RIO PIQUIRI	29/07/2009	32	09/11/2005	40
5	66651000	FOZ RIO PIQUIRI	RIO PIQUIRI	26/07/2001	13	Não Monitora	0
6	66651100	BARÃO DE MELGAÇO	RIO PIQUIRI	28/07/2018	9	Não Monitora	0

6.3.5. Sub-bacia do rio Taquari

A bacia do rio Taquari é formada pelos rios Jauru-MS, Coxim, e o próprio rio Taquari (Fig. 36). Para esta bacia, o trecho escolhido para avaliação da dinâmica temporal da CSS é bem antes do seu encontro com o rio Paraguai, uma vez que este rio vai se tornando difuso, e tem sua largura diminuída, à medida em que entra no Pantanal. Diferente da maior parte dos rios, o rio Taquari não está exatamente em um fundo de um vale. O Taquari está numa cumieira, ou seja, o leito do rio corre em uma porção mais alta do que a planície ao seu redor. Então, nesta situação, ele tende a extravasar nos pontos mais vulneráveis (Godoy et al., 2002).

Em relação ao monitoramento, existem 11 estações com dados *in situ*, sendo que 3 delas monitoram sedimentos em suspensão (Fig. 36 e Tab. 16).

Atualmente, existe uma PCH nessa bacia, localizada nos altos do rio Coxim (PCH Ponte Alta), porém, outros 26 empreendimentos hidrelétricos estão sendo considerados para o futuro. Estima-se que os empreendimentos futuros no Alto do Taquari poderiam reduzir em até 50% no transporte de sedimentos natural, e para o rio Coxim, cerca de 75% de redução. Barragens nestes rios sofreriam com problemas de assoreamento, devido ao solo altamente erodível dessa região. A retenção de sedimentos nas barragens também impactaria negativamente os canais dos rios a jusante, causando uma situação de escassez de sedimentos. Para compensar a perda em sedimentos, rios podem começar a escavar os próprios canais a jusante do reservatório, alterando a dinâmica geomorfológica e causando impactos negativos para a planície.

Como o canal do rio Taquari se torna difuso e perde seus diques marginais, à medida em que adentra a planície do Pantanal, a dinâmica temporal da CSS foi avaliada para um trecho onde o rio ainda possui um canal com largura superior a 100 m. A CSS mediana mensal máxima é observada em janeiro (484,1 mg/L), e a mínima em julho (53,8 mg/L).

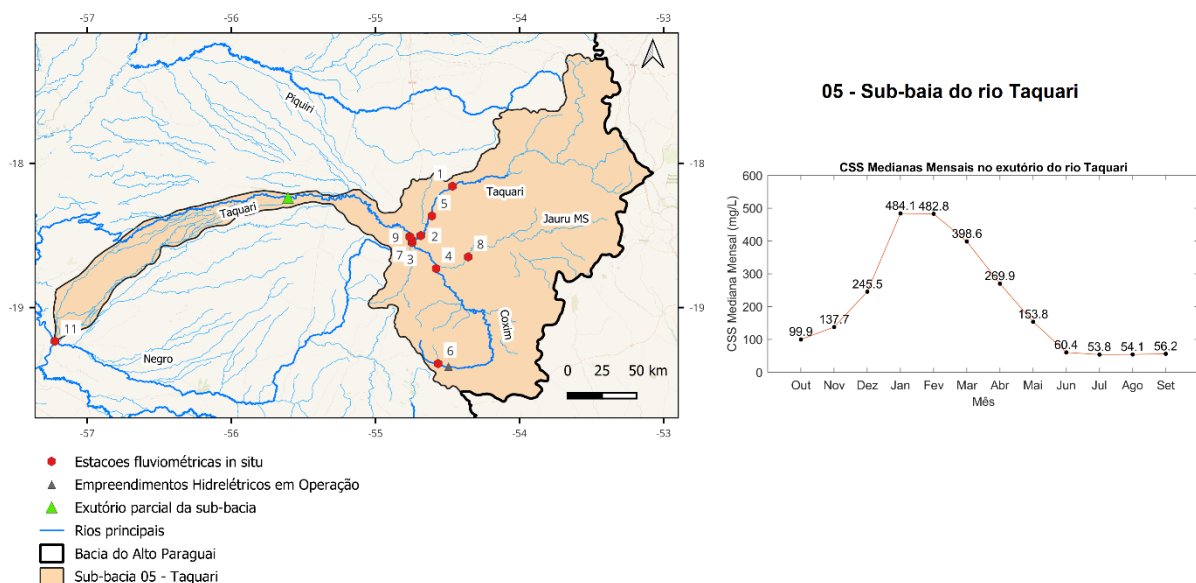


Fig. 36 – Sub-bacia 05 – rio Taquari

Tab. 16 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 05

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66845000	PEDRO GOMES	RIO TAQUARI	23/06/2009	29	03/07/2007	35
2	66848000	COXIM	RIO TAQUARI	06/05/1994	76	Não Monitora	0
3	66848900	COXIM	RIO COXIM	06/05/1994	111	Não Monitora	0
4	66849000	CONFLUÊNCIA RIO JAURU	RIO COXIM	30/06/2009	30	Não Monitora	0
5	66850000	CONTRAVERTENTE	RIO JAURU	27/06/2009	30	Não Monitora	0
6	66851000	SÃO GABRIEL DO OESTE	RIO COXIM	29/04/1994	69	Não Monitora	0
7	66852000	SÃO GABRIEL DO OESTE	RIO COXIM	09/02/2010	17	Não Monitora	0
8	66855000	GARIMPAGEM	RIO JAURU	26/06/2009	30	04/07/2007	32
9	66870000	COXIM	RIO TAQUARI	15/09/1979	44	05/07/2007	33
10	66870200	COXIM	RIO TAQUARI	22/05/1994	71	Não Monitora	0
11	66894000	RIO TAQUARI - FOZ	RIO TAQUARI	10/05/1994	52	Não Monitora	0

6.3.6. Sub-bacia do rio Negro

O principal curso d'água da sub-bacia do rio Negro é o próprio rio Negro (Fig. 37). Devido ao relevo plano em praticamente toda a área de drenagem, o rio Negro praticamente não possui sedimentos em suspensão. Sua cor escura advém de substâncias húmicas presentes na água. O rio Negro possui cinco estações de monitoramento da qualidade da água, mas nenhuma estação monitora sedimentos (Tab. 17).

Essa região não possui empreendimentos hidrelétricos em operação, e existem sete empreendimentos sendo avaliados para possível implantação. Os impactos dos possíveis empreendimentos hidrelétricos futuros no transporte de sedimentos para o Pantanal foi estimado em 8% de redução no transporte de sedimentos, conforme os estudos disponíveis.

Em relação à dinâmica temporal da CSS, o resultado confirma uma baixa concentração de sedimentos ao longo do ano todo, com um ligeiro aumento nos meses mais chuvosos de outubro a fevereiro (pico da CSS mediana mensal em novembro – 29,3 mg/L), que provavelmente são provenientes da proximidade do encontro do rio Negro com o rio Paraguai.

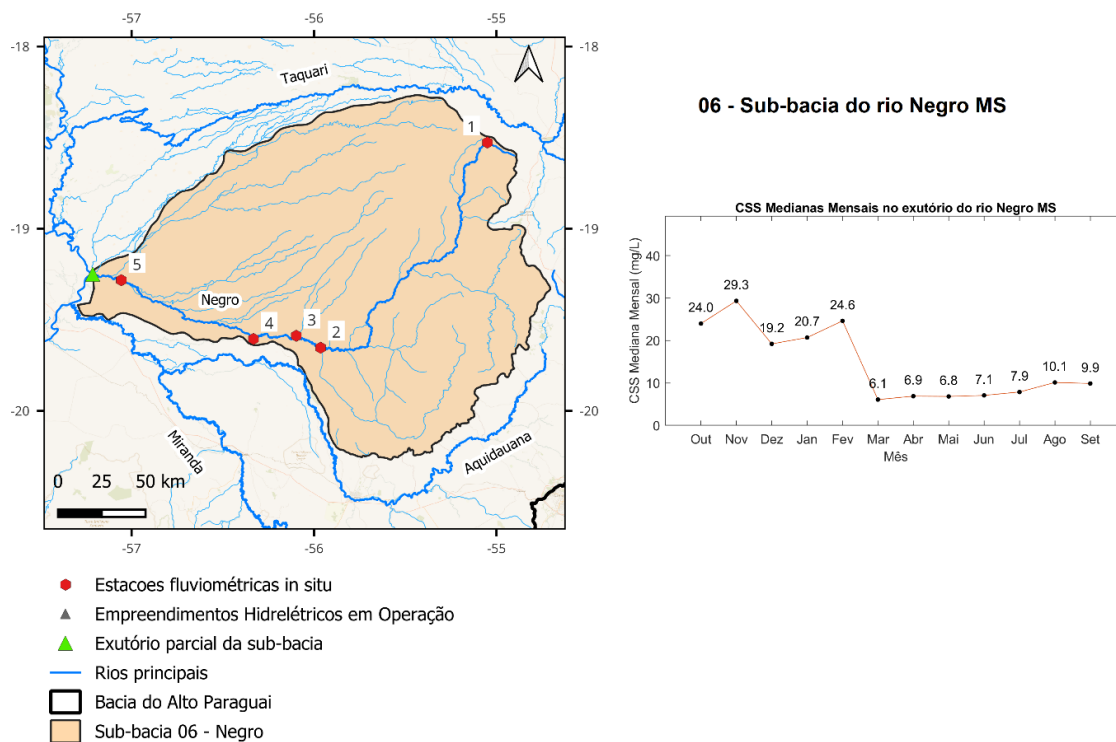


Fig. 37 – Sub-bacia 06 – rio Negro MS

Tab. 17 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 06

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66887500	RIO NEGRO	RIO NEGRO	15/04/1997	53	Não Monitora	0
2	66886500	AQUIDAUANA	RIO NEGRO	17/03/1998	44	Não Monitora	0
3	66886800	AQUIDAUANA	RIO NEGRO	17/03/1998	46	Não Monitora	0
4	66891000	AQUIDAUANA	RIO NEGRO	17/03/1998	47	Não Monitora	0
5	66892000	CORUMBÁ	RIO NEGRO	12/11/1998	39	Não Monitora	0

6.3.7. Sub-bacia do rio Miranda

Os principais rios dessa sub-bacia é o rio Aquidauana e o rio Miranda (Fig. 38). Observa-se a existência de 20 estações *in situ* de monitoramento, sendo que 5 delas monitoram sedimentos em suspensão (Tab. 18). Atualmente não existem empreendimentos hidrelétricos nessa sub-bacia, assim como não existem empreendimentos previstos para o futuro.

Em relação à dinâmica temporal de sedimentos em suspensão no exutório do rio Miranda, pouco antes do seu desague no rio Paraguai, observa-se que os meses de outubro a

fevereiro apresentam maiores CSS medianas mensais (pico em novembro – 79,7 mg/L), coincidindo com o período de chuvas da região, reduzindo gradativamente a partir de março (mínima em julho – 27,3 mg/L).

