

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOLOGIA
NÍVEL MESTRADO**

ANA CAROLINE RUPPENTHAL

**PREDIÇÃO DE BANDAS ESPECTRAIS E CLASSIFICAÇÃO DE IMAGENS DE
SATÉLITE PARA IDENTIFICAÇÃO E MAPEAMENTO DE ÁREAS ÚMIDAS: um
estudo de caso na Bacia Hidrográfica do Rio dos Sinos**

São Leopoldo, RS.

2021

ANA CAROLINE RUPPENTHAL

**PREDIÇÃO DE BANDAS ESPECTRAIS E CLASSIFICAÇÃO DE IMAGENS DE
SATÉLITE PARA IDENTIFICAÇÃO E MAPEAMENTO DE ÁREAS ÚMIDAS: um
estudo de caso na Bacia Hidrográfica do Rio dos Sinos**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Biologia, pelo Programa de Pós-Graduação em Biologia, da Universidade do Vale do Rio dos Sinos - UNISINOS

Orientador: Prof. Dr. Uwe Horst Schulz

Coorientador: Prof. Dr. Maurício Roberto Veronez

São Leopoldo, RS

2021

R946p Ruppenthal, Ana Caroline.
Predição de bandas espectrais e classificação de imagens de satélite para identificação e mapeamento de áreas úmidas : um estudo de caso na Bacia Hidrográfica do Rio dos Sinos / Ana Caroline Ruppenthal. – 2021.
132 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Biologia, 2021.
“Orientador: Prof. Dr. Uwe Horst Schulz
Coorientador: Prof. Dr. Maurício Roberto Veronez.”

1. Áreas úmidas. 2. Sensoriamento remoto. 3. Redes neurais artificiais. 4. Inteligência artificial. 5. Classificação supervisionada. I. Título.

CDU 573

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecária: Amanda Schuster – CRB 10/2517)

ANA CAROLINE RUPPENTHAL

**PREDIÇÃO DE BANDAS ESPECTRAIS E CLASSIFICAÇÃO DE IMAGENS DE
SATÉLITE PARA IDENTIFICAÇÃO E MAPEAMENTO DE ÁREAS ÚMIDAS: um
estudo de caso na Bacia Hidrográfica do Rio dos Sinos**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Biologia, pelo Programa de Pós-Graduação em Biologia, da Universidade do Vale do Rio dos Sinos - UNISINOS

Aprovado em 19 de agosto de 2021.

BANCA EXAMINADORA

Dr. Uwe Horst Schulz – Universidade do Vale do Rio dos Sinos (UNISINOS)

Dra. Eniuce Menezes de Souza – Universidade Estadual de Maringá (UEM)

Dr. Daniel Capella Zanotta – Universidade do Vale do Rio dos Sinos (UNISINOS)

AGRADECIMENTOS

Ao meu orientador Dr. Uwe Horst Schulz pela confiança em me escolher como integrante deste projeto. Serei eternamente grata pela oportunidade que me deste de estudar sobre esses ecossistemas fantásticos, além da oportunidade de vivenciar um projeto de planejamento ambiental para conservação de banhados.

Ao meu coorientador Dr. Maurício R. Veronez por ter aceitado a proposta deste trabalho e por ter me encorajado em todo o processo de aceite do mestrado, além de todo o auxílio científico e confiança no meu trabalho.

Aos financiadores e apoiadores deste estudo: Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos e ao Movimento Roessler pela bolsa de estudos em nível de pós-graduação; a Fundação Estadual de Proteção Ambiental Henrique Luiz Roessler (FEPAM); Promotoria de Justiça Regional da Bacia Hidrográfica do Rio dos Sinos e Secretaria do Meio Ambiente e Infraestrutura RS (SEMA) pelo apoio e discussões técnicas que enriqueceram o trabalho.

Aos professores do PPG Biologia Unisinos por todas as experiências compartilhadas em sala de aula.

Aos colegas do *Vizlab X-Reality and Geoinformatics Laboratory* que me auxiliaram do início ao fim na execução deste estudo. Agradeço especialmente à Tainá Tomassim por todas as horas desprendidas na execução da predição de bandas, em reuniões, pelo apoio e encorajamento nos momentos de frustração e medo, e por toda a sua paciência e companheirismo nesta trajetória. E ao Lucas Silveira Kupssinskü pela concepção da arquitetura da rede neural utilizada neste trabalho, assim como pela execução da rede e processamento dos resultados e o compartilhamento de conhecimento.

Aos colegas do Laboratório de Ecologia de Peixes, pela colaboração na execução do processamento das imagens de satélite, coleta de dados com VANT e auxílio em campo, especialmente à Amanda Letícia Bauer, Fernanda Gabriela da Silva e Marlon Ferraz da Rosa.

Às minhas amigas e amigos que me acompanharam nesta jornada, me dando suporte, apoio, incentivo, compreensão e dividiram todas as experiências vividas nestes dois anos. Agradeço especialmente à amiga e colega Caroline Brückmann pela amizade que construímos nestes dois anos, pelo incentivo, dedicação nas etapas do projeto e por todo carinho, dedicação e parceria ao longo desta trajetória.

Ao meu companheiro Alisson Borges, por seu apoio incondicional, seu suporte em todos os momentos de desânimo e por seu entusiasmo e alegria incentivando-me a continuar na caminhada final. Obrigada pelas palavras de conforto e energias positivas mesmo que de longe.

À minha família, que mesmo através da distância imposta em nossas vidas, sempre me apoiaram a buscar o meu melhor, incentivando sempre a valorizar o estudo e o crescimento pessoal e profissional em minha vida.

“O futuro dependerá daquilo que fazemos no presente”

Mahatma Gandhi

RESUMO

As Áreas Úmidas (AUs) são ecossistemas que possuem alta biodiversidade e produtividade, além de promoverem múltiplos serviços ecossistêmicos de importância global. No Rio Grande do Sul as AUs são conhecidas pelo termo local “banhados”. Estes ecossistemas, embora sejam amplamente reconhecidos, ainda são negligenciados e degradados. A Bacia Hidrográfica do Rio dos Sinos (BHRS) vêm sofrendo pressões antrópicas constantes que resultam na degradação das AUs devido, principalmente, ao aumento populacional que demanda áreas habitáveis. Neste contexto, é de extrema urgência a necessidade de elaborar estratégias de conservação das AUs na bacia hidrográfica. Por serem ecossistemas complexos devido as suas características de hidrologia, solo, vegetação e espectrais, o Sensoriamento Remoto (SR) se mostra como uma ferramenta eficiente na identificação e mapeamento das AUs, gerando subsídios para o poder público criar estratégias de proteção e fiscalização. Deste modo, esta dissertação teve como objetivos i) delimitar as AUs remanescentes da BHRS com uso de imagens centimétricas GeoEye-1 e SIG gratuito; ii) aferir as AUs com uso de Veículo Aéreo Não Tripulado (VANT); iii) propor um método para predizer bandas espectrais a partir de imagem RGB de resolução centimétrica por meio de Rede Neural Artificial (RNA), com o intuito de gerar uma imagem com alta resolução espacial e mais alta resolução espectral para posterior classificação de AUs; e iv) elaborar um guia de identificação de AUs da BHRS, com apresentação de um método de aferição dos indicadores de AUs em campo. Os resultados mostraram que o uso de imagens centimétricas eleva a precisão do mapeamento de AUs, sendo que uma área total de 93,11km² foi mapeada. A predição de bandas espectrais com uso de RNA foi capaz de gerar uma imagem com resolução espacial (2m) e espectral (RGB+NIR+RE 1,2,3,4 + SWIR 1 e 2). A imagem predita gerou uma melhor delimitação das AUs quando comparada a imagem bruta (RGB+NIR). Por fim, o Guia de Identificação de Banhados trouxe uma base científica e técnica para identificação das AUs em campo. Concluiu-se que os resultados deste trabalho servirão como subsídio para a complementação do planejamento ambiental da BHRS e a conservação das AUs remanescentes.

Palavras-chave: Áreas úmidas; Sensoriamento Remoto; Redes Neurais Artificiais; Inteligência Artificial; Classificação supervisionada.

ABSTRACT

Wetlands are ecosystems that have high biodiversity and productivity, in addition to promoting multiple ecosystem services of global importance. In Rio Grande do Sul, wetlands are known by the local term “banhados”. These ecosystems, although widely recognized, are still neglected and degraded. The Rio dos Sinos Hydrographic Basin (BHRS) has been suffering constant anthropogenic pressures that result in the degradation of wetlands, mainly due to the population increase that demands habitable areas. In this context, the need to develop conservation strategies for wetlands in the hydrographic basin is extremely urgent. As they are complex ecosystems due to their hydrology, soil, vegetation and spectral characteristics, Remote Sensing (SR) is an efficient tool in the identification and mapping of wetlands, generating subsidies for the public authorities to create protection and inspection strategies. Thus, this dissertation aimed to i) delimit the remaining wetlands of the BHRS using centimetric images GeoEye-1 and free GIS; ii) measure wetlands using an Unmanned Aerial Vehicle (UAV); iii) to propose a method to predict spectral bands from a centimeter-resolution RGB image by means of Artificial Neural Network (ANN), in order to generate an image with high spatial resolution and higher spectral resolution for subsequent classification of wetlands; and iv) prepare a guide for identifying BHRS wetlands, presenting a method for measuring wetland indicators in the field. The results showed that the use of centimetric images increases the accuracy of wetland mapping, with a total area of 93.11km² being mapped. The prediction of spectral bands using ANN was able to generate an image with spatial (2m) and spectral resolution (RGB+NIR+RE 1,2,3,4 + SWIR 1 and 2). The predicted image generated a better delimitation of wetlands when compared to the raw image (RGB+NIR). Finally, the Wetlands Identification Guide provided a scientific and technical basis for identifying wetlands in the field. It was concluded that the results of this work will serve as a subsidy to complement the environmental planning of the BHRS and the conservation of the remaining wetlands.