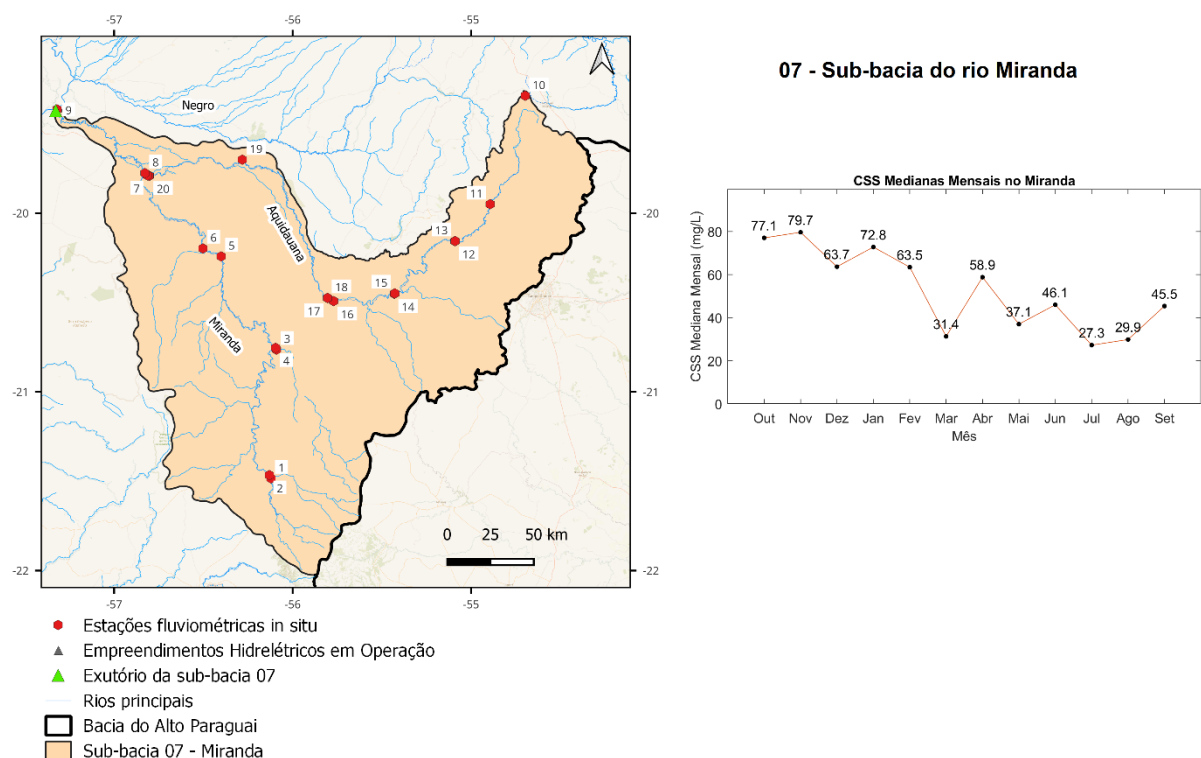


Fig. 38 – Sub-bacia 07 – rio Miranda

Tab. 18 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 07

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66895500	JARDIM	RIO MIRANDA	18/01/1994	80	Não Monitora	0
2	66895800	JARDIM	RIO MIRANDA	02/02/1995	89	Não Monitora	0
3	66896000	BONITO	RIO MIRANDA	18/01/1994	91	Não Monitora	0
4	66900000	ESTRADA MT-738	RIO MIRANDA	17/11/1979	31	19/07/2007	35
5	66910000	MIRANDA	RIO MIRANDA	20/06/2009	21	23/09/2005	39
6	66911000	PONTE RODOVIA BR-262	RIO MIRANDA	18/02/1994	79	Não Monitora	1
7	66920500	MIRANDA	RIO MIRANDA	03/02/1994	82	Não Monitora	2
8	66920800	JUS. FOZ RIO AQUIDAUANA	RIO MIRANDA	03/02/1994	73	Não Monitora	3
9	66921000	MIRANDA	RIO MIRANDA	18/02/1994	94	Não Monitora	4
10	66924000	SÃO GABRIEL DO OESTE	RIO AQUIDAUANA	06/01/1994	92	Não Monitora	0
11	66924500	ROCHEDO	RIO AQUIDAUANA	23/01/1994	87	Não Monitora	0
12	66925900	TERENOS	RIO AQUIDAUANA	13/01/1994	95	Não Monitora	0
13	66926000	PONTE DO GREGO	RIO AQUIDAUANA	20/08/2009	34	20/09/2007	29
14	66941000	PALMEIRAS	RIO AQUIDAUANA	21/07/2009	36	Não Monitora	0
15	66941100	DOIS IRMÃOS DO BURITI	RIO AQUIDAUANA	05/06/2018	10	Não Monitora	0
16	66944500	ANASTÁCIO	RIO AQUIDAUANA	11/01/1994	95	Não Monitora	0
17	66945000	AQUIDAUANA	RIO AQUIDAUANA	09/10/1979	34	30/03/2000	45
18	66945500	AQUIDAUANA	RIO AQUIDAUANA	13/01/1994	85	Não Monitora	0
19	66950000	PORTO CIRIACO	RIO AQUIDAUANA	19/06/2009	20	21/09/2005	36
20	66951000	AQUIDAUANA	RIO AQUIDAUANA	18/01/1994	101	Não Monitora	0

6.3.8. Sub-bacia do Corixó Grande

A sub-bacia do Corixó Grande (Fig. 39) está inserida no território da Bolívia, e desagua no rio Paraguai pela margem direita. Não foram encontradas estações de monitoramento *in situ* nessa região. Da mesma forma, não existem empreendimentos hidrelétricos operando ou previstos para essa sub-bacia. De forma geral, essa sub-bacia possui cobertura da terra bastante natural, com pouca presença de influência antrópica.

A dinâmica temporal da CSS no exutório do Corixó Grande possui comportamento bastante semelhante ao do rio Paraguai, no trecho em que eles se conectam. Esse trecho é marcado por um relevo extremamente plano da planície do Pantanal, com formação de lagoas interconectadas, e grande conexão lateral dos canais dos rios com a planície de inundação. As CSS medianas mensais apresentam-se mais elevadas entre outubro e janeiro (pico em novembro – 111,7 mg/L), e os valores mínimos estão entre abril e julho (mínima em junho – 10,3 mg/L).

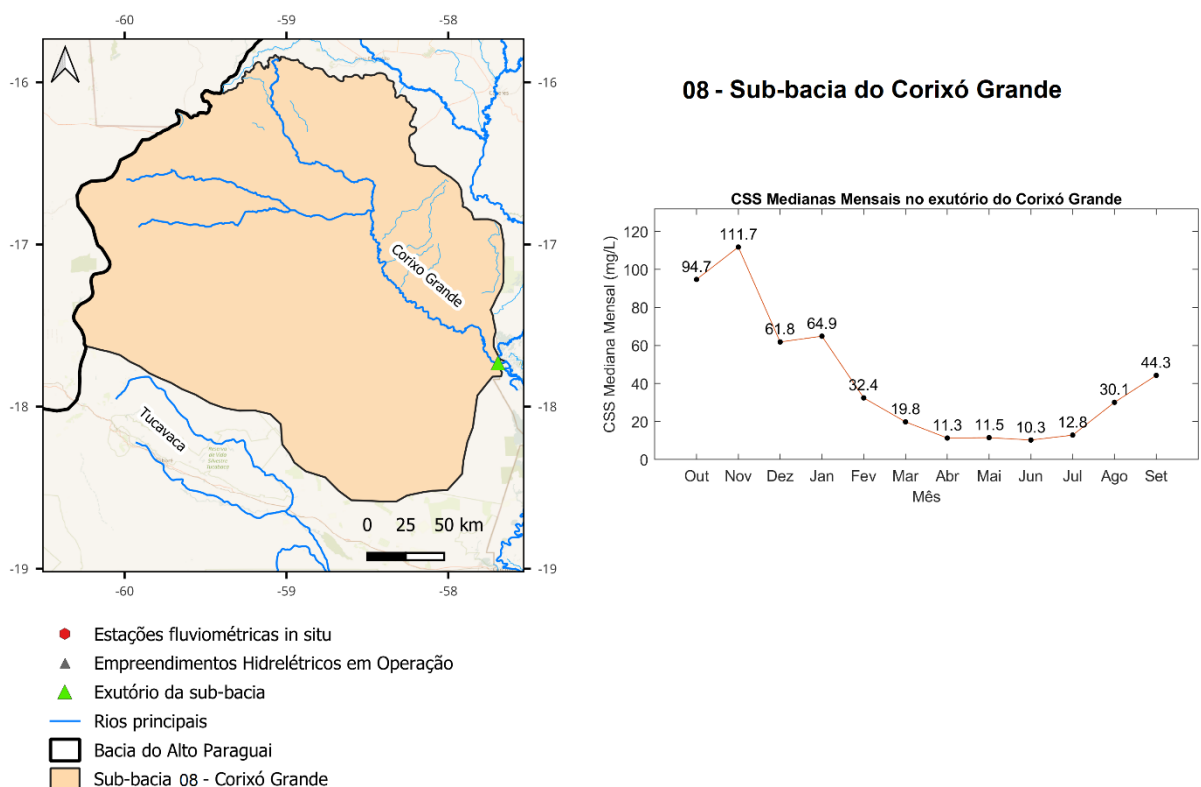


Fig. 39 – Sub-bacia 08 – Corixó Grande

6.3.9. Sub-bacia del río Negro

A sub-bacia del río Negro (Fig. 40) está inserida no território da Bolívia e do Paraguai, e também desagua no rio Paraguai pela margem direita. Não foram encontradas estações de

monitoramento *in situ* nessa região, assim como não existem empreendimentos hidrelétricos operando ou previstos. Essa sub-bacia já está parcialmente inserida no bioma Chaco, que é caracterizado por um bioma com estação seca ainda mais severa que a do cerrado, e com período chuvoso com índices pluviométricos mais baixos em relação ao cerrado.

A CSS mediana mensal no rio Negro apresenta pouca variação mensal, sendo que em outubro ocorre um ligeiro aumento nas concentrações de sedimentos (17,9 mg/L). Em geral, as CSS são bem baixas (em torno de 10 mg/L).

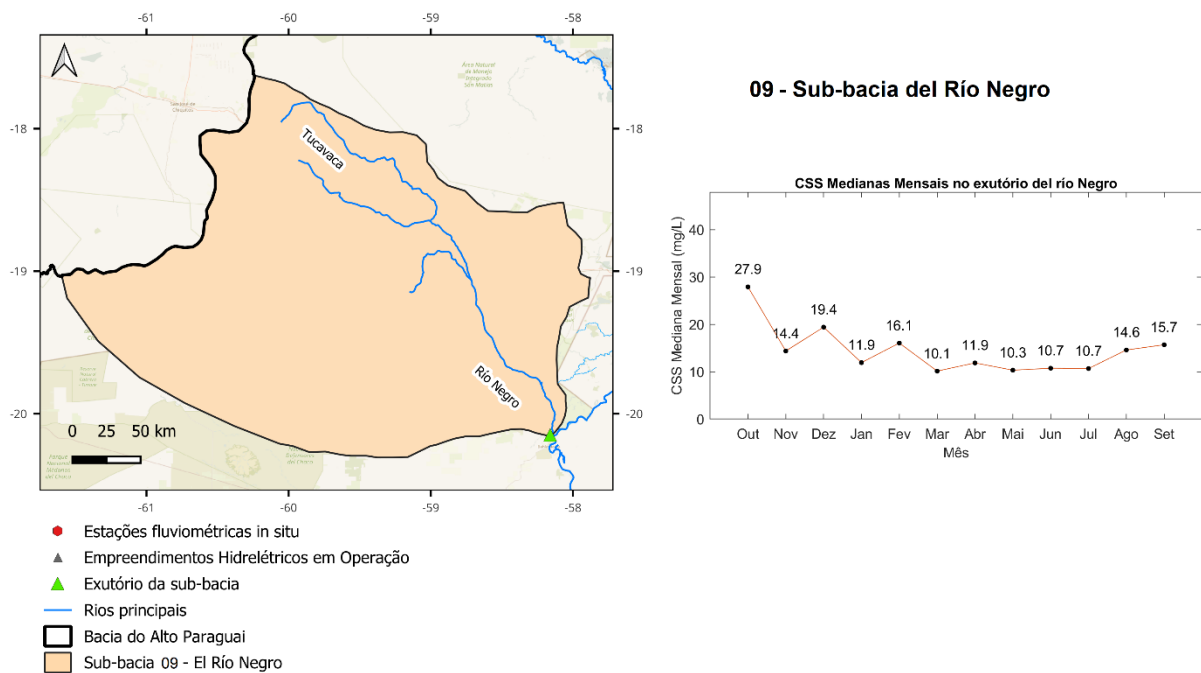
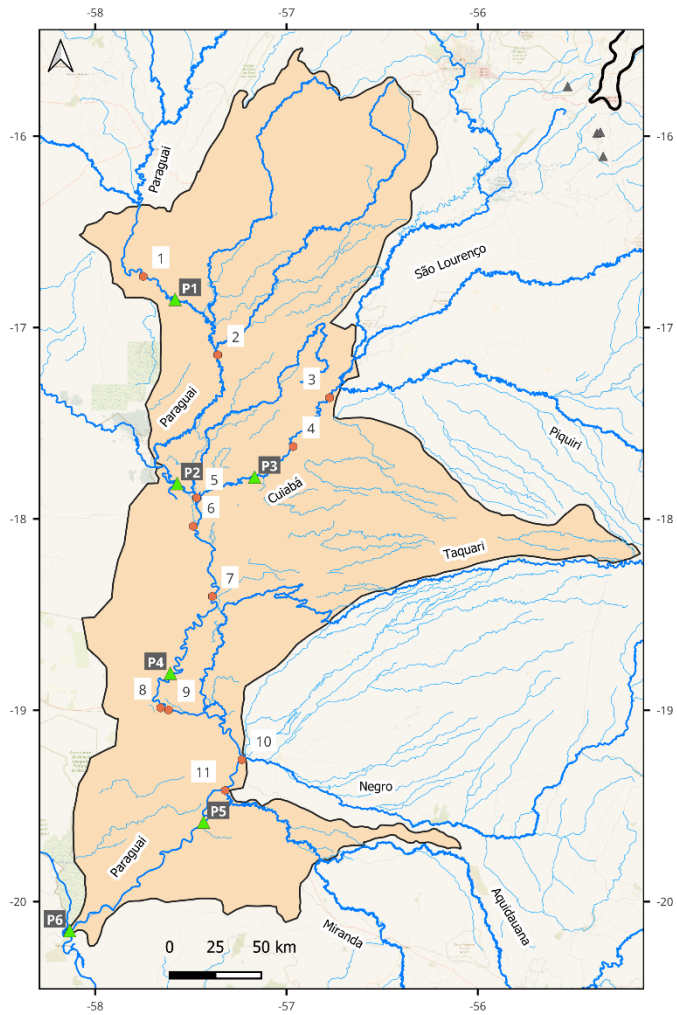


Fig. 40 – Sub-bacia 09 – El Río Negro

6.3.10. Região da planície de inundação do rio Paraguai

Todas as sub-bacias apresentadas anteriormente desaguam na região da planície de inundação do rio Paraguai (Fig. 41). Em termos de contribuição hídrica, os principais rios afluentes são o próprio rio Paraguai, vindo da sub-bacia 01, e o rio Cuiabá, vindo da sub-bacia 02. Vale ressaltar que as sub-bacias do rio São Lourenço e do rio Piquiri se juntam ao rio Cuiabá, antes deste desaguar no rio Paraguai.

Para essa região, foram identificadas 12 estações com dados *in situ*, sendo que 7 delas monitoram CSS (Tab. 19).



- Estações fluviométricas in situ
- ▲ Empreendimentos Hidrelétricos em Operação
- ▲ Pontos para avaliação da CSS Média Mensal
- Rios principais
- Bacia do Alto Paragui
- Sub-bacia 11 - Região da Planície de Inundação do rio Paragui

11 - Região da Planície de Inundação do rio Paragui/Pantanal









Fig. 41 – Região da Planície de Inundação do rio Paragui

Tab. 19 - Disponibilidade de estações *in situ* com dados de turbidez e CSS na sub-bacia 10

ID	Código da Estação	Nome	Rio	Turbidez		CSS	
				Monitoramento Início	N de Registros	Monitoramento Início	N de Registros
1	66090000	DESCALVADOS	RIO PARAGUAI	30/06/2009	27	06/07/2007	36
2	66120000	PORTO CONCEIÇÃO	RIO PARAGUAI	02/07/2009	26	24/02/2000	47
3	66710000	POUSADA TAIAMÃ	RIO CUIABÁ	27/07/2009	31	Não Monitora	0
4	66750000	PORTO DO ALEGRE	RIO CUIABÁ	28/07/2009	31	08/11/2005	40
5	66751000	CORUMBÁ	RIO PARAGUAI	23/06/1999	40	Não Monitora	0
6	66800000	AMOLAR	RIO PARAGUAI	31/07/1985	26	30/06/2007	32
7	66810000	SÃO FRANCISCO	RIO PARAGUAI	26/06/2009	19	01/06/2002	32
8	66811000	MONTANTE CAPTAÇÃO CORUMBÁ	RIO PARAGUAI	10/05/1994	90	Não Monitora	0
9	66824000	CORUMBÁ	RIO PARAGUAI	17/01/2001	55	Não Monitora	0
10	66895000	PORTO DA MANGA	RIO PARAGUAI	25/06/2009	19	25/10/2007	31
11	66921000	MIRANDA	RIO MIRANDA	18/02/1994	94	Não Monitora	0
12	67100000	PORTO MURTINHO	RIO PARAGUAI	Não Monitora	0	13/07/2005	36

Devido a presença do Pantanal, não existem empreendimentos hidrelétricos operando ou previstos para essa região, no entanto, os empreendimentos previstos para serem implantados nos rios do planalto poderão implicar em redução de cerca de 62% no aporte de sedimentos para o Pantanal (Fantin-Cruz et al., 2020).

Em relação à dinâmica dos sedimentos, observa-se um padrão temporal muito semelhante em todos os pontos avaliados. Observa-se que outubro a dezembro é o período com as maiores CSS em todo o sistema rio-planície, sendo novembro o mês com a maior CSS mediana mensal em todos os pontos avaliados. Este trimestre corresponde ao início do período das chuvas, e é o período em que as águas ainda estão baixas (menores níveis e vazões).

As CSS mais baixas foram observadas no trimestre de abril a junho, que corresponde ao período de cheias no Pantanal. As cheias, por sua vez, acontecem cerca de 3-4 meses após o pico do período chuvoso. Também se observa que a CSS média mensal começa a aumentar por volta do mês de abril, coincidindo com o início da vazante do Pantanal (recessão do hidrograma de vazões). Neste período, os índices pluviométricos são mais baixos, portanto, o aumento da CSS neste período está provavelmente mais relacionado com a mudança nas vazões.

Observa-se que o ponto P3, localizado no rio Cuiabá, antes do seu desague no rio Paraguai, apresenta magnitudes de CSS maiores que os outros pontos localizados ao longo do rio Paraguai (154,8 mg/L). O rio Cuiabá apresenta uma bacia hidrográfica menor em comparação ao rio Paraguai, no entanto, produz uma maior concentração de sedimentos em suspensão, com diques marginais bem desenvolvidos, que proporcionam maiores velocidades ao fluxo, e uma maior capacidade de transporte de sedimentos em suspensão. Em contrapartida, o rio Paraguai apresenta uma bacia hidrográfica maior, mas retém a maior parte dos sedimentos nos leques (sistema rio-planície), pois não apresenta diques marginais em alguns trechos, e

possui múltiplos canais com alta razão largura/profundidade com maior interação com ambientes lacustres do que o rio Cuiabá. Essas características levam a uma menor capacidade de transporte de sedimentos que a do rio Cuiabá (Luz, 2019).

6.4. Discussões

Do ponto de vista da disponibilidade de dados *in situ*, a sub-bacia do rio Cuiabá foi a que apresentou mais estações de monitoramento, tanto de qualidade da água, quanto de sedimentos em suspensão. Além disso, as únicas estações fluviométricas que possuem mais de 70 medições de sedimentos em suspensão estão localizadas nesta bacia (estação de Rosario Oeste, de Acorizal e de Cuiabá). As medições da CSS nestas estações iniciaram-se no ano de 1999, ou seja, a frequência média de amostragem é de 3 a 4 medições por ano. Mesmo sendo as estações que mais monitoram CSS *in situ* na bacia do Alto Paraguai, a frequência temporal é insuficiente para uma avaliação contínua da dinâmica temporal do transporte de sedimentos.

A turbidez é a variável mais monitorada ao longo de todas as sub-bacias avaliadas, tanto espacialmente quanto temporalmente. Porém, a frequência temporal não passa de 4 – 6 medições ao longo do ano, considerando as estações com mais dados. Isso reflete a escassez de dados também para qualidade da água, uma vez que turbidez só é monitorada nas campanhas de monitoramento da qualidade da água.

Diversos estudos vêm mostrando que a turbidez é uma variável que pode ser utilizada como medida indireta na CSS (Bayram et al., 2012; Sari et al., 2015, 2017; Sirabahenda et al., 2017; Teixeira et al., 2020; Campos e Pedrollo, 2021). Neste sentido, uma alternativa estratégica para o monitoramento indireto da CSS na bacia do Alto Paraguai seria a instalação de estações de monitoramento da turbidez com alta frequência (escala sub diária, da ordem de horas ou até minutos), por meio de turbidímetros em estações telemétricas já existentes. Dessa forma, com turbidímetros instalados em pontos estratégicos da bacia, seria possível observar a variação da CSS ao longo de eventos de precipitação, e inferir maiores conclusões acerca da variação do transporte de sedimentos ao longo dos meses, e ao longo dos diferentes rios que drenam para o Pantanal.

Em relação aos empreendimentos hidrelétricos atuais, a bacia com maior alteração atual no transporte de sedimentos é também a sub-bacia do rio Cuiabá, devido a presença da UHE Manso (que reduz cerca de 60% do transporte de sedimentos natural), e a sub-bacia do rio São Lourenço, devido a PCH São Lourenço (que reduz o transporte de sedimentos natural em 50%).

Os empreendimentos hidrelétricos nos rios Jauru-MT, Itiquira e Correntes também causam reduções importantes no transporte de sedimentos desses rios.

Considerando os possíveis empreendimentos futuros, a sub-bacia do rio Cuiabá também é a sub-bacia que apresenta o pior cenário, com possível redução de mais de 80% do transporte de sedimentos natural no cenário futuro. Também são previstas reduções significativas nos rios Coxim (sub-bacia do Taquari), rio Correntes, na parte alta do rio Taquari, rio Itiquira, rio Sepotuba e rio Cabaçal.

Os resultados da CSS calculados a partir de reflectâncias de imagens de satélite evidenciam um comportamento sazonal da CSS ao longo de toda a bacia hidrográfica do Alto Paraguai. Esse comportamento parece ser influenciado tanto pelo ciclo das chuvas quanto pelo ciclo das inundações na planície.

Em alguns rios, o aumento e diminuição da CSS acompanha exatamente o início e fim do período chuvoso, como o caso dos rios São Lourenço e Taquari, cuja CSS mediana mensal começa a aumentar a partir de outubro, com pico em janeiro, e diminui progressivamente. Vale ressaltar que estes rios não apresentam um desague claro no rio Paraguai, devido ao seu caráter entrelaçado quando entram na planície do Pantanal, e parecem não sofrer influência das inundações do rio Paraguai nos trechos avaliados. Do ponto de vista da morfologia fluvial, estes dois rios possuem canais entrelaçados nos trechos avaliados, que tendem a se formar devido à grande variação do volume do fluxo, combinada com uma grande carga sedimentar, e também devido a presença de margens facilmente erodíveis (Rocha, 2011). Possivelmente, estas características também contribuem para a dinâmica da CSS observada, tanto no rio São Lourenço, quanto no rio Taquari.

Já nos rios Cuiabá, no próprio rio Paraguai e no rio Piquiri, a dinâmica temporal da CSS parece ser influenciada majoritariamente pelas inundações periódicas do Pantanal. A CSS nestes rios começa a aumentar a partir do mês de abril, que corresponde ao pico das inundações, e da vazante. Neste período, os índices pluviométricos já estão mais baixos. Contrariamente, a CSS começa a diminuir a partir de novembro, que é justamente o período em que a planície começa a se encher, e os índices pluviométricos estão maiores. Em outras palavras, no período de cheias, as concentrações de sedimentos suspensos são menores se comparadas às concentrações obtidas para a seca. A razão para esse comportamento pode ser porque parte os sedimentos fica retida nos leques aluviais que compõem a planície do Pantanal nos rios de morfologia fluvial meandrante, que é o caso do rio Paraguai, rio Cuiabá e rio Piquiri nos trechos

avaliados, fazendo com que exista maior transporte no período de seca, no qual o fluxo se limita ao canal fluvial, o que aumenta a capacidade de transporte do canal neste período.

Em termos de magnitudes de CSS, o rio São Lourenço e o rio Taquari apresentam as maiores concentrações mensais observadas. O rio Cuiabá também apresenta CSS elevadas, mesmo no trecho próximo ao seu encontro com o rio Paraguai.

O rio Cuiabá apresenta uma bacia hidrográfica menor em comparação ao rio Paraguai, no entanto, produz uma maior concentração de sedimentos em suspensão, com diques marginais bem desenvolvidos e um padrão de canal sinuoso contendo material de leito mais grosso (arenoso). Em contrapartida, o rio Paraguai apresenta uma bacia hidrográfica maior, retém a maior parte dos sedimentos nos leques, não apresenta diques marginais em alguns trechos, possui múltiplos canais com alta razão w/d e maior interação com ambientes lacustres do que o rio Cuiabá (Luz, 2019).

A montante da confluência, o leito do rio Paraguai é formado principalmente por sedimentos mais finos ($<62 \mu\text{m}$), o que permite classificar essa área como uma zona de deposição (ver Tabela 8, seção 13), possivelmente em decorrência das baixas velocidades de fluxo: 0,34 m/s (abril de 2016) e 0,13 m/s (novembro de 2016). Por outro lado, no canal do rio Cuiabá a montante da confluência, o sedimento do leito é composto por areia fina e muito fina. Já a jusante da confluência há o transporte de areia mais grossa (Luz, 2019).