Key-words: Wetlands; Remote Sensing; Artificial Neural Networks; Artificial Intelligence; Supervised Classification.

SUMÁRIO

RESUMO	7
ABSTRACT	8
APRESENTAÇÃO	11
1 CAPÍTULO I – INTRODUÇÃO	12
1.1 OBJETIVO GERAL	17
1.1.1 Objetivos Específicos	17
1.2 JUSTIFICATIVA	18
2. CAPÍTULO II	27
Mapeamento e identificação de áreas úmidas na Bacia Hidrográfica do Rio dos Sinos	27
1 INTRODUÇÃO	29
2 MATERIAL E MÉTODOS	31
2.1 ÁREA DE ESTUDO.....	31
2.2 AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS.....	33
2.3 CLASSIFICAÇÃO SUPERVISIONADA DAS IMAGENS	35
2.4 CLASSIFICAÇÃO DE AUS E AFERIÇÃO DA ACURÁCIA DAS IMAGENS COM USO DE VANT	39
3 RESULTADOS E DISCUSSÃO	41
4 CONCLUSÕES	47
3. CAPÍTULO III	52
Predição de bandas espectrais a partir de técnicas de Inteligência Artificial para classificação de áreas úmidas: um estudo de caso na Bacia Hidrográfica do Rio dos Sinos	52
INTRODUÇÃO	54
MATERIAL E MÉTODOS	56
ÁREA DE ESTUDO.....	57
AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS.....	59
ARQUITETURA E CONFIGURAÇÕES DA RNA	60
Treinamento da RNA	62
Métodos de avaliação da RNA	63
CLASSIFICAÇÃO DAS IMAGENS.....	64
RESULTADOS	69

	10
PREDIÇÃO DE BANDAS ESPECTRAIS	69
CLASSIFICAÇÃO DAS IMAGENS.....	73
DISCUSSÃO	79
CONCLUSÕES	83
4. CAPÍTULO IV.....	88
Guia de Identificação de Banhados da Bacia Hidrográfica do Rio dos Sinos ...	88

APRESENTAÇÃO

A presente dissertação é composta por quatro capítulos, sendo o primeiro uma introdução geral sobre o trabalho realizado e formatado seguindo as normas da ABNT. O segundo capítulo está estruturado na forma de artigo científico, seguindo as normas do periódico “Land Use Policy”, com avaliação B1 no Qualis Capes para área de Biodiversidade. Neste capítulo são apresentados resultados sobre a identificação e delimitação das AUs remanescentes da BHRS com uso de imagens centimétricas do satélite GeoEye-1, com uso do método de classificação supervisionada Máxima Verossimilhança e uso de VANT. O artigo científico será submetido ao periódico supracitado após sua tradução para o inglês e a inclusão das considerações dos coautores e da banca examinadora.

O terceiro capítulo também está estruturado na forma de artigo científico, seguindo as normas do periódico “Plos One”, com avaliação A1 no Qualis Capes para a área de Biodiversidade. Esse capítulo é baseado na hipótese de que existe possibilidade de predizer bandas espectrais a partir de imagens RGB (bandas espectrais no vermelho (*red*), verde (*green*) e azul (*blue*)) de resolução centimétrica para auxiliar a classificação de AUs, utilizando ferramentas de Inteligência Artificial (IA), como RNAs. Nesta perspectiva, diante de todos os problemas ambientais atuais, se faz necessária a criação de uma metodologia que seja capaz de aprimorar a resolução espectral de imagens de satélite que não possuem informações em algumas regiões de interesse do espectro e também melhorar a resolução espacial de imagens de satélite que possuem as bandas de interesse, porém com baixa resolução. O artigo científico será submetido ao periódico supracitado após sua tradução para o inglês e a inclusão das considerações dos coautores e da banca examinadora.

O quarto capítulo apresenta um trabalho técnico, o qual foi publicado na data de 03 de março de 2021, pela Casa Leiria. Neste capítulo é apresentado o Guia de Identificação de Banhados da BHRS, o qual oferece uma referência científica para aferição dos indicadores de banhados em campo.

Por fim, informo que este trabalho teve a contribuição do Laboratório de Ecologia de Peixes e do *Vizlab X-Reality and Geoinformatics Laboratory*, do Movimento Roessler, do Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos – COMITESINOS, da Fundação Estadual de Proteção Ambiental Henrique Luiz

Roessler – FEPAM, da Secretaria do Meio Ambiente e Infraestrutura – RS e da Promotoria de Justiça Regional Ambiental da Bacia Hidrográfica do Rio dos Sinos.

1 CAPÍTULO I – INTRODUÇÃO

As AUs, reconhecidas internacionalmente pelo termo *wetlands*, são locais estratégicos de conservação por possuírem um papel ecológico crucial no meio ambiente. São responsáveis por uma grande quantidade de serviços ecossistêmicos, que vão desde o fornecimento de habitats, recarga de aquíferos, regulação de enchentes, regulação dos ciclos biogeoquímicos, controle do regime hídrico e do clima, entre outros. (JUNK et al., 2014; CUNHA; PIEDADE; JUNK, 2015; GALLANT, 2015; GOMES; JUNIOR, 2015; GARDNER; FINLAYSON, 2018). No sul do Brasil estes ecossistemas são conhecidos pelo termo *banhados*, sendo esta denominação oriunda do termo “*bañado*”, influência dos países vizinhos. (BURGER, 2010).

As funções ecológicas das AUs são determinadas por variáveis hidrológicas, climáticas, geomorfológicas, pedológicas, químicas e biológicas, sendo que a influência mútua entre estas variáveis, como a água, solo e vegetação, resulta em uma ampla diversidade de tipologias e características de AUs, assim como diferentes processos e funções. (GOMES; JÚNIOR, 2015; GALLANT, 2015; KANDUS et al, 2018).

Junk et al. (2013) definiram que as AUs são “ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanente ou periodicamente inundados ou com solos encharcados. As águas podem ser doces, salobras ou salgadas, com comunidades de plantas e animais adaptados à sua dinâmica hídrica”. Esta definição foi aprovada pelo Comitê Nacional de Zonas Úmidas - CNZU, por meio da Recomendação CNZU nº 7, de 11 de junho de 2015, visto que era necessário o Brasil possuir uma caracterização mais específica para as AUs do seu território. (MMA, 2018).

Diversas legislações buscam proteger a integridade das AUs, sendo que em âmbito nacional o Código Florestal, Lei 12.651/2012, em seu inciso XXV, determina que as AUs são “pantaneais e superfícies terrestres cobertas de forma periódica por águas, cobertas originalmente por florestas ou outras formas de vegetação adaptadas à inundações” (BRASIL, 2012). Em termos regionais, o Estado do Rio Grande do Sul, no seu mais novo Código Estadual do Meio Ambiente, sancionado pela lei 15.434/2020, em seu art. 2º, inciso XIII define que “banhados são ecossistemas

úmidos caracterizados por solos hidromórficos naturalmente alagados ou saturados de água de forma periódica, excluídas as situações efêmeras, onde se desenvolvem fauna e flora típicas, com características e peculiaridades definidas em regulamento”. (RIO GRANDE DO SUL, 2020).

Para Kandus et al. (2018) as AUs são consideradas ecossistemas únicos, com uma estrutura e funcionalidades distintas contrapondo o conceito clássico que define as AUs como uma transição entre os ecossistemas terrestres e aquáticos, ainda que, em alguns casos, possam representar transições, em sua maioria as AUs possuem sua própria identidade, como exemplo as turfeiras.

Mesmo havendo pleno reconhecimento da grande importância das AUs, ainda não existem mapeamentos detalhados sobre a extensão, estado de conservação e os tipos de AUs para os países da América do Sul, e muito menos um cronograma para o monitoramento das AUs ainda existentes. (KANDUS et al., 2018). Logo, na maioria das situações, as AUs acabam sendo negligenciadas. (RAMSAR, 2018; RAPINEL et al., 2019).

Atualmente, os poucos estudos que estimam a cobertura global das AUs realizam uma compilação de dados a partir de vários inventários regionais. Porém, com os avanços do Sensoriamento Remoto (SR) os inventários atuais apresentam maior confiabilidade em termos de mapeamento das AUs existentes. Se estima que a área global interior e costeira de AUs é superior a 12,1 milhões de km², sendo que destes 54% ficam inundados permanentemente e 46% inundados sazonalmente. Ademais, cerca de 93% são AUs de interior, com 7% sendo AUs marinhas e costeiras. (MAHDAVI et al., 2018; GARDNER; FINLAYSON, 2018).