Os rios Negros, tanto do Mato Grosso do Sul (sub-bacia 06), quanto o da Bolívia (sub-bacia 09), possuem baixíssimas concentrações de sedimentos, sendo rios caracterizados pela presença de substâncias húmicas na água. As bacias hidrográficas de ambos são circulares e planas, características que não favorecem a erosão ao longo da bacia. Além disso, o leito destes rios não é suscetível a erosão, levando às baixas CSS observadas nos mesmos. Ocorre um ligeiro aumento da CSS no período chuvoso, mas ainda assim, a CSS continua sendo mais baixa do que os demais rios da bacia do Alto Paraguai.

A região da planície do rio Paraguai (sub-bacia 10) apresentou comportamento bastante semelhante da CSS nos pontos analisados.

Os resultados obtidos oferecem uma visão detalhada da dinâmica singular da CSS ao longo da bacia do Alto Paraguai. Estes revelam a notável influência da sazonalidade das chuvas e das inundações na planície do Pantanal sobre as variações da CSS ao longo dos rios, destacando diferenças expressivas na dinâmica temporal dos trechos analisados e suas respostas às mudanças sazonais. Essa análise detalhada permite compreender como as condições sazonais

específicas influenciam as concentrações de sedimentos, ampliando os conhecimentos sobre as interações complexas entre os ciclos naturais e as características morfológicas de cada rio.

6.5. Conclusões

Este estudo proporcionou uma análise hidrossedimentológica integrada para as principais sub-bacias que drenam para o Pantanal. Foi avaliada a disponibilidade de dados *in situ* de CSS e de turbidez nas estações do sistema nacional de informações sobre recursos hídricos; a presença e prospecção de empreendimentos hidrelétricos e seus impactos sobre o transporte de sedimentos; e por fim, foi realizada uma avaliação da dinâmica de sedimentos nos exutórios das sub-bacias.

Em suma, a análise detalhada das estações de monitoramento na bacia do Alto Paraguai revelou uma escassez significativa de dados contínuos e frequência limitada de medições, principalmente em relação aos sedimentos em suspensão, mas também em relação à turbidez nas estações de qualidade da água. A sub-bacia do rio Cuiabá se destaca por possuir mais estações de monitoramento, porém, a frequência temporal das medições permanece insuficiente para uma avaliação abrangente da dinâmica temporal do transporte de sedimentos. Os dados de turbidez disponíveis nas sub-bacias estudadas foram convertidos em CSS a partir do modelo regional baseado em RNAs, desenvolvido e apresentado em Campos e Pedrollo, (2021), resultando em um aumento nas informações hidrossedimentológicas ao longo da bacia do Alto Paraguai (Apêndice 1). No entanto, mesmo com os avanços obtidos por meio do modelo regional desenvolvido, a turbidez também não é monitorada frequentemente, apesar de ser mais monitorada do que a CSS.

Na sequência, o mapeamento da CSS a partir de imagens de satélite permitiu a avaliação da dinâmica da CSS nos exutórios das principais sub-bacias que drenam para o Pantanal, mesmo naquelas que não possuem qualquer tipo de monitoramento *in situ*.

Também foi apresentado um panorama por sub-bacia em relação aos empreendimentos hidrelétricos atuais e previstos. Os estudos disponíveis já revelam importantes reduções no transporte de sedimentos natural em alguns rios. Por exemplo, a UHE Manso e a PCH São Lourenço, já demonstraram uma significativa redução no transporte natural de sedimentos nos rios em que estão localizadas, com previsões de reduções ainda maiores no futuro, particularmente na sub-bacia do rio Cuiabá. De forma geral, espera-se uma redução de cerca de 60% no transporte de sedimentos para o Pantanal, caso todos os empreendimentos previstos

sejam implementados. Isso pode acarretar perda no aporte de nutrientes para a planície do Pantanal, e causar redução na produtividade biológica da mesma, impactando drasticamente o ecossistema existente.

Os resultados obtidos neste estudo contribuem para um melhor entendimento da dinâmica dos sedimentos em suspensão na planície do Pantanal. A sazonalidade hidrológica, as características dos rios e a influência dos afluentes mostraram-se fatores determinantes na distribuição espacial e temporal dos sedimentos suspensos na região. Essas informações são essenciais para o monitoramento e manejo adequado dos recursos hídricos e dos ecossistemas do Pantanal.

7. Conclusões da Tese

Esta pesquisa buscou proporcionar avanços na compreensão da dinâmica espaço-temporal dos sedimentos em suspensão do sistema rio-planície da região hidrográfica do Paraguai/Pantanal, e no desenvolvimento de técnicas baseadas em aprendizado de máquinas e dados de sensoriamento remoto para aplicações hidrossedimentológicas. Por meio desta pesquisa, foi possível elaborar uma caracterização detalhada da dinâmica de sedimentos em suspensão ao longo da BAP, enfatizando as informações obtidas em cada uma das principais sub-bacias que drenam para o Pantanal.

Inicialmente, a escassez de dados *in situ* foi parcialmente contornada a partir de um modelo regional baseado em RNAs. Por meio desta etapa do estudo, foi possível demonstrar a aplicabilidade de um modelo empírico para estimar a CSS em bacias heterogêneas não monitoradas. Tal modelo apresentou bom desempenho, desde que dados de turbidez e vazão estejam disponíveis em combinação com dados de precipitação e de sensoriamento remoto (área de drenagem, tipo de solo, uso do solo e declive médio da bacia). Os dados de turbidez oriundos de estações de qualidade da água, de monitoramento trimestral, foram convertidos em CSS a partir do modelo de RNAs desenvolvido, resultando em um aumento nas informações hidrossedimentológicas ao longo da bacia do Alto Paraguai.

Na sequência, o efeito de empreendimentos hidrelétricos de pequeno porte no transporte de sedimentos para o Pantanal foi investigado. Por meio de uma aplicação original, modelos SIFs foram empregados de forma a se obter conhecimentos sobre como diferentes variáveis relacionadas às características das bacias hidrográficas e das barragens, bem como as variações hidrológicas podem afetar as respostas sedimentológicas das pequenas hidrelétricas. Para isso, as regras dos SIFs foram analisadas, permitindo a identificação de padrões nas variáveis modeladas. Observou-se que a CSS a montante da barragem é a variável mais determinante na alteração causada pelas barragens, enquanto barragens com maiores CSS entrando no reservatório tendem a causar maior retenção. As alterações nulas, por fim, estão relacionadas a baixas concentrações a montante da barragem, com alterações positivas ocorrendo principalmente durante períodos chuvosos.

O tipo de solo na área de drenagem das barragens também influencia nas alterações, dado que barragens localizadas em bacias com solo mais siltoso tendem a alterar mais. A cobertura vegetal também se mostrou importante nos efeitos causados pelas barragens: aquelas localizadas em bacias com maior cobertura vegetal tendem a afetar menos o transporte de

sedimentos frente às localizadas em bacias com alto percentual de agricultura e pastagens. Os resultados também confirmaram que o tamanho das barragens está diretamente relacionado à capacidade de alterar o transporte de sedimentos. Quanto maior o volume, área e tempo de detenção do reservatório, maior é o potencial de retenção de sedimentos.

A partir dos padrões encontrados, observa-se que os empreendimentos hidrelétricos na sub-bacia do rio Cuiabá e do rio São Lourenço lideram as alterações no transporte de sedimentos. A UHE Manso e a PCH São Lourenço reduzem cerca de 60% e 50% do transporte de sedimentos natural, respectivamente. Além disso, as usinas nos rios Jauru-MT, Itiquira e Correntes também causam significativas reduções no transporte. Corroborando com os resultados encontrados pelos modelos SIF, o rio São Lourenço e o próprio rio Cuiabá são rios com considerável magnitude de CSS. Ademais, as usinas de Jauru-M, Itiquira e Ponte de Pedra são as usinas de maior porte presentes na BAP, com maiores capacidades instaladas, bem como volumes úteis e áreas alagadas, e são as usinas que mais alteram o transporte de sedimentos. Considerando os empreendimentos hidrelétricos futuros, a sub-bacia do rio Cuiabá apresenta o cenário mais desafiador, com uma possível redução de mais de 80% do transporte de sedimentos natural. Reduções importantes também são previstas nos rios Coxim (sub-bacia do Taquari) e na parte alta do Taquari, que são rios com elevada CSS.

Por fim, foi realizado um mapeamento inédito da dinâmica de sedimentos em suspensão ao longo do sistema rio-planície da região hidrográfica do Alto Paraguai, utilizando imagens de satélite, RNAs e a plataforma de nuvem GEE. Observou-se um padrão sazonal marcante na CSS, influenciado pelos ciclos de chuvas e inundações, e que varia ao longo dos rios da bacia. Nos rios São Lourenço e Taquari, a variação da CSS acompanha diretamente o início e término do período chuvoso. Nestes rios, a CSS começa a aumentar em outubro, atingindo seu ápice em janeiro, e, em seguida, diminui progressivamente, aparentemente não sendo afetada pelas inundações do rio Paraguai. Essa particularidade, aliada às características morfológicas dos trechos avaliados (canais entrelaçados e margens facilmente erodíveis), contribui na dinâmica observada de CSS.

Por outro lado, nos rios Cuiabá, Paraguai e Piquiri, a dinâmica temporal da CSS parece ser influenciada não somente pelas chuvas, mas também pelas inundações cíclicas do Pantanal. Nestes rios, a CSS começa a aumentar em abril, após o pico das inundações e início da vazante. Neste período, os índices pluviométricos são mais baixos e, portanto, o aumento da CSS pode estar relacionado ao movimento das águas na planície. Em contrapartida, a CSS começa a

diminuir a partir de novembro, período que coincide com o início da subida das águas e o aumento dos índices pluviométricos.

Quanto à magnitude da CSS, destacam-se os rios São Lourenço e Taquari com as maiores concentrações, seguidos pelo rio Cuiabá, que, mesmo próximo à sua junção com o rio Paraguai, apresenta magnitudes significativas. Apesar de possuir uma bacia hidrográfica menor em comparação ao rio Paraguai, o rio Cuiabá gera uma maior CSS, devido aos diques marginais bem desenvolvidos e um canal sinuoso com leito mais espesso. Em contraponto, o rio Paraguai, com sua bacia maior, retém a maior parcela dos sedimentos nos leques aluviais, pois não apresenta diques marginais em algumas áreas e, portanto, interações mais acentuadas com ambientes lacustres. Neste sentido, o Rio Cuiabá caracteriza-se como uma fonte essencial de sedimentos em suspensão para a região do Pantanal, desempenhando um papel fundamental no transporte de CSS para a planície.

Para uma melhor descrição dos processos e padrões identificados, recomenda-se uma avaliação detalhada dos padrões temporais da CSS observados ao longo da bacia frente a uma perspectiva de morfologia fluvial de planícies de inundação. Outra perspectiva futura para essa pesquisa é a utilização de imagens de coleções anteriores da missão Landsat, iniciada em 1985, de modo a captar tendências de aumento da CSS ao longo dos anos na planície do Pantanal, correlacionando essas mudanças com alterações no uso e cobertura da terra.

Por fim, esta pesquisa representa um avanço significativo na compreensão da dinâmica dos sedimentos em suspensão na região hidrográfica do Paraguai/Pantanal, agregando conhecimento para futuras pesquisas e contribuindo para a gestão sustentável dos recursos hídricos e ambientais nesta complexa e única região da América do Sul.