Os eventos constantes de degradação e perda das AUs acabam resultando em eventos ambientais extremos e problemas sociais, sendo um resultado da má gestão da conservação desses ambientes somado as mudanças climáticas. (JUNK et al., 2015). Assim sendo, as AUs são ecossistemas prioritários para a conservação, pois contêm alta biodiversidade e oferecem diversos benefícios à sociedade, além de contribuírem para o equilíbrio ambiental. (ROLON; MALTCHIK, 2006).

O Brasil, por apresentar extensão continental, contém uma alta variedade de tipologias de AUs, sendo esta alta diversidade consequência da heterogeneidade ambiental e das grandes variações nas precipitações anuais, latitude, longitude e altitude. (JUNK et al., 2013). A falta de reconhecimento das AUs como importantes potenciais recursos hídricos disponíveis nas bacias hidrográficas, assim como pelos

inúmeros serviços ambientais e sociais que elas fornecem, poderá acarretar em complicações ambientais e sociais futuras pela degradação desses ricos ecossistemas. (JUNK et al., 2013).

Além disso, concomitante ao crescimento urbano, a demanda por áreas habitáveis aumenta, e isso envolve a tendência em invadir as AUs, descaracterizando-as e alterando sua funcionalidade ecológica. A integração destes ecossistemas no planejamento ambiental e urbanístico é uma pré-condição para sustentar o crescimento populacional e econômico. (THE RAMSAR CONVENTION SECRETARIAT, 2018).

A proteção e o manejo destas áreas se tornaram prioridade em muitas partes do mundo. (YAN et al., 2017). A preservação ambiental depende de recursos para o seu planejamento e a realização de planos de conservação para as AUs deve ocorrer concomitantemente com o inventário das mesmas. O inventário determina a quantidade, a extensão e a localização das AUs, criando assim subsídios para a geração de um plano ambiental e de monitoramento. (ROLON; MALTCHIK, 2006).

No contexto de formulação de políticas públicas para proteção e conservação das AUs, o SR é reconhecido como ferramenta importante para auxiliar na elaboração destas medidas e no monitoramento destes ecossistemas. O SR é considerado uma das tecnologias de coleta automatizada de dados para levantamento e monitoramento de recursos terrestres mais bem-sucedidos na atualidade. (MENESES; ALMEIDA, 2012).

De modo geral, o SR é definido como um conjunto de técnicas que permite a obtenção de informações dos objetos que compõem a superfície terrestre sem necessitar o contato direto com os mesmos. O SR se baseia em dados sobre a superfície terrestre, sendo estes obtidos através de sensores remotos, por exemplo os satélites, que captam a radiação eletromagnética (REM) refletida ou emitida pelos alvos. (NOVO; PANZZONI, 2001; MORAES, 2002; BAPTISTA, 2019).

O uso de SR possibilita conhecer e monitorar as AUs, superando as dificuldades de acessibilidade às áreas, mostrando ser uma tecnologia que torna acessível e menos custoso o processo de obtenção de dados quando comparado ao trabalho a campo, (KANDUS et al., 2018).

Os diversos satélites atuais fornecem imagens distintas, tornando-as aplicáveis em várias áreas do conhecimento. As imagens de satélite encontram-se bem difundidas em todos os meios, porém a aquisição de imagens com resoluções

centimétricas possuem um custo elevado, sendo muitas vezes inviável sua utilização. Além disso, é importante avaliar o nível de detalhamento necessário para detectar o fenômeno de interesse, lembrando novamente que o custo da aquisição destas imagens de alta resolução é elevado. (CRUZ; GALO, 2005).

Ainda no mesmo contexto, existe uma crescente demanda por mapeamentos e inventários que utilizem geotecnologias fazendo com que este ramo do SR se aprimore cada vez mais. Frente a essa demanda, aliada ao avanço tecnológico ocorrido nas últimas décadas, aumentou significativamente o uso de VANT's, que coletam imagens a nível de aeronaves. Os VANT's apresentam vantagens técnicas e econômicas, como excelência em imageamentos de pequenas áreas, possibilidade de altas taxas de visita e resolução espacial diferenciada. (FERREIRA et al., 2013). Com o advento da tecnologia dos VANT's, o SR teve sua precisão melhorada e aumentada, facilitando a aquisição da delimitação de corpos e água. (RUSNÁK et al., 2018).

Por apresentarem diversas funções e utilidades, às técnicas de SR e os Sistemas de Informações Geográficas (SIG) estão cada vez mais sendo valorizadas como ferramentas úteis para fornecer informações básicas em larga escala sobre as características da paisagem. (KAVYASHREE; RAMESH, 2016).

As técnicas de SR fornecem meios não invasivos com o objetivo de coletar, medir e monitorar informações sobre mudanças nos ecossistemas ao longo do tempo, tanto localmente quanto regionalmente. No âmbito do monitoramento de AUs, ainda que o SR não forneça informações iguais as medições em campo, a fusão de tecnologias de SR passivo e ativo pode fornecer dados extremamente úteis e eficazes. (CHASMER et al., 2020).

Dada a complexidade da análise e da identificação dessas AUs por imagens de satélite, além do uso do SR e imagens com altas resoluções, outras técnicas como as de IA vêm se mostrando eficientes na execução destes estudos. Nesse contexto, faz-se necessário conceituar a IA sendo definida como a capacidade de gerenciar novas situações, solucionar problemas, responder a questões e demais outras capacidades. (COPIN, 2013). Ainda, de acordo com Copin (2013, p.4), a "IA envolve utilizar métodos baseados no comportamento inteligente de humanos e outros animais para solucionar problemas complexos". Russell e Norvig (2013) elucidam as diferentes definições de IA divididas em quatro categorias de estudo, sendo elas: pensando

como um humano; pensando racionalmente; agindo como seres humanos; e agindo racionalmente.

As definições de IA ainda são ambíguas, e até o presente momento não se obteve um consenso sobre uma definição única e abrangente do que seria IA, visto ser uma ciência nova, sendo que sua estruturação e metodologia não estão tão bem desenvolvidas e consolidadas quando comparada a outras ciências mais antigas. (LUGER, 2013).

Dentro da grande área da IA, existe um segundo segmento denominado de Aprendizado de Máquina - AM (do inglês *Machine Learnig*), sendo este considerado um recurso dentro da IA, o qual tem como objetivo estudar e desenvolver métodos computacionais com o intuito de obter sistemas eficientes na busca pelo conhecimento de forma automatizada. (COPIN, 2010; RUSSELL; NORVIG, 2013; LIMA; PINHEIRO, OLIVEIRA, 2014).

Considerada uma terceira etapa dentro da abrangente ciência da IA, as Redes Neurais Artificiais (RNAs) são consideradas modelos de aprendizado conexionistas, e são principalmente utilizadas para criar sistemas de IA. (HAYKIN, 2001; LIMA; PINHEIRO; OLIVEIRA, 2014). Uma RNA é definida por dois aspectos básicos: arquitetura e aprendizado. O tipo, a quantidade de unidades de processamento e a forma de conexão dos neurônios está relacionado ao aspecto da arquitetura, enquanto o aspecto do aprendizado é referente às regras utilizadas para o ajuste das informações e os pesos que serão utilizados pela rede. (HAYKIN, 2001; LUGER, 2013; LIMA; PINHEIRO; OLIVEIRA, 2014). De acordo com Medeiros (2018) as RNAs têm como objetivo principal o desenvolvimento de um sistema que opere de forma similar ao dos seres humanos, ou seja, semelhante ao cérebro humano.

As RNAs são um mecanismo de AM e foram criadas baseadas na estrutura e no funcionamento do sistema nervoso humano, tendo como objetivo principal simular a capacidade de aprendizado do cérebro humano na aquisição de conhecimento através de máquinas. Uma RNA é projetada para modelar a maneira como o cérebro realiza uma tarefa ou função de interesse. As RNAs realizam a construção de modelos matemáticos que simulam as atividades do cérebro, descrevendo as funções mentais por meio da eletroquímica das células cerebrais (os neurônios). As redes são compostas de nós ou unidades, que se conectam por ligações direcionadas. (HAYKIN, 2001; SILVA et al., 2019).

Logo, uma RNA é determinada por dois aspectos básicos: arquitetura e aprendizado, sendo a arquitetura relacionada com o tipo, o número de neurônios e a forma como eles estão interligados, e o aprendizado relacionado as regras utilizadas para ajustar os pesos da RNA e a informação que é usada por essas regras. (COPPIN, 2013; CARVALHO et al., 2011).

Apesar da RNA ser uma ferramenta promissora, para que a RNA forneça resultados satisfatórios, além de uma arquitetura adequada, o processo de treinamento e validação deve ser efetuado com qualidade. Deve-se fornecer para a rede dados representativos, onde a determinação destes valores deve ser efetuada de modo a propiciar uma rede que forneça bons resultados sem que haja um esforço computacional excessivo. (FLECK et al. 2016).

A utilização de abordagens de IA, como o uso de RNAs, são tidas como abordagens promissoras no campo de SR, pois se baseiam em outras técnicas que podem aprimorar os resultados. O propósito das RNAs é de que elas sejam capazes de aprender e tomar decisões baseadas na aprendizagem, obtendo o conhecimento através da experiência, ou seja, aprendendo, errando e fazendo novas descobertas. Utilizar as RNAs para solucionar problemas tem sido cada vez mais atrativo, justamente por esta capacidade de aprender através de exemplos generalizar a informação aprendida na rede. (BRAGA; CARVALHO; LUDERMIR, 2000).

A partir deste contexto, o qual envolve a preocupação da crescente perda das AUs e os impactos futuros oriundos desta destruição, se faz urgente a criação de subsídios para a identificação e mapeamento destes ecossistemas para elaboração de políticas de conservação e fiscalização das AUs.

1.1 OBJETIVO GERAL

O objetivo principal deste trabalho é identificar e delimitar as AUs na Bacia Hidrográfica do Rio dos Sinos – BHRS.

1.1.1 Objetivos Específicos

Com o intuito de atingir o objetivo principal, foram estabelecidos os seguintes objetivos específicos:

- i) Identificar e delimitar as AUs remanescentes da BHRS com uso de imagens centimétricas do satélite GeoEye-1 através de SIG gratuito;
- ii) Aferir em campo os resultados do mapeamento com uso de VANT;
- iii) Propor um método para prever bandas espectrais a partir de imagem RGB de resolução centimétrica por meio de RNA, com o intuito de gerar uma imagem com alta resolução espacial e mais alta resolução espectral para posterior classificação de AUs em um determinado perímetro da BHRS;
- iv) Elaborar um guia de identificação de AUs da BHRS, com apresentação de um método de aferição dos indicadores de AUs em campo.

1.2 JUSTIFICATIVA

Os banhados (como são chamadas as AUs na Região Sul do Brasil), sempre foram vistos pela sociedade como áreas improdutivas, as quais necessitassem serem drenadas e aterradas, configurando assim um outro tipo de uso do solo para aquele ecossistema. (BURGER, 2010). Após longos anos de degradação e conversão destas áreas para outros usos, atualmente, existe uma enorme urgência em prestar mais atenção aos inventários das AUs e análises das mudanças nas AUs, visto que a conversão e perda destes ecossistemas naturais, entre os séculos 20 e 21, resultaram na diminuição de 64 a 71% das AUs presentes em 1900, sendo esta perda ocorrendo a uma taxa muito mais rápida (3,7 vezes) do que anteriormente. (DAVIDSON; FINLAYSON, 2007).

As legislações vigentes acabam sendo embasadas em terminologias regionais, que muitas vezes não incluem todas as classes de AUs de uma região, deixando lacunas em aberto, resultando em embasamentos para sua descaracterização e degradação. (ROLON; MALTCHIK, 2006). As AUs são Áreas de Preservação Permanente (APPs), desta forma, são protegidas por lei. Porém a maior ameaça para as AUs brasileiras é a falta de uma exata definição se uma determinada área é ou não uma AU, ou seja, uma legislação específica que traga uma definição clara, objetiva e que regule a proteção destes ecossistemas. (CUNHA, PIEDADE E JUNK, 2015).

Muitas das AUs mapeadas e estudadas são de grande extensão, a exemplo dos Sítios Ramsar, os quais são AUs integrantes da Lista Ramsar consideradas Unidades de Conservação, caracterizadas por possuírem grandes extensões de

perímetros. (MMA,2018). Porém, nota-se que AUs de menores extensões não são mapeadas, o que pode estar relacionado a diferentes fatores como suas características singulares regionais, influenciadas por fatores físicos, biológicos e climatológicos, dentre outros. Por serem negligenciadas, não são mapeadas e georreferenciadas, e grande parte destas áreas existentes nos perímetros dos municípios poderão desaparecer. (BERTOLUCI, 2004).

O Rio dos Sinos, rio principal da BHRS, é de grande importância principalmente para os setores industriais da região, produção agrícola, pesca artesanal, além de servir como fonte de abastecimento para a população desta região. (FEPAM, 2021). A região do Sinos foi a primeira a criar um Comitê para o gerenciamento da BHRS, tendo como objetivo principal, norteador “garantir água em quantidade e qualidade para todos os usos humanos e a sobrevivência dos demais seres vivos da região, preservando e recuperando seus habitats naturais”. (COMITESINOS, 2014).

De acordo com Figueiredo (2010) os principais impactos ambientais na BHRS são a exploração excessiva de água, poluição do solo, ar e recursos hídricos, contaminação dos recursos hídricos por efluentes domésticos, efluentes líquidos industriais e redução da fauna e flora nativas. Nesta lista extensa destaca-se a falta do tratamento de esgoto doméstico, visto que de 30 municípios da bacia apenas São Leopoldo mantém estações de tratamento do esgoto. Os problemas e situações são recorrentes na BHRS, sendo que a segurança hídrica da bacia está colocada em risco, justamente por falta de planejamento da ocupação do solo e preservação das áreas cruciais para a manutenção desta segurança hídrica. (ANSCHAU, 2016). Além disso, o gerenciamento e manejo dos recursos hídricos concentra seus esforços na maioria do território brasileiro no uso sustentável de rios, lagos e recursos hídricos subterrâneos, para os mais variados fins, como domésticos, industriais, irrigação, navegação, produção de energia e para tratamento de esgotos. (CUNHA; PIEDADE; JUNK, 2015).

Em meio a esta problemática, o uso das geotecnologias vem se tornando uma forma estratégica na busca por planejamento ambiental que auxilie na preservação destes ecossistemas, além de apresentar um embasamento técnico e científico. Sabe-se que imagens de satélite que contenham mais bandas espectrais proporcionam uma discriminação dos alvos com uma qualidade superior do que imagens que possuam menos bandas espectrais, pode-se usar como exemplo uma imagem com as bandas

RGB, a qual oferece uma capacidade de discriminação superior às imagens em nível de cinza. (KWAN et al., 2017).

Outrossim, métodos que realizem a combinação de imagens com características espectrais e espaciais distintas, justamente com o intuito de gerar uma nova imagem com melhor resolução espacial e espectral do que a imagem original, acabam proporcionando desta forma um melhor aproveitamento da imagem e melhor extração de informações necessárias. (LEONARDI; ORTIZ; FONSECA, 2005).

Segundo Han, Shi e Zheng (2018) os sensores existentes fornecem uma resolução espacial baixa, o que dificulta a análise por parte de programas computacionais sobre os alvos a serem estudados nas imagens, sendo então a fusão das imagens hiperespectrais de baixa resolução e multiespectrais de alta resolução uma alternativa para se obter uma imagem hiperespectral de alta resolução, sendo esta uma forma para a extração de alta informação espacial e espectral.

Neste contexto, a utilização de métodos que aliem o SR a técnicas inovadoras de IA podem gerar resultados necessários para o embasamento científico ao planejamento territorial e ambiental das cidades, neste caso no mapeamento das AUs da BHRS. A utilização destas ferramentas de forma estratégica na busca pela formulação de políticas públicas que privilegiam a conservação destes ecossistemas, para que se alcance a segurança hídrica são de extrema relevância no contexto ambiental em que a sociedade se encontra atualmente.

REFERÊNCIAS

- ANSCHAU, C. **Atlas do Projeto Verdesinos**. Editora Anschau, Porto Alegre, p. 116, 2016.
- BAPTISTA, Gustavo Macedo de Mello. **Sensoriamento remoto hiperespectral**. 2.ed. Rio de Janeiro: Interciência, 2019. Livro eletrônico.
- BERTOLUCI, Vilma Daniela Mânica. **Inventário, biodiversidade e conservação de áreas úmidas do município de São Leopoldo**. 2004. 70 f. Dissertação (Mestrado) - Curso de Biologia, Universidade do Vale do Rio dos Sinos, São Leopoldo, 2004.
- BRAGA, Antônio de Pádua; CARVALHO, André Ponce de Leon F. de; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, p.262, 2000. Livro eletrônico.
- BRASIL. **Decreto nº 1.905, de 16 de maio de 1996**. Promulga a Convenção sobre Zonas Úmidas de Importância Internacional, especialmente como Habitat de Aves Aquáticas, conhecida como Convenção de Ramsar, de 02 de fevereiro de 1971. Ramsar, IRÃ, Disponível em: <http://www.planalto.gov.br/ccivil_03/decreto/1996/D1905.htm>. Acesso em: 08 set. 2019.
- BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória no 2.166-67, de 24 de agosto de 2001; e dá outras providências. Brasília, DISTRITO FEDERAL, Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12651.htm>. Acesso em: 08 nov. 2018.
- BURGER, Maria Inês. **Situação e ações prioritárias para a conservação de banhados e áreas úmidas da zona costeira**. 2010. Disponível em:

<http://rodadas.anp.gov.br/arquivos/Round7/arquivos_r7/SISMICA_R7/refere/Bohados.pdf> Acesso em: 02 out. 2019.

CARVALHO, André et al. Inteligência Artificial—uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**, p. 45, 2011.

CHASMER, Laura, et al. Remote Sensing of Boreal Wetlands 1: Data Use for Policy and Management. **Remote Sensing**, v.12, n.8, p.1320. 2020.

Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos (COMITESINOS). **Plano Sinos – Plano de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos-meta 3**. Consórcio Pró-Sinos [2014]. Disponível em: <<http://www.prosinos.rs.gov.br/downloads/Meta%203%20-%20Ativ.%203.3%20-%20Situa%C3%A7%C3%A3o%20Rec.%20H%C3%ADdricos.pdf>> Acesso em: 20 mai. 2020.

COPPIN, Bem. **Inteligência artificial**. Rio de Janeiro: LTC, 2013. Livro eletrônico.