Referências

- Adnan RM, Liang Z, El-Shafie A, Zounemat-Kermani M, Kisi O. Prediction of Suspended Sediment Load Using Data-Driven Models. *Water*. 2019;11:2060. <https://doi.org/10.3390/w11102060>
- Afan HA, El-shafie A, Mohtar WHMW, Yaseen ZM. Past, present and prospect of an Artificial Intelligence (AI) based model for sediment transport prediction. *J Hydrol*. 2016;541:902–13. <https://doi.org/10.1016/j.jhydrol.2016.07.048>
- Afan HA, El-Shafie A, Yaseen ZM, Hameed MM, Wan Mohtar WHM, Hussain A. ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. *Water Resour Manag*. 2014;29:1231–45. <https://doi.org/10.1007/s11269-014-0870-1>
- Aires URV, da Silva DD, Fernandes Filho EI, Rodrigues LN, Uliana EM, Amorim RSS, de Melo Ribeiro CB, Campos JA. Modeling of surface sediment concentration in the Doce River basin using satellite remote sensing. *J Environ Manage*. 2022;323:116207
- Alho C. Biodiversity of the Pantanal: response to seasonal flooding regime and to environmental degradation. *Brazilian J Biol*. 2008;68:957–66. <https://doi.org/10.1590/S1519-69842008000500005>
- ANA. Estudos de avaliação dos efeitos da implantação de empreendimentos hidrelétricos. Brasília, DF, Brazil: 2020.
- ANA. Plano de Recursos Hídricos da Região Hidrográfica do Paraguai – PRH Paraguai: Relatório final. Brasília: 2018.
- Asce. Artificial Neural Networks in Hydrology. I: Preliminary Concepts. *J Hydrol Eng*. 2000;5:115–23
- Ashley JTF, Bushaw-Newton K, Wilhelm M, Boettner A, Drames G, Velinsky DJ. The effects of small dam removal on the distribution of sedimentary contaminants. *Environ Monit Assess*. 2006;114:287–312. <https://doi.org/10.1007/s10661-006-4781-3>
- Assine ML. River avulsions on the Taquari megafan, Pantanal wetland, Brazil. *Geomorphology*. 2005;70:357–71. <https://doi.org/10.1016/j.geomorph.2005.02.013>
- Assine ML, Merino ER, Pupim FN, Warren L V., Guerreiro RL, McGlue MM. Geology and Geomorphology of the Pantanal Basin; 2015 [cited [s.d.]]. https://doi.org/10.1007/698_2015_349
- Atieh M, Mehlretter SL, Gharabaghi B, Rudra R. Integrative neural networks model for prediction of sediment rating curve parameters for ungauged basins. *J Hydrol*. 2015;531:1095–107. <https://doi.org/10.1016/j.jhydrol.2015.11.008>
- Attila J, Kauppila P, Kallio KY, Alasalmi H, Keto V, Bruun E, Koponen S. Applicability of Earth Observation chlorophyll-a data in assessment of water status via MERIS — With implications for the use of OLCI sensors. *Remote Sens Environ*. 2018;212:273–87. <https://doi.org/10.1016/j.rse.2018.02.043>
- Aytek A, Kişi Ö. A genetic programming approach to suspended sediment modelling. *J Hydrol*. 2008;351:288–98. <https://doi.org/10.1016/j.jhydrol.2007.12.005>
- Baker DW, Bledsoe BP, Albano CM, Poff NL. Downstream effects of diversion dams on sediment and hydraulic conditions of Rocky Mountain streams. *River Res Appl*. 2011;27:388–401. <https://doi.org/10.1002/rra.1376>
- Bayram A, Kankal M, Önsoy H. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. *Environ Monit Assess*. 2012;184:4355–65. <https://doi.org/10.1007/s10661-011-2269-2>
- Bayram A, Kankal M, Tayfur G, Önsoy H. Prediction of suspended sediment concentration from water quality variables. *Neural Comput Appl*. 2014;24:1079–87. <https://doi.org/10.1007/s00521-012-1333-3>
- Bergier I. Effects of highland land-use over lowlands of the Brazilian Pantanal. *Sci Total Environ*. 2013;463–464:1060–6. <https://doi.org/10.1016/j.scitotenv.2013.06.036>
- Bracken LJ, Turnbull L, Wainwright J, Bogaart P. Sediment connectivity: a framework for understanding sediment transfer at multiple scales. *Earth Surf Process Landforms*. 2015;40:177–88. <https://doi.org/10.1002/esp.3635>
- Brandt SA. Classification of geomorphological effects downstream of dams. *Catena*. 2000;40:375–401.

[https://doi.org/10.1016/S0341-8162\(00\)00093-X](https://doi.org/10.1016/S0341-8162(00)00093-X)

Bravo JM, Allasia D, Paz AR, Collischonn W, Tucci CEM. Coupled Hydrologic-Hydraulic Modeling of the Upper Paraguay River Basin. *J Hydrol Eng*. 2012;17:635–46. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000494](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000494)

Brown CF, Brumby SP, Guzder-Williams B, Birch T, Hyde SB, Mazzariello J, Czerwinski W, Pasquarella VJ, Haertel R, Ilyushchenko S, Schwehr K, Weisse M, Stolle F, Hanson C, Guinan O, Moore R, Tait AM. Dynamic World, Near real-time global 10 m land use land cover mapping. *Sci Data*. 2022;9:251. <https://doi.org/10.1038/s41597-022-01307-4>

Buchhorn M., Bertels L, Smets B, De Roo B, Lesiv M, Tsendbazar NE, Masiliunas D, Linlin L. Copernicus Global Land Service: Land Cover 100m: Version 3 Globe 2015-2019: Algorithm Theoretical Basis Document. Copernicus Glob L Oper. 2020

BÜHLER BF, SANTOS C dos, SOUZA CA de, BELOTE LCG, TESTONI MC. APORTE DE SEDIMENTOS DO RIO PARAGUAI ENTRE O PERÍMETRO URBANO DE CÁCERES, MT, E O BARRANCO DO TOURO. *Cad Geociências*. 2012;12

Burrough PA, McDonnell RA. Principles of geographical information systems. 3rd ed. New York: Oxford University Press; 1998. <https://doi.org/10.2307/144481>

Buyukyildiz M, Kumcu SY. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. *Water Resour Manag*. 2017;31:1343–59. <https://doi.org/10.1007/s11269-017-1581-1>

Campos JA. Modelagem hidrossedimentológica em escala espacial e temporal na bacia do Alto Paraguai utilizando redes neurais artificiais. Universidade Federal do Rio Grande do Sul; 2019.

Campos JA, Fassoni-Andrade AC, Uvo CB, Fujita T, Cuartas LA, Attila J, Bruun E, Pedrollo OC. Mapping suspended sediment dynamics in the Pantanal wetland using artificial neural networks and remote sensing. *Remote Sens Environ*. 2023;In press

Campos JA, Pedrollo OC. Modelling and assessing how small hydropower facilities affect sediment transport by using fuzzy inference systems. *J Hydrol*. 2023;620:129374. <https://doi.org/10.1016/j.jhydrol.2023.129374>

Campos JA, Pedrollo OC. A regional ANN-based model to estimate suspended sediment concentrations in ungauged heterogeneous basins. *Hydrol Sci J*. 2021;66:1222–32. <https://doi.org/10.1080/02626667.2021.1918695>

Campos MM de, Tritico HM, Girard P, Zeilhofer P, Hamilton SK, Fantin-Cruz I. Predicted impacts of proposed hydroelectric facilities on fish migration routes upstream from the Pantanal wetland (Brazil). *River Res Appl*. 2020;36:452–64. <https://doi.org/10.1002/rra.3588>

Cantalice JRB, Souza WL da S, Bezerra Silva YJA, Guerra SMS, Araújo AM, Cavalcante DM, Silva CMCAC. Bedload and Suspended Sediment of a Watershed Impacted by Dams. Effects of Sediment Transport on Hydraulic Structures. *InTech*; 2015. . <https://doi.org/10.5772/61478>

Carvalho N. Hidrossedimentologia prática. 2ª. Rio de Janeiro: Interciência; 2008

Casillas J. Interpretability issues in fuzzy modeling. 2003

Casserly CM, Turner JN, O' Sullivan JJ, Bruen M, Bullock C, Atkinson S, Kelly-Quinn M. Effect of low-head dams on reach-scale suspended sediment dynamics in coarse-bedded streams. *J Environ Manage*. 2021;277. <https://doi.org/10.1016/j.jenvman.2020.111452>

Cavalcante RBL, da Silva Ferreira DB, Pontes PRM, Tedeschi RG, da Costa CPW, de Souza EB. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. *Atmos Res*. 2020;238:104879

Chen T, Shang C, Su P, Shen Q. Induction of accurate and interpretable fuzzy rules from preliminary crisp representation. *Knowledge-Based Syst*. 2018. <https://doi.org/10.1016/j.knosys.2018.02.003>

Chong XY, Vericat D, Batalla RJ, Teo FY, Lee KSP, Gibbins CN. A review of the impacts of dams on the hydromorphology of tropical rivers. *Sci Total Environ*. 2021;794. <https://doi.org/10.1016/j.scitotenv.2021.148686>

Claverie M, Ju J, Masek JG, Dungan JL, Vermote EF, Roger J-C, Skakun S V, Justice C. The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sens Environ*. 2018;219:145–61

Cobaner M, Unal B, Kisi O. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and

- neural network approaches using hydro-meteorological data. *J Hydrol.* 2009;367:52–61. <https://doi.org/10.1016/j.jhydrol.2008.12.024>
- Colman CB, Oliveira PTS, Almagro A, Soares-Filho BS, Rodrigues DBB. Effects of Climate and Land-Cover Changes on Soil Erosion in Brazilian Pantanal. *Sustain.* 2019;11. <https://doi.org/10.3390/sul1247053>
- Couto TBA, Olden JD. Global proliferation of small hydropower plants – science and policy. *Front Ecol Environ.* 2018;16:91–100. <https://doi.org/10.1002/fee.1746>
- Csiki S, Rhoads BL. Hydraulic and geomorphological effects of run-of-river dams. *Prog Phys Geogr.* 2010;34:755–80. <https://doi.org/10.1177/0309133310369435>
- Csiki SJC, Rhoads BL. Influence of four run-of-river dams on channel morphology and sediment characteristics in Illinois, USA. *Geomorphology.* 2014;206:215–29. <https://doi.org/10.1016/j.geomorph.2013.10.009>
- Dai Z, Liu JT. Impacts of large dams on downstream fluvial sedimentation: An example of the Three Gorges Dam (TGD) on the Changjiang (Yangtze River). *J Hydrol.* 2013;480:10–8. <https://doi.org/10.1016/j.jhydrol.2012.12.003>
- Dehkordi AT, Ghasemi H, Zoj MJV. Machine Learning-Based Estimation of Suspended Sediment Concentration along Missouri River using Remote Sensing Imageries in Google Earth Engine. In: 2021 7th International Conference on Signal Processing and Intelligent Systems (ICSPIS); 2021; IEEE; 2021. p. 1–5.
- Dutu LC, Mauris G, Bolon P. A Fast and Accurate Rule-Base Generation Method for Mamdani Fuzzy Systems. *IEEE Trans Fuzzy Syst.* 2018;26:715–33. <https://doi.org/10.1109/TFUZZ.2017.2688349>
- Editora Rios Vivos Allasia DG, Collischonn W, Tucci CEM, Germano A, Collischonn B, Failache N. *Modelo Hidrológico da Bacia do Alto Paraguai.* Porto Alegre-RS: 2004.
- Ely P, Fantin-Cruz I, Tritico HM, Girard P, Kaplan D. Dam-Induced Hydrologic Alterations in the Rivers Feeding the Pantanal. *Front Environ Sci.* 2020;8:1–17. <https://doi.org/10.3389/fenvs.2020.579031>
- Embrapa. Monitoramento das alterações da cobertura vegetal e uso do Solo na Bacia do Alto Paraguai – Porção Brasileira – Analysis period: 2012 to 2014; Brasília, DF, Brazil: 2015 [cited 2019 abr. 2]. Available from: https://d3nehc6yl9qzo4.cloudfront.net/downloads/publicacao_bap_sumarioexecutivo_2012_2014_web.pdf.
- Erskine WD. Downstream geomorphic impacts of large dams: the case of Glenbawn Dam, NSW. *Appl Geogr.* 1985;5:195–210. [https://doi.org/10.1016/0143-6228\(85\)90022-0](https://doi.org/10.1016/0143-6228(85)90022-0)
- Fagundes HO, Paiva RCD, Fan FM, Buarque DC, Fassoni-Andrade AC. Sediment modeling of a large-scale basin supported by remote sensing and in-situ observations. *Catena.* 2020;190:104535. <https://doi.org/10.1016/j.catena.2020.104535>
- Fantin-Cruz I, de Oliveira MD, Campos JA, de Campos MM, de Souza Ribeiro L, Mingoti R, de Souza ML, Pedrollo O, Hamilton SK. Further Development of Small Hydropower Facilities Will Significantly Reduce Sediment Transport to the Pantanal Wetland of Brazil. *Front Environ Sci.* 2020;8. <https://doi.org/10.3389/fenvs.2020.577748>
- Fantin-Cruz I, Pedrollo O, Castro NMR, Girard P, Zeilhofer P, Hamilton SK. Historical reconstruction of floodplain inundation in the Pantanal (Brazil) using neural networks. *J Hydrol.* 2011;399:376–84. <https://doi.org/10.1016/j.jhydrol.2011.01.014>
- Fantin-Cruz I, Pedrollo O, Girard P, Zeilhofer P, Hamilton SK. Changes in river water quality caused by a diversion hydropower dam bordering the Pantanal floodplain. *Hydrobiologia.* 2016;768:223–38. <https://doi.org/10.1007/s10750-015-2550-4>
- FAO/UNESCO. *Soil map of the world.* 1:5.000.000. 1974
- Farias SL, Centurião TD, Sousa YDL, Carvalho GA, Ide CN. Hidrossedimentologia do rio Miranda, Pantanal Sul. In: *Encontro Nacional de Engenharia de Sedimentos*; 2018; Vitória-ES. 2018. p. 1–8.
- Farr TG, Rosen PA, Caro E, Crippen R, Duren R, Hensley S, Kobrick M, Paller M, Rodriguez E, Roth L, Seal D, Shaffer S, Shimada J, Umland J, Werner M, Oskin M, Burbank D, Alsdorf DE. The shuttle radar topography mission. *Rev Geophys.* 2007;45. <https://doi.org/10.1029/2005RG000183>
- Fassoni-Andrade AC, Paiva RCD de. Mapping spatial-temporal sediment dynamics of river-floodplains in the Amazon. *Remote Sens Environ.* 2019;221:94–107. <https://doi.org/10.1016/j.rse.2018.10.038>
- Figueiredo JSMC d., Fantin-Cruz I, Silva GMS, Beregula RL, Girard P, Zeilhofer P, Uliana EM, Morais