CRUZ, N. C.; GALO, M. L. B. T. Mapeamento das infestações por plantas aquáticas em reservatórios utilizando imagens multiescala e redes neurais artificiais. **RBC – Revista 70 Brasileira de Cartografia**, n. 57/02, 2005. Disponível em: <<http://www.rbc.lsie.unb.br/index.php/rbc/article/viewFile/138/121>>. Acesso em: 13 out. 2019.

CUNHA, Catia Nunes; PIEDADE, Maria Teresa Fernandez; JUNK, Wolfgang. 2015. Classificação e Delineamento das Áreas Úmidas Brasileiras e de seus Macrohabitats. **Instituto Nacional de Ciência e Tecnologia em Áreas Úmidas – INAU**. Cuiabá, 2015. EdUFMT. Disponível em: <<http://www.cppantanal.org.br/2018/index.php/2017-11-25-10-48-10/2018-03-31-15-56-14/item/254-classificacao-e-delineamento-das-areas-umidas-brasileiras-e-de-seus-macrohabitats>>. Acesso em: 21 nov. 2020.

DAVIDSON, Nick C.; FINLAYSON, Max C. Earth Observation for wetland inventory, assessment and monitoring. **Aquatic Conservation Marine and Freshwater Ecosystems**, v.17, n.3, p.219 – 228, 2007.

FERREIRA, A. M. R.; ROIG, H. L.; MAROTTA, G. S.; MENEZES, P. H. B. J.

Utilização de aeronaves remotamente pilotadas para extração de mosaico georreferenciado multiespectral e modelo digital de elevação de altíssima resolução espacial. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR**. Foz do Iguaçu: INPE, 2013. p. 9308-9315. Disponível em: < <http://marte2.sid.inpe.br/col/dpi.inpe.br/marte2/2013/05.29.00.37.47/doc/p1264.pdf>>. Acesso em: 28.nov.2020.

FIGUEIREDO, J. A. S. et al. The Rio dos Sinos watershed: an economic and social space and its interface with environmental status. **Brazilian Journal of Biology**, v. 70, n. 4, p. 1131-1136, 2010.

FLECK, Leandro et al. REDES NEURAIS ARTIFICIAIS: PRINCÍPIOS BÁSICOS ARTIFICIAL. **Revista Eletrônica Científica Inovação e Tecnologia**, Medianeira, Paraná, v. 1, n. 13, p.47-57, jan. 2016.

Fundação Estadual de Proteção Ambiental Henrique Luiz Roessler – RS (FEPAM). Qualidade Ambiental - Região Hidrográfica Do Guaíba. [2021?]. Disponível em:< <http://www.fepam.rs.gov.br/qualidade/guaiba.asp>> Acesso em 15 mar.2021.

GALLANT, Alisa L. The challenges of remote monitoring of wetlands. **Remote Sensing**, v.7, n.8, p. 10938-10950, 2015.

GARDNER, Royal C.; FINLAYSON, C. Global wetland outlook: state of the World's wetlands and their services to people. In: **Ramsar Convention Secretariat**. 2018.

GOMES, Cecília S.; JÚNIOR, Antônio P. M. Áreas úmidas (wetlands): panorama e desafios teórico-conceituais. **XXI Simpósio Brasileiro de Recursos Hídricos**. Brasília. 2015.

HAYKIN, Simon. **Redes Neurais: Princípios e práticas**. 2. ed. São Paulo: Artmed Editora S.a., 2001. 908 p. Livro eletrônico.

HAN, X.; SHI, B.; ZHENG, Y. SSF-CNN: Spatial and Spectral Fusion with CNN for Hyperspectral Image Super-Resolution. **IEEE International Conference on Image Processing (ICIP)**, p. 2506-2510, 2018.

JUNK, Wolfgang. J. et al. Brazilian wetlands: their definition, delineation, and classification for research, sustainable management, and protection. **Aquatic Conservation: Marine and Freshwater Ecosystems**, [s.l.], v. 24, n. 1, p.5-22, 2013.

JUNK, Wolfgang Johannes. et al. Brazilian wetlands: their definition, delineation, and classification for research, sustainable management, and protection. **Aquatic Conservation: Marine and Freshwater Ecosystems**, v. 24, n. 1, p. 5-22, 2014.

JUNK, W.J., et al. Definição e Classificação das Áreas Úmidas (AUs) Brasileiras: Base Científica para uma Nova Política de Proteção e Manejo Sustentável. In: Cunha, C.N., Piedade, M.T.F., Junk, W.J. (Org.). **Classificação e Delineamento das Áreas Úmidas Brasileiras e de seus Macrohabitats**. 1ed. Cuiabá: INCT-INAU – Ed UFMT, p. 13-76, 2015.

KANDUS, Patricia, et al. Remote sensing of wetlands in South America: status and challenges. **International Journal of Remote Sensing**, v.39, n.4, p. 993–1016, 2018.

KAVYASHREE, M. P.; RAMESH, H. Wetland mapping and change detection using remote sensing and GIS. **International Journal of Engineering Science**, v. 2356, 2016.

KWAN, Chiman et al. Blind quality assessment of fused worldview-3 images by using the combinations of pansharpening and hypersharpening paradigms. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 10, p. 1835–1839, 2017.

LEONARDI, Silva Shizue; ORTIZ, Jussara de Oliveira; FONSECA, Leila Maria Garcia. **Comparação de técnicas de fusão de imagens para diferentes sensores**

orbitais. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 4111-4113

LIMA, Isaías; PINHEIRO, Carlos A. M.; OLIVEIRA, Flávia. S. **Inteligência artificial**. São Paulo: Elsevier Brasil, 2014.

LUGER, George F. **Inteligência artificial**. 6 ed. São Paulo: Pearson Education do Brasil, 2013. Livro eletrônico.

MAHDAVI, Sahel et al. Remote sensing for wetland classification: A comprehensive review. **GIScience & Remote Sensing**, v. 55, n. 5, p. 623-658, 2018.

MEDEIROS, Luciano Frontino de. **Inteligência artificial aplicada: uma abordagem introdutória**. Curitiba: InterSaberes, 2018. Livro eletrônico.

MENESES, Paulo Roberto; ALMEIDA, Tati de (Org.). **Introdução ao processamento de imagens de Sensoriamento Remoto**. Brasília - DF: Unb, 2012. 266 p.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Áreas Úmidas - Convenção de Ramsar**. 2018. Disponível em: <<http://www.mma.gov.br/biodiversidade/biodiversidade-aquatica/zonas-umidas-convencao-de-ramsar>>. Acesso em: 08 nov. 2019.

MORAES, E. C. **Fundamentos de Sensoriamento Remoto**. Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 2002. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf>. Acesso em: 20 fev. 2021.

NOVO, Evlyn M.L. de M.; PONZONI, Flávio J. **Introdução ao sensoriamento remoto**. 2001.

RAMSAR, Ramsar Convention on Wetlands. **Global Wetland Outlook: State of the World's Wetlands and their Services to People**. Gland, Switzerland: Ramsar

Convention Secretariat, 2018. Disponível em: <<https://www.global-wetland-outlook.ramsar.org/outlook>> Acesso em: 24 fev. 2021.

RAPINEL, Sebastien, et al. Mapping potential, existing and efficient wetlands using free remote sensing data. **Journal of Environmental Management**, v. 247, p. 829–839, 2019.

RIO GRANDE DO SUL. **Código Estadual do Meio Ambiente. Lei nº 15.434, de 10 de janeiro de 2020**. Disponível em: <http://www.al.rs.gov.br/Legis/M010/M0100099.ASP?Hid_Tipo=TEXT0&Hid_TodasNormas=65984&hTexto=&Hid_IDNorma=65984>. Acesso em: 25 mai. 2020.

ROLON, Ana Silvia. MALTCHIK, Leonardo. Áreas palustres: classificar para proteger. **Ciência hoje**, v.38, n 228, 2006.

RUSSEL, Stuart; NORVIG, Peter. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2013. Livro eletrônico.

RUSNÁK, Miloš et al. Modelo para mapeamento de paisagem de rio em alta resolução usando tecnologia UAV. **Medição**, v. 115, p. 139-151, 2018.

THE RAMSAR CONVENTION SECRETARIAT (Switzerland). **World Wetlands Day, 2 February: Urban wetlands: prized land, not wasteland**. 2018. Disponível em: <<http://www.worldwetlandsday.org/>>. Acesso em: 03 out. 2019.

YAN, Fengqin et al. China's wetland databases based on remote sensing technology. **Chinese Geographical Science**, v. 27, n. 3, p.374-388, 2017.

2. CAPÍTULO II

Mapeamento e identificação de áreas úmidas na Bacia Hidrográfica do Rio dos Sinos

(Manuscrito nas normas da revista "Land Use Policy")

MAPEAMENTO E IDENTIFICAÇÃO DE ÁREAS ÚMIDAS NA BACIA HIDROGRÁFICA DO RIO DOS SINOS

Ana Caroline Ruppenthal¹

¹ Universidade do Vale do Rio dos Sinos-UNISINOS
Laboratório de Ecologia de Peixes-LEP
Av. Unisinos, 950, São Leopoldo, RS / CEP 93022-750
ana.c.ruppenthal@gmail.com

RESUMO

Apesar da importância ecológica e social das Áreas Úmidas (AUs) serem amplamente reconhecidas pela comunidade científica, poder público e sociedade, as AUs ainda são ecossistemas extremamente negligenciados e degradados. Conforme a crescente expansão urbana, que demanda áreas habitáveis, e as mudanças climáticas que alteram a dinâmica das AUs, estes ecossistemas estão cada vez mais degradados. A Bacia Hidrográfica do Rio dos Sinos (BHRS) vêm sofrendo ao longo das décadas com a perda de AUs ao longo do Rio dos Sinos causada justamente pela expansão urbana e falta de planejamento ambiental e urbano. Diante deste cenário, é de extrema urgência a necessidade de elaborar estudos para embasar estratégias de conservação e gerenciamento das AUs. Neste sentido, o Sensoriamento Remoto (SR) se mostra como uma ferramenta eficiente na geração de mapeamentos com a localização e a situação das AUs remanescentes. O objetivo deste trabalho foi mapear as AUs remanescentes da BHRS, a partir de imagens de satélite de resolução centimétrica, empregando o uso de Sistema de Informação Geográfica (SIG) gratuito. Em ambiente SIG, utilizando-se o Quantum GIS (QGIS), foram gerados quadrantes das cinco imagens de satélite GeoEye-1 (0,5m de resolução) para posterior classificação semiautomática com o uso do plugin *Semi-Automatic Classification Plugin* (SCP). Além disso, cinco AUs integrantes do polígono mapeado foram aferidas com o uso de um Veículo Aéreo Não Tripulado (VANT). O polígono total das AUs foi gerado de forma manual a partir dos resultados das classificações semiautomáticas de cada imagem. Um total de 350 feições foram mapeadas, sendo que o polígono total do mapeamento das AUs da BHRS resultou em uma área de 9.311,15ha. A utilização de imagens de alta resolução somado ao método de classificação supervisionada das imagens resultou em um mapeamento com alta precisão. Conseqüentemente, conferiu ao método manual de delimitação dos polígonos uma

exatidão maior. Além disso a técnicas de identificação dos limites das AUs com uso de VANT revelou-se promissora. O mapeamento proporcionará aos municípios integrantes da área de estudo, uma base técnica para a elaboração de um planejamento ambiental estratégico visando a proteção das AUs remanescentes.

Palavras-chave: Áreas úmidas; Sensoriamento Remoto; Inventários; Planejamento Ambiental e Urbano.

1 INTRODUÇÃO

As áreas úmidas (AUs), conhecidas pelo termo “banhados” no Rio Grande do Sul, são ecossistemas que fornecem uma série de benefícios ao meio ambiente e à sociedade. Dentre estes serviços ecossistêmicos destacam-se a purificação da água, regulação de enchentes, promoção da recarga de águas subterrâneas, regulação da mudança climática global através de sequestro e liberação de carbono, servem como habitat para diversas espécies de animais e vegetais e também proporcionam benefícios culturais para a sociedade (Millenium Ecosystem Assessment, 2005; Rolon; Maltchik, 2006; Junk et al., 2015).

Embora a importância ecológica e as contribuições das AUs para o bem-estar humano sejam amplamente reconhecidas pela comunidade científica, poder público e sociedade em geral, muitas vezes estas AUs acabam sendo negligenciadas. Logo, a conservação destes ecossistemas tem sido subestimada, principalmente quando partes de setores interessados adotam decisões, com base em interesses individuais e de curto prazo, e assim acabam causando mais perda de AUs (Ramsar, 2018; Rapinel et al., 2019).

Com uma grande extensão territorial, o Brasil possui uma alta variedade de tipos de AUs. Esta diversidade é consequência da heterogeneidade ambiental e das grandes variações nas precipitações anuais, latitude, longitude e altitude, criando um mosaico de diferentes tipos de AUs (Junk et al., 2013).

Em relação a precipitação, a sua distribuição sazonal na maior parte do território brasileiro confere aos grandes rios uma forte oscilação do nível de água, entre a época de cheia e da seca, causando um fenômeno conhecido como “pulso de inundação” (Junk et al., 2015). Neste cenário, as AUs que se estendem as margens destes rios, são alimentadas pelas águas nos períodos de cheia. A maior parte das AUs dos trópicos e subtropicais, pertence à classe de AUs de pulso de inundação,

sendo que esta classe inclui mais de 90% das AUs existentes no Brasil (Junk et al., 2015). Ao analisar as AUs da BHRS, a sua maioria integra a planície de inundação do Rio dos Sinos, sendo alimentadas por estes eventos de cheia.

Diante de um cenário de constante degradação e perda das AUs, a ocorrência de eventos climáticos extremos e problemas sociais tendem a aumentar, sendo um resultado da má gestão da conservação das AUs somado as mudanças climáticas. (JUNK et al., 2015). As AUs são ecossistemas prioritários para a conservação, justamente por apresentar alta biodiversidade e oferecer diversos benefícios à sociedade, além de contribuírem para o equilíbrio ambiental (Rolon; Maltchik, 2006).

Além de registros de lançamento de efluentes domésticos e industriais que prejudicam ainda mais as condições ambientais das águas (Kieling-Rubio et al., 2015) e ocupação e uso agrícola, principalmente pelas ocupações de grandes propriedades destinadas ao cultivo de arroz sobre as AUs dessa região (Kieling-Rubio et al., 2015).

Com os objetivos voltados para a preservação e conservação da BHRS, o Comitê de Gerenciamento da BHRS (Comitesinos) propôs em 2014 o Primeiro Plano de Recursos Hídricos da BHRS. O documento traz um programa de gestão de áreas protegidas e ações de preservação e conservação, onde em uma das ações destaca o objetivo de identificação, recuperação, conservação e manutenção de banhados, nascentes e áreas de recarga de aquíferos (Comitesinos, 2014).

Conforme Dvoretz et al. (2011), os programas de monitoramento baseados em avaliações das regiões podem ajudar a limitar e reduzir a degradação atual e futura das AUs e dedicar os esforços na restauração destes ambientes. Os inventários, servem para delimitar áreas prioritárias para a preservação e a criação de um zoneamento ambiental e urbanístico que busque proteger estes ricos ambientes. São considerados projetos ambientais que auxiliam justamente na criação de um zoneamento ambiental específico para o município, em conjunto com outros ecossistemas que visem sua preservação (Kurtz; Rocha; Kurtz, 2001).

No contexto de formulação de políticas públicas de proteção e conservação das AUs, o sensoriamento remoto (SR) é reconhecido como ferramenta importante para auxiliar na elaboração destas medidas e no monitoramento destes ecossistemas. O SR é considerado uma das tecnologias de coleta automatizada de dados para levantamento e monitoramento de recursos terrestres mais bem-sucedidos na atualidade (Meneses; Almeida, 2012). Antunes et al. (2014) elucidam que hoje em dia existe uma maior demanda e acessibilidade às imagens orbitais de média e alta

resolução, tornando possível a criação de técnicas e métodos novos voltados à análise que transcenda o nível de pixel.

O uso de SR possibilita conhecer e monitorar os ecossistemas de AUs, superando as dificuldades de acessibilidade às áreas. O SR se mostra uma tecnologia que torna acessível e menos custoso o processo de obtenção de dados quando comparado o trabalho de campo, além de fornecer informações sobre uma ampla gama de escalas temporais (Kandus et al., 2018).

Frente aos trabalhos que apontam para a redução drástica e significativa das AUs da região, as técnicas de SR propõem um refinamento no estudo e levantamento dessas áreas, bem como auxiliam na acurácia dos polígonos gerados. É imperioso a identificação e delimitação das AUs remanescentes junto ao planejamento urbano, bem como, apoiar medidas que visem a efetivação das leis que protegem essas áreas, assegurando o crescimento econômico e populacional mais sustentável (The Ramsar Convention Secretariat, 2018).

Nesse sentido, o objetivo geral deste trabalho foi delimitar e mapear as AUs remanescentes da BHRS, a partir de imagens de satélite de resolução centimétrica, empregando o uso de SIG gratuito, gerando subsídios para fiscalização e planejamento ambiental destes ecossistemas.

2 MATERIAL E MÉTODOS

2.1 ÁREA DE ESTUDO

Este estudo se localizou na planície de inundação da BHRS. A BHRS se situa na região leste do Estado do Rio Grande do Sul e localiza-se na Região Hidrográfica do Guaíba. O corpo hídrico principal da bacia é o Rio dos Sinos, o qual possui uma extensão aproximada de 190 km, sendo que toda a BHRS possui uma área de 3.820 km². Sua nascente está situada no município de Caraá, a uma altitude aproximada de 600m. Sua foz encontra-se no Delta do Jacuí, onde irá se juntar às águas do Guaíba (Anschau, 2016; Comitesinos, 2019).