EB de, Tritico HM, Hamilton SK. Hydropeaking by Small Hydropower Facilities Affects Flow Regimes on Tributaries to the Pantanal Wetland of Brazil. *Front Environ Sci.* 2021;9:1–13. <https://doi.org/10.3389/fenvs.2021.577286>

Forsberg C. Importance of sediments in understanding nutrient cyclings in lakes. *Hydrobiologia.* 1989;176–177:263–77. <https://doi.org/10.1007/BF00026561>

Francke T, Werb S, Sommerer E, López-Tarazón JA. Analysis of runoff, sediment dynamics and sediment yield of subcatchments in the highly erodible Isábena catchment, Central Pyrenees. *J Soils Sediments.* 2014;14:1909–20. <https://doi.org/10.1007/s11368-014-0990-5>

Friedl MA, McIver DK, Hodges JCF, Zhang XY, Muchoney D, Strahler AH, Woodcock CE, Gopal S, Schneider A, Cooper A, Baccini A, Gao F, Schaaf C. Global land cover mapping from MODIS: Algorithms and early results. *Remote Sens Environ.* 2002;83. [https://doi.org/10.1016/S0034-4257\(02\)00078-0](https://doi.org/10.1016/S0034-4257(02)00078-0)

Friedl MA, Sulla-Menashe D, Tan B, Schneider A, Ramankutty N, Sibley A, Huang X. MODIS Collection 5 global land cover: Algorithm refinements and characterization of new datasets. *Remote Sens Environ.* 2010;114. <https://doi.org/10.1016/j.rse.2009.08.016>

Fryirs K. (Dis)Connectivity in catchment sediment cascades: a fresh look at the sediment delivery problem. *Earth Surf Process Landforms.* 2013;38:30–46. <https://doi.org/10.1002/esp.3242>

Funk C, Peterson P, Landsfeld M, Pedreros D, Verdin J, Shukla S, Husak G, Rowland J, Harrison L, Hoell A, Michaelsen J. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci Data.* 2015;2:150066. <https://doi.org/10.1038/sdata.2015.66>

Galdino S, Vieira LM, Pellegrin LA. Impactos Ambientais e Socioeconômicos na Bacia do Rio Taquari - Pantanal. 2006

Gebremicael TG, Mohamed YA, van der Zaag P, Berhe AG, Haile GG, Hagos EY, Hagos MK. Comparison and validation of eight satellite rainfall products over the rugged topography of Tekeze-Atbara Basin at different spatial and temporal scales. *Hydrol Earth Syst Sci Discuss.* 2017:1–31. <https://doi.org/10.5194/hess-2017-504>

Gholami V, Booij MJ, Nikzad Tehrani E, Hadian MA. Spatial soil erosion estimation using an artificial neural network (ANN) and field plot data. *Catena.* 2018;163:210–8. <https://doi.org/10.1016/j.catena.2017.12.027>

Godoy JM, Padovani CR, Guimarães JRD, Pereira JCA, Vieirac LM, Carvalho ZL, Galdino S. Evaluation of the siltation of river Taquari, Pantanal, Brazil, through 210Pb geochronology of floodplain lake sediments. *J Braz Chem Soc.* 2002;13. <https://doi.org/10.1590/S0103-50532002000100011>

Gomes L, Simões S, Dalla Nora E, de Sousa-Neto E, Forti M, Ometto J. Agricultural Expansion in the Brazilian Cerrado: Increased Soil and Nutrient Losses and Decreased Agricultural Productivity. *Land.* 2019;8:12. <https://doi.org/10.3390/land8010012>

Grove MK, Bilotta GS, Woockman RR, Schwartz JS. Suspended sediment regimes in contrasting reference-condition freshwater ecosystems: Implications for water quality guidelines and management. *Sci Total Environ.* 2015;502:481–92. <https://doi.org/10.1016/j.scitotenv.2014.09.054>

Guillaume S. Designing fuzzy inference systems from data: An interpretability-oriented review. *IEEE Trans Fuzzy Syst.* 2001;9:426–43. <https://doi.org/10.1109/91.928739>

Hafeez S, Wong MS, Abbas S, Asim M. Evaluating Landsat-8 and Sentinel-2 Data Consistency for High Spatiotemporal Inland and Coastal Water Quality Monitoring. *Remote Sens.* 2022;14:3155. <https://doi.org/10.3390/rs14133155>

Haimann M, Liedermann M, Lalk P, Habersack H. An integrated suspended sediment transport monitoring and analysis concept. *Int J Sediment Res.* 2014;29:135–48. [https://doi.org/10.1016/S1001-6279\(14\)60030-5](https://doi.org/10.1016/S1001-6279(14)60030-5)

Hamilton SK. Hydrological controls of ecological structure and function in the Pantanal wetland (Brazil). *Ecohydrol South Am rivers Wetl.* 2002a;6:133–58

Hamilton SK. Comparison of inundation patterns among major South American floodplains. *J Geophys Res.* 2002b;107:8038. <https://doi.org/10.1029/2000JD000306>

Hamilton SK, Sippel SJ, Melack JM. Inundation patterns in the Pantanal wetland of South America determined from passive microwave remote sensing. *Arch für Hydrobiol.* 1996a;137:1–23. <https://doi.org/10.1127/archiv-hydrobiol/137/1996/1>

Hamilton SK, Sippel SJ, Melack JM. Inundation patterns in the Pantanal wetland of South America

determined from passive microwave remote sensing. *Arch fur Hydrobiol.* 1996b;137:1–23

Harrington ST, Harrington JR. An assessment of the suspended sediment rating curve approach for load estimation on the Rivers Bandon and Owenabue, Ireland. *Geomorphology.* 2013;185:27–38. <https://doi.org/10.1016/j.geomorph.2012.12.002>

Hebb DO. *The organization of behavior: A neuropsychological theory.* Psychol Press. 1949

Hecht-Nielsen R. *Neurocomputing.* Massachusetts: Addison-Wesley Publishing Company; 1990

Hecht-Nielsen R. Theory of the Backpropagation Neural Network. *Proc Int Jt Conf Neural Networks.* 1989;1:593–605. <https://doi.org/10.1109/IJCNN.1989.118638>

Heng S, Suetsugi T. Using Artificial Neural Network to Estimate Sediment Load in Ungauged Catchments of the Tonle Sap River Basin, Cambodia. *J Water Resour Prot.* 2013;05:111–23. <https://doi.org/10.4236/jwarp.2013.52013>

Ho DWC, Zhang PA, Xu J. Fuzzy wavelet networks for function learning. *IEEE Trans Fuzzy Syst.* 2001. <https://doi.org/10.1109/91.917126>

Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators. *Neural Networks.* 1989;2:359–66. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)

Hou AY, Kakar RK, Neeck S, Azarbarzin AA, Kummerow CD, Kojima M, Oki R, Nakamura K, Iguchi T. The Global Precipitation Measurement Mission. *Bull Am Meteorol Soc.* 2014;95:701–22. <https://doi.org/10.1175/BAMS-D-13-00164.1>

Huffman G, Bolvin D, Braithwaite D, Hsu K, Joyce R, Kidd C, Nelkin E, Sorooshian S, Tan J, Xie P. NASA GPM Integrated Multi-satellite Retrievals for GPM (IMERG) Algorithm Theoretical Basis Document (ATBD) Version 06. Nasa/Gsfc. 2020

Jain SK. Development of integrated sediment rating curves using ANNs. *J Hydraul Eng.* 2001;127:30–7. [https://doi.org/10.1061/\(ASCE\)0733-9429\(2001\)127:1\(30\)](https://doi.org/10.1061/(ASCE)0733-9429(2001)127:1(30))

Jang JSR. ANFIS: Adaptive-Neuro-Fuzzy Inference System. *IEEE Trans Syst Man Cybern.* 1993. <https://doi.org/10.1109/21.256541>

Jaramillo F, Desormeaux A, Hedlund J, Jawitz J, Clerici N, Piemontese L, Rodríguez-Rodríguez J, Anaya J, Blanco-Libreros J, Borja S, Celi J, Chalov S, Chun K, Cresso M, Destouni G, Dessu S, Di Baldassarre G, Downing A, Espinosa L, Ghajarnia N, Girard P, Gutiérrez Á, Hansen A, Hu T, Jarsjö J, Kalantari Z, Labbaci A, Licero-Villanueva L, Livsey J, Machotka E, McCurley K, Palomino-Ángel S, Pietron J, Price R, Ramchunder S, Ricaurte-Villota C, Ricaurte L, Dahir L, Rodríguez E, Salgado J, Sannel A, Santos A, Seifollahi-Aghmiani S, Sjöberg Y, Sun L, Thorslund J, Vigouroux G, Wang-Erlandsson L, Xu D, Zamora D, Ziegler A, Åhlén I. Priorities and Interactions of Sustainable Development Goals (SDGs) with Focus on Wetlands. *Water.* 2019;11:619. <https://doi.org/10.3390/w11030619>

Jardim PF, Melo MMM, Ribeiro L de C, Collischonn W, Paz AR da. A Modeling Assessment of Large-Scale Hydrologic Alteration in South American Pantanal Due to Upstream Dam Operation. *Front Environ Sci.* 2020;8:1–15. <https://doi.org/10.3389/fenvs.2020.567450>

Jean Milien E, Nunes GM, Pierre G, Hamilton SK, Da Cunha CN. Hydrological Dynamics of the Pantanal, a Large Tropical Floodplain in Brazil, Revealed by Analysis of Sentinel-2 Satellite Imagery. *Water.* 2023;15:2180. <https://doi.org/10.3390/w15122180>

Jeng JT, Lee TT. Support vector machines for the fuzzy neural networks. In: *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics; 1999; 1999.* <https://doi.org/10.1109/icsmc.1999.816469>

Jensen JR. *Remote sensing of the environment: An earth resource perspective 2/e.* Pearson Education India; 2009

Jimeno-Sáez P, Martínez-España R, Casalí J, Pérez-Sánchez J, Senent-Aparicio J. A comparison of performance of SWAT and machine learning models for predicting sediment load in a forested Basin, Northern Spain. *Catena.* 2022;212. <https://doi.org/10.1016/j.catena.2021.105953>

Kallio K, Koponen S, Ylöstalo P, Kervinen M, Pyhälähti T, Attila J. Validation of MERIS spectral inversion processors using reflectance, IOP and water quality measurements in boreal lakes. *Remote Sens Environ.* 2015;157:147–57. <https://doi.org/10.1016/j.rse.2014.06.016>