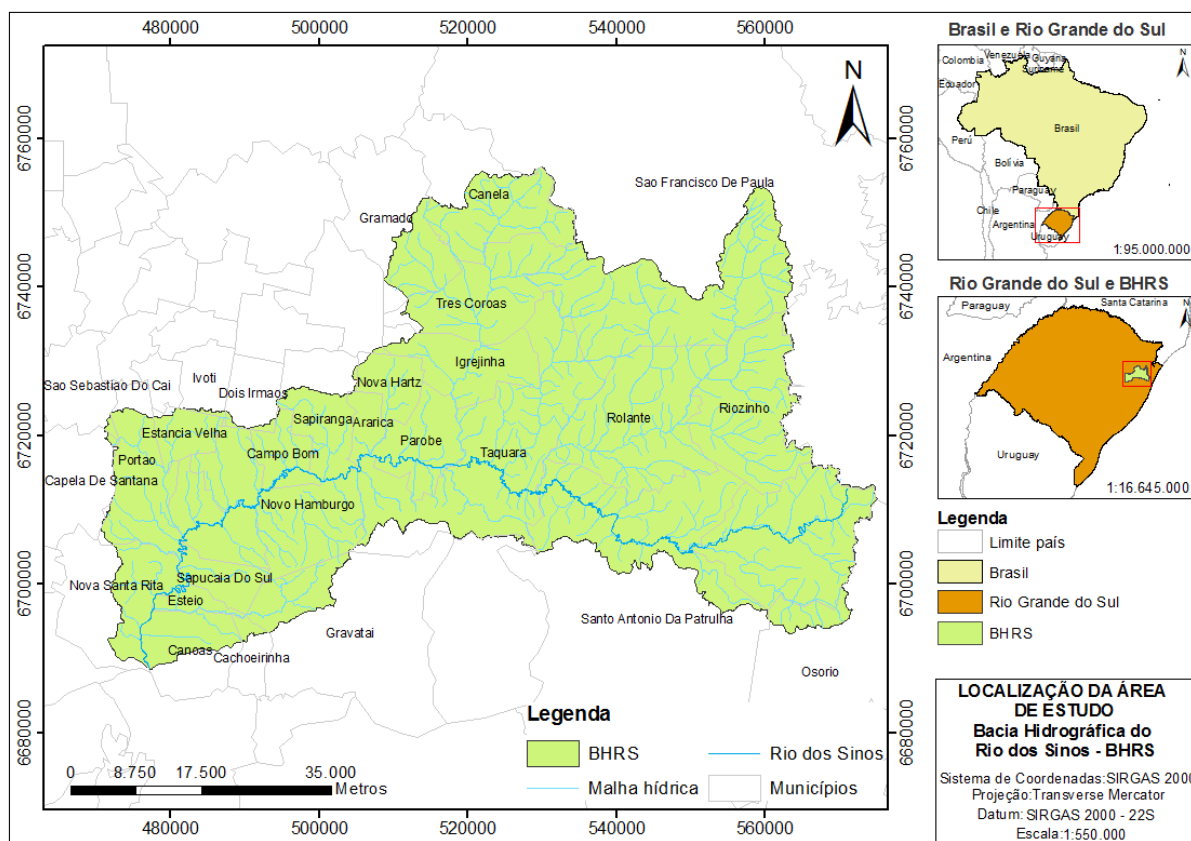


Fig. 1. Localização da Bacia Hidrográfica do Rio dos Sinos - BHRS

No contexto de região fitogeográfica, a BHRS situa-se dentro do Bioma Mata Atlântica e o seu fluxo segue em direção ao Bioma Pampa, o qual se situa na região fitogeográfica da Floresta Estacional Semidecidual. A BHRS possui clima predominantemente subtropical e precipitação anual média de 1.600 mm por ano, bem distribuídos nas quatro estações, e temperaturas que variam em torno de 20 graus. (Moura, 2016; Comitesinos, 2019).

A área de estudo propriamente dita se concentrou em um polígono de 606km² (Fig. 2) pré-determinado. Para a composição do polígono foram utilizadas cinco imagens de satélite GeoEye-1, datados do período de 2017.

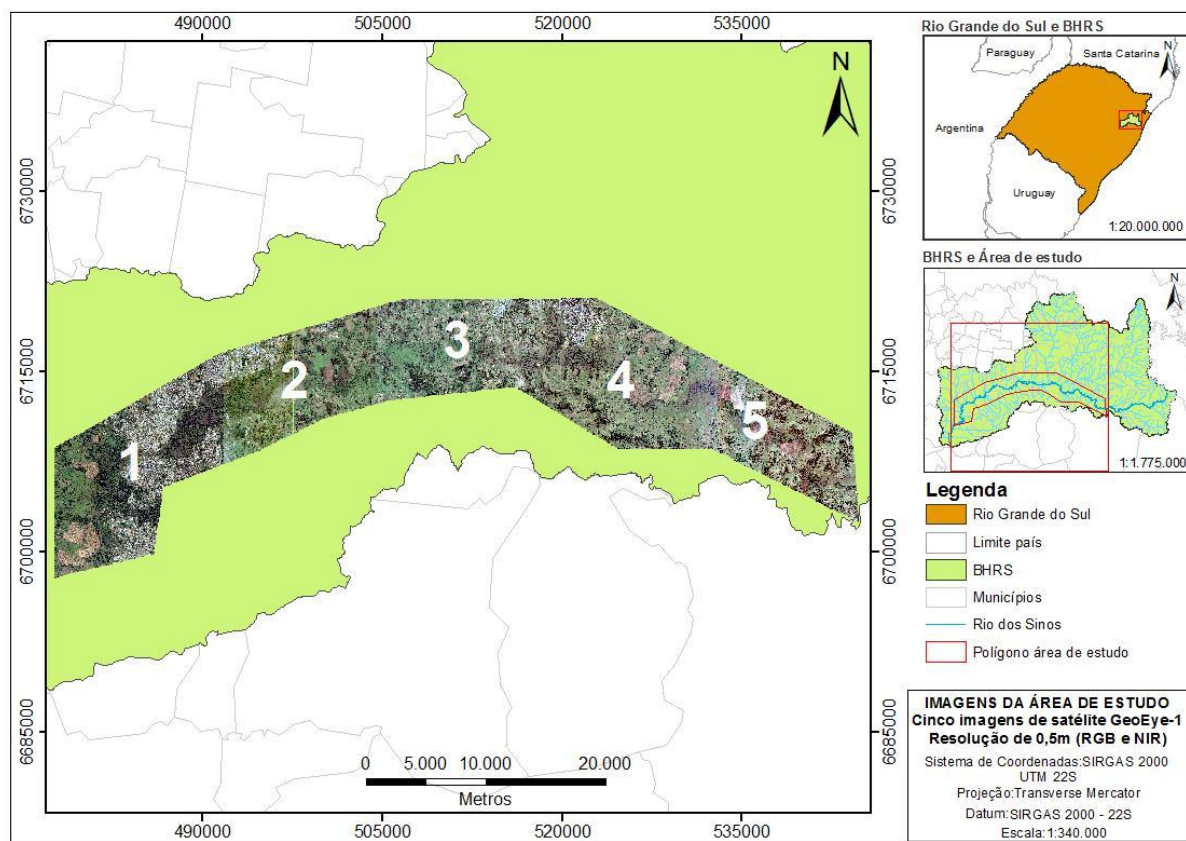


Fig. 2. Polígono da área do projeto de mapeamento das AUs da BHRs – contempla o uso de cinco imagens de satélite de alta resolução espacial

2.2 AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS

As cinco imagens de satélite de alta resolução espacial foram adquiridas da empresa Globalgeo, pelo COMITESINOS, datadas do ano de 2017. As mesmas são provenientes do satélite GeoEye-1, sendo que os produtos oriundos do satélite são referência em termos de imagens de alta resolução. Ela possui resolução espacial de 0,5m e bandas do tipo Pancromático P&B e Multiespectrais no Azul, Verde, Vermelho (RGB) e NIR (Engesat, 2019). As imagens foram entregues pré-processadas, ortoretificadas, mosaicadas e realçadas, em formato GeoTIFF - 8 bits, projeção UTM e projeção SIRGAS 2000. Importante ressaltar que não existe a informação de quais parâmetros foram utilizados para o pré-processamento das cinco imagens de satélite.

Antes de iniciar o processo de mapeamento das AUs, foi estabelecido previamente a área de inundação do trecho do Rio dos Sinos a ser mapeado. Com os dados da Agência Nacional das Águas (ANA, 2019) foi calculada a quota máxima da

cheia do rio no ano de 2013, ano da maior vazão do Rio dos Sinos no período delimitado.

Para demarcar em mapa a extensão da área de inundação utilizou-se o *software* livre Quantum Gis (Qgis), e imagens Landsat-8 disponíveis pelo Instituto Nacional de Pesquisas Espaciais. (INPE, 2019), datadas do período de 2013. Desta forma, foi possível obter um polígono com a extensão máxima de alagamento do Rio dos Sinos baseado na cheia de 2013 (Fig. 3), que correspondeu a 665,953m³. (ANA, 2019).