- Kaya M, Alhadj R. A clustering algorithm with genetically optimized membership functions for fuzzy association rules mining. *IEEE Int Conf Fuzzy Syst.* 2003;2:881–6. <https://doi.org/10.1109/fuzz.2003.1206547>
- Khosravi K, Mao L, Kisi O, Yaseen ZM, Shahid S. Quantifying hourly suspended sediment load using data mining models: Case study of a glacierized Andean catchment in Chile. *J Hydrol.* 2018;567:165–79. <https://doi.org/10.1016/j.jhydrol.2018.10.015>
- Kirk JTO. *Light and photosynthesis in aquatic ecosystems.* Cambridge university press; 1994
- Kisi O, Dailr AH, Cimen M, Shiri J. Suspended sediment modeling using genetic programming and soft computing techniques. *J Hydrol.* 2012;450–451:48–58. <https://doi.org/10.1016/j.jhydrol.2012.05.031>
- Kisi O, Shiri J. River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. *Comput Geosci.* 2012;43:73–82. <https://doi.org/10.1016/j.cageo.2012.02.007>
- Kondolf GM, Rubin ZK, Minear JT. Dams on the Mekong: Cumulative sediment starvation. *Water Resour Res.* 2014;50:5158–69. <https://doi.org/10.1002/2013WR014651>
- Kumar A, Kumar P, Singh VK. Evaluating Different Machine Learning Models for Runoff and Suspended Sediment Simulation. *Water Resour Manag.* 2019;33:1217–31. <https://doi.org/10.1007/s11269-018-2178-z>
- Kwon M, Kwon H-H, Han D. A Hybrid Approach Combining Conceptual Hydrological Models, Support Vector Machines and Remote Sensing Data for Rainfall-Runoff Modeling. *Remote Sens.* 2020;12:1801. <https://doi.org/10.3390/rs12111801>
- Lafdani EK, Moghaddam Nia A, Ahmadi A. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *J Hydrol.* 2013;478:50–62. <https://doi.org/10.1016/j.jhydrol.2012.11.048>
- Laurencelle J, Logan T, Gens R. ASF Radiometrically Terrain Corrected ALOS PALSAR products. *Alaska Satell Facil.* 2015;1
- Lindloff SD. Institutionalizing the option of dam removal: The New Hampshire initiative. *Water Sci Technol.* 2003;48:9–16. <https://doi.org/10.2166/wst.2003.0419>
- Lobo F de L, Novo EML de M, Barbosa CCF, Galvão LS. Reference spectra to classify Amazon water types. *Int J Remote Sens.* 2012;33:3422–42
- Lohani AK, Goel NK, Bhatia KKS. Deriving stage-discharge-sediment concentration relationships using fuzzy logic. *Hydrol Sci J.* 2007. <https://doi.org/10.1623/hysj.52.4.793>
- Lucchese LV, de Oliveira GG, Pedrollo OC. Mamdani fuzzy inference systems and artificial neural networks for landslide susceptibility mapping. *Nat Hazards.* 2021;106:2381–405. <https://doi.org/10.1007/s11069-021-04547-6>
- Luz LD. *Geomorfologia da Planície de Inundação e Hidrodinâmica da Confluência Paraguai-Cuiabá: Pantanal Mato-Grossense, Brasil.* Universidade Estadual de Maringá; 2019.
- Macedo HDA. *Evolução Geomorfológica e dinâmica hidrossedimentar da Planície Fluvial Paraguai-Corumbá, Quaternário do Pantanal.* Universidade Estadual Paulista; 2017.
- Magilligan FJ, Roberts MO, Marti M, Renshaw CE. The impact of run-of-river dams on sediment longitudinal connectivity and downstream channel equilibrium. *Geomorphology.* 2021;376:107568. <https://doi.org/10.1016/j.geomorph.2020.107568>
- Mamdani. Application of Fuzzy Logic to Approximate Reasoning Using Linguistic Synthesis. *IEEE Trans Comput.* 1977;C-26:1182–91. <https://doi.org/10.1109/TC.1977.1674779>
- Marengo J, Alves L, Torres R. Regional climate change scenarios in the Brazilian Pantanal watershed. *Clim Res.* 2016;68:201–13. <https://doi.org/10.3354/cr01324>
- Marengo JA, Oliveira GS, Alves LM. Climate Change Scenarios in the Pantanal. 2015. p. 227–38. . https://doi.org/10.1007/698_2015_357
- Martinez J, Espinoza-Villar R, Armijos E, Silva Moreira L. The optical properties of river and floodplain waters in the Amazon River Basin: Implications for satellite-based measurements of suspended particulate matter. *J Geophys Res Earth Surf.* 2015;120:1274–87
- Marzano FS, Iacobelli M, Orlandi M, Cimini D. Coastal water remote sensing from sentinel-2 satellite data using physical, statistical, and neural network retrieval approach. *IEEE Trans Geosci Remote Sens.* 2020;59:915–

- Masek JG, Claverie M, Ju J, Vermote E, Justice CO. A Harmonized Landsat-Sentinel-2 Surface Reflectance product: a resource for Agricultural Monitoring. In: AGU Fall Meeting Abstracts; 2015; 2015. p. B43A-0541.
- Matía F, Al-Hadithi BM, Jiménez A, Segundo PS. An affine fuzzy model with local and global interpretations. *Appl Soft Comput J*. 2011. <https://doi.org/10.1016/j.asoc.2011.03.018>
- McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys*. 1943;5:115–33
- Mingoti R, Sais ICR, Padovani CR, Calheiros DF, Oliveira MD De. Variação da produção de sedimentos entre 1985 e 2017 na bacia do rio São Lourenço. In: Simpósio Brasileiro de Sensoriamento Remoto; 2019; 2019.
- Mitsch WJ. Reconnecting Rivers to Their Floodplains. *Memoirs of an Environmental Science Professor*. 2023. . <https://doi.org/10.1201/9781003374619-6>
- Mohsen A, Kovács F, Kiss T. Remote Sensing of Sediment Discharge in Rivers Using Sentinel-2 Images and Machine-Learning Algorithms. *Hydrology*. 2022;9:88
- Mollae Z, Zahiri J, Jalili S, Ansari MR, Taghizadeh A. Estimating Suspended Sediment Concentration Using Remote Sensing and Artificial Neural Network (Case Study: Karun River). *J Water Soil Sci*. 2018;22:249–59. <https://doi.org/10.29252/jstnar.22.2.249>
- Moore RJ. Transfer functions, noise predictors and the forecasting of flood events in realtime. In: VP S, organizador. *Statistical analysis of rainfall and runoff*. Littleton: Water Resources Publications; 1982. p. 229–50.
- Morgan PC. *Soil Erosion and Conservation*. 2005
- Moriasi DN, Gitau MW, Pai N, Daggupati P. Hydrologic and Water Quality Models: Performance Measures and Evaluation Criteria. *Am Soc Agric Biol Eng*. 2015;58:1763–85. <https://doi.org/10.13031/trans.58.10715>
- Nash JE, Sutcliffe J V. River flow forecasting through conceptual models part I - A discussion of principles. *J Hydrol*. 1970;10:282–90. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Nhu V-H, Khosravi K, Cooper JR, Karimi M, Kisi O, Pham BT, Lyu Z. Monthly suspended sediment load prediction using artificial intelligence: testing of a new random subspace method. *Hydrol Sci J*. 2020;65:2116–27. <https://doi.org/10.1080/02626667.2020.1754419>
- Nilsson C, Reidy CA, Dynesius M, Revenga C. Fragmentation and flow regulation of the world's large river systems. *Science (80-)*. 2005;308:405–8. <https://doi.org/10.1126/science.1107887>
- Nilsson C, Svedmark M. Basic principles and ecological consequences of changing water regimes: Riparian plant communities. *Environ Manage*. 2002;30:468–80. <https://doi.org/10.1007/s00267-002-2735-2>
- Oliveira EC de, Pla-Pueyo S, Hackney CR. Natural and anthropogenic influences on the Nhecolândia wetlands, SE Pantanal, Brazil. *Geol Soc London, Spec Publ*. 2019;488:167–80. <https://doi.org/10.1144/SP488.5>
- Oliveira MD de, Fantin-Cruz I, Campos JA, Campos MM de, Mingoti R, Souza ML de, Figueiredo DM de, Dores EFG de C, Pedrollo O, Hamilton SK. Further Development of Small Hydropower Facilities May Alter Nutrient Transport to the Pantanal Wetland of Brazil. *Front Environ Sci*. 2020;8:1–19. <https://doi.org/10.3389/fenvs.2020.577793>
- Oliveira MHC, Sari V, dos Reis Castro NM, Pedrollo OC. Estimation of soil water content in watershed using artificial neural networks. *Hydrol Sci J*. 2017;62:2120–38. <https://doi.org/10.1080/02626667.2017.1364844>
- Onderka M, Krein A, Wrede S, Martínez-Carreras N, Hoffmann L. Dynamics of storm-driven suspended sediments in a headwater catchment described by multivariable modeling. *J Soils Sediments*. 2012;12:620–35. <https://doi.org/10.1007/s11368-012-0480-6>
- Orr CH, Rogers KL, Stanley EH. Channel morphology and P uptake following removal of a small dam. *J North Am Benthol Soc*. 2006;25:556–68. [https://doi.org/10.1899/0887-3593\(2006\)25\[556:CMAPUF\]2.0.CO;2](https://doi.org/10.1899/0887-3593(2006)25[556:CMAPUF]2.0.CO;2)
- Padovani CR. *Dinâmica espaço-temporal das inundações do Pantanal*. Universidade de São Paulo; 2010.
- Pancho DP, Alonso JM, Cordon O, Quirin A, Magdalena L. Fingrams: Visual representations of fuzzy rule-based inference for expert analysis of comprehensibility. *IEEE Trans Fuzzy Syst*. 2013;21:1133–49. <https://doi.org/10.1109/TFUZZ.2013.2245130>
- Paz AR da, Collischonn W, Bravo JM, Bates PD, Baugh C. The influence of vertical water balance on

modelling Pantanal (Brazil) spatio-temporal inundation dynamics. *Hydrol Process.* 2014;28:3539–53. <https://doi.org/10.1002/hyp.9897>

Pektas AO, Cigizoglu HK. Investigating the extrapolation performance of neural network models in suspended sediment data. *Hydrol Sci J.* 2017;62:1694–703. <https://doi.org/10.1080/02626667.2017.1349316>

Pereira OJR, Merino ER, Montes CR, Barbiero L, Rezende-Filho AT, Lucas Y, Melfi AJ. Estimating Water pH Using Cloud-Based Landsat Images for a New Classification of the Nhecolândia Lakes (Brazilian Pantanal). *Remote Sens.* 2020;12:1090. <https://doi.org/10.3390/rs12071090>

Peterson KT, Sagan V, Sidike P, Cox AL, Martinez M. Suspended sediment concentration estimation from landsat imagery along the lower missouri and middle Mississippi Rivers using an extreme learning machine. *Remote Sens.* 2018;10:1503

Pradhan RK, Markonis Y, Godoy MRV, Villalba-Pradas A, Andreadis KM, Nikolopoulos EI, Papalexiou SM, Rahim A, Tapiador FJ, Hanel M. Review of GPM IMERG performance: A global perspective. *Remote Sens Environ.* 2022;268:112754

Rocha PC. Sistemas Rio-Planície de Inundação: Geomorfologia e Conectividade Hidrodinâmica. *Cad Prudentino Geogr.* 2011;1

Roque F de O, Guerra A, Johnson M, Padovani C, Corbi J, Covich AP, Eaton D, Tomas WM, Valente-Neto F, Borges ACP, Pinho A, Barufatii A, Crispim B do A, Guariento RD, Andrade MH da S, Rezende-Filho AT, Portela R, Divina M, da Silva JCS, Bernadino C, Gomes de Sá ÉFG, Cordeiro-Estrela P, Desbiez A, Rosa IMD, Yon L. Simulating land use changes, sediment yields, and pesticide use in the Upper Paraguay River Basin: Implications for conservation of the Pantanal wetland. *Agric Ecosyst Environ.* 2021;314:107405. <https://doi.org/10.1016/j.agee.2021.107405>

Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol Rev.* 1958;65

Rozante JR, Gutierrez ER, Fernandes A de A, Vila DA. Performance of precipitation products obtained from combinations of satellite and surface observations. *Int J Remote Sens.* 2020;41:7585–604

Rozante JR, Moreira DS, Goncalves LGG, Vila DA. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. *Am Meteorol Soc.* 2010;25:885–94. <https://doi.org/10.1175/2010WAF2222325.1>

Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature.* 1986;323:533–6. <https://doi.org/10.1038/323533a0>

Salih SQ, Sharafati A, Khosravi K, Faris H, Kisi O, Tao H, Ali M, Yaseen ZM. River suspended sediment load prediction based on river discharge information: application of newly developed data mining models. *Hydrol Sci J.* 2020;65:624–37. <https://doi.org/10.1080/02626667.2019.1703186>

Santos HG, Jacomine PKT, Anjos LHC dos, Oliveira VÁ, Lumbreiras JF, Coelho MR, Almeida JA, Cunha TJF, Oliveira JB. Brazilian soil classification system; Brasília, DF: Embrapa; 2018 [cited 2019 abr. 7]. Available from: <https://www.embrapa.br/solos/busca-de-publicacoes/-/publicacao/1094001/brazilian-soil-classification-system>.

Sari V, Castro N, Kobiyama M. Estimativa da concentração de sedimentos suspensos com sensores ópticos: revisão / Estimation of the suspended sediment concentration with optical sensors: review. *Rev Bras Recur Hídricos.* 2015;20:816–36. <https://doi.org/10.21168/rbrh.v20n4.p816-836>

Sari V, Castro NM dos R, Pedrollo OC. Estimate of Suspended Sediment Concentration from Monitored Data of Turbidity and Water Level Using Artificial Neural Networks. *Water Resour Manag.* 2017;31:4909–23. <https://doi.org/10.1007/s11269-017-1785-4>

Sharaf El Din E, Zhang Y, Suliman A. Mapping concentrations of surface water quality parameters using a novel remote sensing and artificial intelligence framework. *Int J Remote Sens.* 2017;38:1023–42. <https://doi.org/10.1080/01431161.2016.1275056>

Shellenbarger GG, Wright SA, Schoellhamer DH. A sediment budget for the southern reach in San Francisco Bay, CA: Implications for habitat restoration. *Mar Geol.* 2013;345:281–93. <https://doi.org/10.1016/j.margeo.2013.05.007>

Shoab M, Shamseldin AY, Khan S, Khan MM, Khan ZM, Sultan T, Melville BW. A Comparative Study of Various Hybrid Wavelet Feedforward Neural Network Models for Runoff Forecasting. *Water Resour Manag.* 2018;32:83–103. <https://doi.org/10.1007/s11269-017-1796-1>

Silva ACC da, Fantin-Cruz I, de Lima ZM, de Figueiredo DM. Cumulative changes in water quality caused by six cascading hydroelectric dams on the Jauru river, tributary of the Pantanal floodplain. *Rev Bras Recur Hidricos*. 2019;24:1–12. <https://doi.org/10.1590/2318-0331.241920180047>

Silveira A, Barreto CJ de F, Gonçalves FA. MONITORAMENTO DA DESCARGA SÓLIDA NA BACIA DO RIO CUIABÁ-MT. In: XI Encontro Nacional de Engenharia de Sedimentos; 2014; 2014.

Singh A, Imtiyaz M, Isaac RK, Denis DM. Comparison of Artificial Neural Network Models for Sediment Yield Prediction at Single Gauging Station of Watershed in Eastern India. *J Hydrol Eng*. 2013;18:115–20. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000601](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000601)

Sirabahenda Z, St-Hilaire A, Courtenay SC, Alberto A, Van Den Heuvel MR. A modelling approach for estimating suspended sediment concentrations for multiple rivers influenced by agriculture. *Hydrol Sci J*. 2017;62:2209–21. <https://doi.org/10.1080/02626667.2017.1367396>

Souza CM, Z. Shimbo J, Rosa MR, Parente LL, A. Alencar A, Rudorff BFT, Hasenack H, Matsumoto M, G. Ferreira L, Souza-Filho PWM, de Oliveira SW, Rocha WF, Fonseca A V., Marques CB, Diniz CG, Costa D, Monteiro D, Rosa ER, Vélez-Martin E, Weber EJ, Lenti FEB, Paternost FF, Pareyn FGC, Siqueira J V., Viera JL, Neto LCF, Saraiva MM, Sales MH, Salgado MPG, Vasconcelos R, Galano S, Mesquita V V., Azevedo T. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. *Remote Sens*. 2020;12:2735. <https://doi.org/10.3390/rs12172735>

Tananaev NI, Debolskiy MV. Turbidity observations in sediment flux studies: Examples from Russian rivers in cold environments. *Geomorphology*. 2014;218:63–71. <https://doi.org/10.1016/j.geomorph.2013.09.031>

Tayfur G. Artificial neural networks for sheet sediment transport. *Hydrol Sci J*. 2002;47:879–92. <https://doi.org/10.1080/02626660209492997>

Teixeira LC, Mariani PP, Pedrollo OC, Castro NMR, Sari V. Artificial Neural Network and Fuzzy Inference System Models for Forecasting Suspended Sediment and Turbidity in Basins at Different Scales. *Water Resour Manag*. 2020;34:3709–23. <https://doi.org/10.1007/s11269-020-02647-9>

Thompson J, Cassidy R, Doody DG, Flynn R. Assessing suspended sediment dynamics in relation to ecological thresholds and sampling strategies in two Irish headwater catchments. *Sci Total Environ*. 2014;468–469:345–57. <https://doi.org/10.1016/j.scitotenv.2013.08.069>

Tomas WM, et al. Sustainability Agenda for the Pantanal Wetland: Perspectives on a Collaborative Interface for Science, Policy, and Decision-Making. *Trop Conserv Sci*. 2019;12:194008291987263. <https://doi.org/10.1177/1940082919872634>

Velinsky DJ, Bushaw-Newton KL, Kreeger DA, Johnson TE. Effects of small dam removal on stream chemistry in southeastern Pennsylvania. *J North Am Benthol Soc*. 2006;25:569–82. [https://doi.org/10.1899/0887-3593\(2006\)25\[569:EOSDRO\]2.0.CO;2](https://doi.org/10.1899/0887-3593(2006)25[569:EOSDRO]2.0.CO;2)

Vercruyssen K, Grabowski RC, Rickson RJ. Suspended sediment transport dynamics in rivers: Multi-scale drivers of temporal variation. *Earth-Science Rev*. 2017;166:38–52. <https://doi.org/10.1016/j.earscirev.2016.12.016>

Wang L-X. Fuzzy systems are universal approximators. In: [1992 Proceedings] IEEE International Conference on Fuzzy Systems; 1992; IEEE; 1992. p. 1163–70. <https://doi.org/10.1109/FUZZY.1992.258721>

Wang LX, Mendel JM. Generating Fuzzy Rules by Learning from Examples. *IEEE Trans Syst Man Cybern*. 1992. <https://doi.org/10.1109/21.199466>

Wang Y, Rhoads BL, Wang D, Wu J, Zhang X. Impacts of large dams on the complexity of suspended sediment dynamics in the Yangtze River. *J Hydrol*. 2018;558:184–95. <https://doi.org/10.1016/j.jhydrol.2018.01.027>

Wei X, Sauvage S, Ouillon S, Le TPQ, Orange D, Herrmann M, Sanchez-Perez JM. A modelling-based assessment of suspended sediment transport related to new damming in the Red River basin from 2000 to 2013. *Catena*. 2021;197:104958. <https://doi.org/10.1016/j.catena.2020.104958>

Widrow B, Hoff M. Adaptive switching circuits. *Ire Wescon Conv Rec*. 1960:96–104

Wildman LAS, MacBroom JG. The evolution of gravel bed channels after dam removal: Case study of the Anaconda and Union City Dam removals. *Geomorphology*. 2005;71:245–62. <https://doi.org/10.1016/j.geomorph.2004.08.018>

WMO. Guide to Meteorological Instruments and Methods of observation. Geneva: Chairperson; 2008.

<https://doi.org/Guide to meteorological instrument and observing practices>

Wosiacki LFK, Suekame HK, Wood MS, Gonçalves FV, Bleninger T. Mapping of suspended sediment transport using acoustic methods in a Pantanal tributary. *Environ Monit Assess.* 2021;193:493. <https://doi.org/10.1007/s10661-021-09266-w>

Yadav A, Chatterjee S, Equeenuddin SM. Suspended sediment yield estimation using genetic algorithm-based artificial intelligence models: case study of Mahanadi River, India. *Hydrol Sci J.* 2018;63:1162–82. <https://doi.org/10.1080/02626667.2018.1483581>

Yu X, Zhang X, Li J, Zhang M, Xie Y. Effects of vegetation cover and precipitation on the process of sediment produced by erosion in a small watershed of loess region. *Acta Ecol Sin.* 2006;26:1–8. [https://doi.org/10.1016/S1872-2032\(06\)60001-2](https://doi.org/10.1016/S1872-2032(06)60001-2)

Zadeh LA. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. *IEEE Trans Syst Man Cybern.* 1973;SMC-3:28–44. <https://doi.org/10.1109/TSMC.1973.5408575>

Zanaga D, Van De Kerchove R, Daems D, De Keersmaecker W, Brockmann C, Kirches G, Wevers J, Cartus O, Santoro M, Fritz S, Lesiv M, Herold M, Tsendbazar NE, Xu P, Ramoino F, Arino O. *ESA WorldCover 10 m 2021 v200. Meteosat Second Gener Evapotranspiration.* 2022

Zeiger S, Hubbart JA. Quantifying suspended sediment flux in a mixed-land-use urbanizing watershed using a nested-scale study design. *Sci Total Environ.* 2016;542:315–23. <https://doi.org/10.1016/j.scitotenv.2015.10.096>

APÊNDICE 1

Informações sobre estações fluviométricas na Bacia do Alto Paraguai, com dados de Turbidez e de Concentração de Sedimentos em Suspensão (CSS), e dados de CSS calculados a partir de dados de turbidez, vazão, bem como dados de sensoriamento remoto, utilizando o modelo regional baseado em RNAS (artigo 01).

Link de acesso aos dados:

https://zenodo.org/records/10208224?token=eyJhbGciOiJIUzUxMiJ9.eyJpZCI6IjRmMzdjY2NmLTE0MzgtNDcwMiliOWU5LTA2ZTI5NTNiOTI0MCIsImRhdGEiOiOnt9LCJyYW5kb2iOiI4YjAyMTE4MDY0MjhmZW5kZWwZTk0M2Y0MWQ5YWE4MSJ9.Rsg2-qWb8uUDMdU0JXBmp9xUIfSmtAqOE29c8XE7kD0ZyKl1w1_IWyqQn6xZwn9VFg5PLm2KKOq72-amQwitMQ

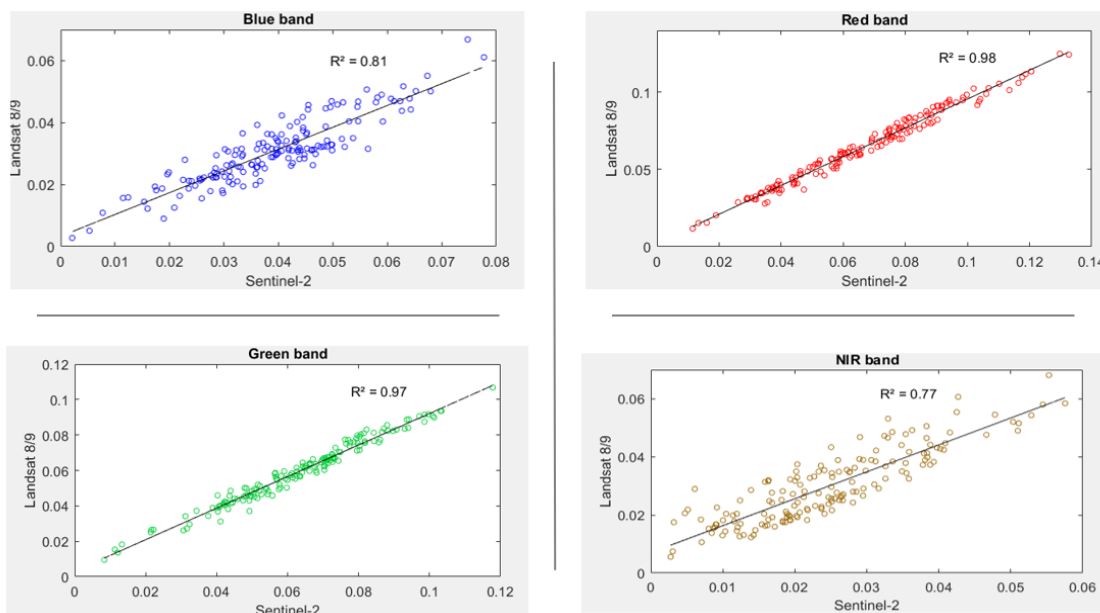
APÊNDICE 2

Código em Javascript para Google Earth Engine - Cálculo de Concentrações de Sedimentos em Suspensão a partir de imagens dos satélites Landsat8/9 e Sentinel 2, e redes neurais artificiais.

O link de acesso ao código direto no GEE pode ser acessado aqui:
<https://code.earthengine.google.com/25c995a6e0f65382c71659a1c4249fcd>

APÊNDICE 3

Análise de consistência espectral entre as reflectâncias dos satélites Landsat 8/9 e Sentinel 2, para as bandas do visível e infravermelho próximo.



	Blue	Green	Red	NIR	SWIR
Slope	0.7039	0.8902	0.9328	0.9274	0.8236
Intercept	0.0033	0.0031	0.0023	0.007	-0.0012
R ²	0.81	0.97	0.98	0.77	0.87

Spectral consistency between Landsat 8/9 and Sentinel 2 before band adjustment					
RMSE	0.0103	0.0053	0.0042	0.0079	0.0046
MD	0.0085	0.004	0.0023	0.0039	0.0044
MAPE (%)	27.08	7.3	3.77	15.65	38.68

RMSE = root-mean-square error

MD = Absolute median difference

MAPE = mean absolute percentage error