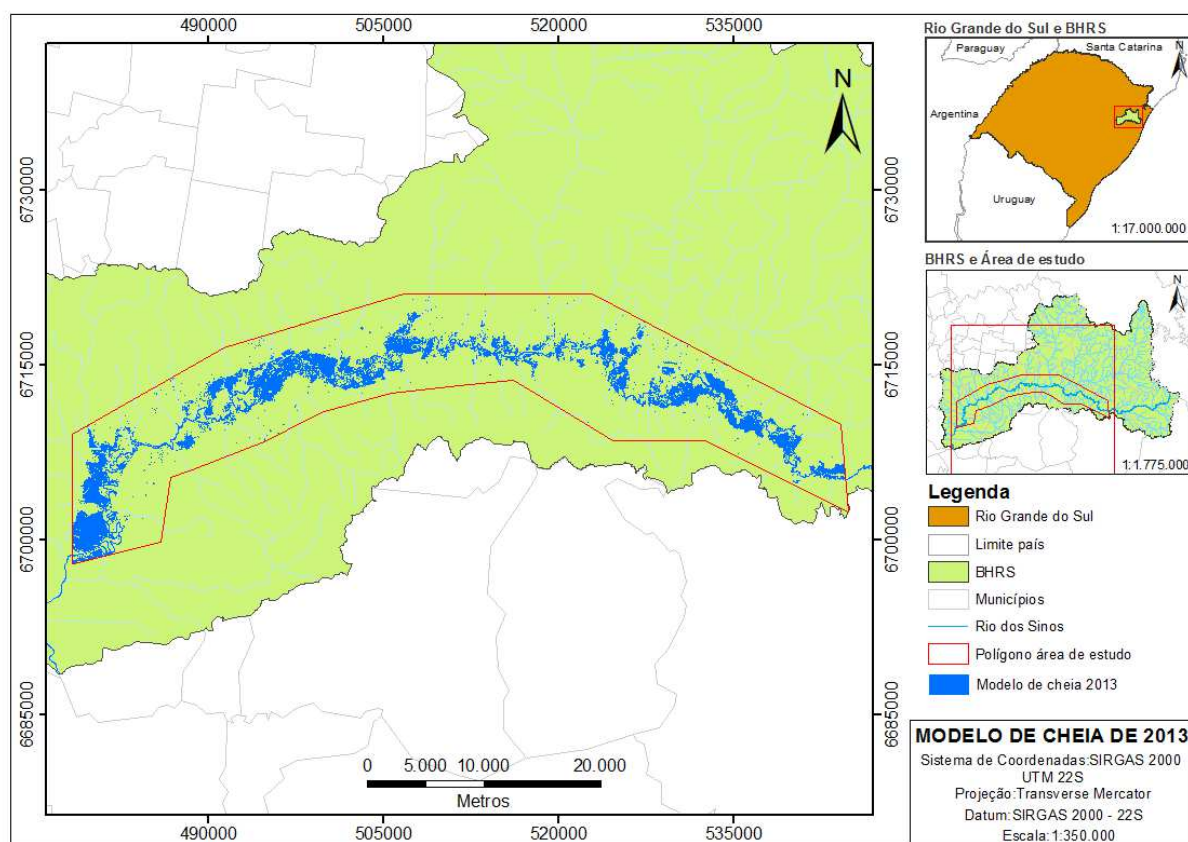


Fig. 3. Polígono da área de estudo (em vermelho) e o modelo de vazão do rio (em azul) com base nos dados obtidos pela ANA

Finalizada esta etapa, realizou-se a inserção de uma grade de 1km x 1km para fracionar as cinco imagens de satélite com resolução centimétrica em múltiplos quadrantes. A resolução espacial centimétrica resulta em imagens pesadas para o processamento de uma cena inteira (por exemplo, a imagem nº 1 que possui 1,72GB e quando fracionada cada quadrante possui um tamanho de 30,5MB). Além disso, a capacidade de processamento das máquinas disponíveis não era compatível com o tamanho das imagens inteiras. Sendo assim, o fracionamento das imagens resultou

em 317 quadrantes (Tabela 1) e possibilitou o processamento das imagens em menor tempo.

Imagem de satélite	Nº quadrantes
Img.1	34
Img.2	68
Img.3	66
Img.4	94
Img.5	55

Tabela 1. Quantidade de quadrantes (1km x 1km) gerados pelo fracionamento das cinco imagens de satélite GeoEye-1, resultando em um total de 317 quadrantes

2.3 CLASSIFICAÇÃO SUPERVISIONADA DAS IMAGENS

Para a elaboração de uma identificação e mapeamento de AUs existentes, o SR e SIG são considerados fontes poderosas e indispensáveis para gerar medidas multitemporais e espaciais da área estudadas (Bansal; Katyal; Garg, 2017). Para a extração de informações contidas nas imagens, são necessários métodos de análises com regras claras e lógicas, para que possam ser replicadas por qualquer analista na interpretação dos dados. Essas regras impõem critérios para a análise dos alvos que compõem a paisagem da imagem, sendo utilizadas as propriedades de cor, tonalidade, textura, estrutura, sombras e formas, específicas de cada alvo (Meneses; Almeida, 2012).

Para este trabalho foi escolhida a classificação supervisionada, pois com este método a imagem é classificada com base nos critérios e parâmetros definidos pelo analista, o qual deve ter conhecimento dos aspectos da área de trabalho. Ainda assim, a definição dos polígonos representativos serve como base para a classificação, visto que estes polígonos contêm uma quantidade significativa de pixels, cuja reflectância representa uma feição previamente determinada (Fitz, 2008).

A classificação inicial para a geração do perímetro das AUs da BHRS foi realizada no *software* livre Qgis, utilizando a metodologia de classificação supervisionada de imagens, sendo esta gerada a partir do complemento do Qgis conhecido como SCP (*Semi-Automatic Classification Plugin*). A ferramenta possibilita

a classificação pixel a pixel, de forma semiautomática ou supervisionada de imagens de satélites (Fig. 4).


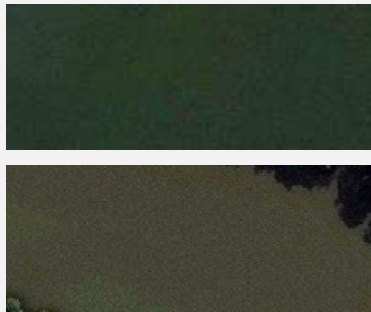



Fig. 4. Etapas da classificação supervisionada das imagens. A) Imagem coloração verdadeira; B) Imagem após ajuste da reflectância de superfície das bandas RGB 421 (falsa cor); C) Resultado da classificação; D) e) Seleção das classes de interesse (água e charco); f) Polígono das AUs

A escolha das classes foi baseada na observação dos diversos alvos que compõe o ortofotomosaico recortado. A definição das amostras para geração do treinamento e posterior classificação supervisionada foi realizada através de observação exemplificada na tabela de classes de interpretação (Tabela 2). A coleta de amostras para o treinamento levou em consideração o conhecimento prévio do usuário/analista, sendo a coleta das amostras executada de forma manual, e a composição RGB “falsa-cor” (composição 4-2-1) que auxilia na definição das classes pois apresenta cores diferentes da combinação das cores do visível. Na combinação de “falsa-cor” os objetos da imagem têm suas características espectrais realçadas, sendo que a água apresenta tons próximos do azul, o solo e as áreas urbanas apresentam tons azul-esverdeados. A vegetação apresenta coloração avermelhada, sendo utilizada para identificar diferentes tipos de vegetais (Fitz, 2008).

A classificação supervisionada com uso do complemento SCP permite a classificação através do fornecimento de amostras de pixels que representam significativamente cada classe determinada. As amostras de pixels são delimitadas por polígonos denominadas por “*Region of Interest*” (ROI). Para a criação do treinamento da classificação, foram escolhidas e delimitadas 50 amostras representativas de cada classe. Foram estipuladas seis classes, sendo elas: 1) água; 2) urbano; 3) campo; 4) solo; 5) mata e 6) charco. Cabe ressaltar que as demais classes apresentadas na tabela de classes de interpretação auxiliaram no processo de delimitação usual do polígono das AUs da BHRS, visto que este processo de delimitação manual levou em consideração o reconhecimento do analista, o qual toma decisão da marcação baseada nas classes de interpretação (Tabela 2). As áreas de cultivo de arroz, mesmo sendo consideradas AUs artificiais, não foram definidas como uma classe específica neste estudo, não sendo classificadas como AUs, tendo em vista que foram delimitadas apenas as AUs naturais remanescentes. As áreas de cultivo de arroz estão abrangidas na classe “Campo”.

Classe	Imagem Geoeye (0,5m) Escala: 1:1000	Definição	Chave de interpretação
<i>Água</i>		Água aparente	Cor: preto, marrom e azul Textura: lisa Tom: escuro Estrutura: lisa/homogênea
<i>Urbano</i>		Área urbana com construções (telhados cinza claro e escuros e telhados de cerâmica marrom)	Cor: cinza claro e escuro e tons de marrom Textura: lisa Tom: claro Estrutura: geometria retangular e quadrada





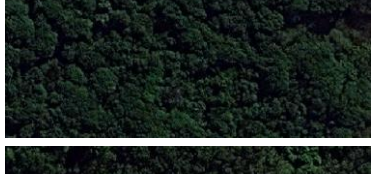

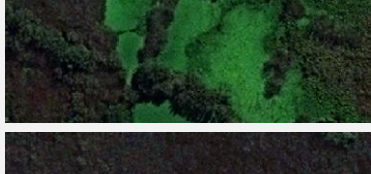

Campo		Plantação agrícola ou pastagens	Cor: verde claro Textura: lisa Tom: claro Estrutura: retangular homogênea
			
Solo		Solo exposto (mineração, solo pós colheita de culturas agrícolas, etc)	Cor: marrom Textura: granulado orientado Tom: claro ao escuro Estrutura: geometria retangular a irregular.
			
Mata		Vegetação densa	Cor: verde Textura: rugosa Tom: médio a escuro Estrutura: irregular com tamanhos variáveis
			
Charco		AUs com presença de vegetação superficial característica – macrófita OU Predominância de vegetação mais seca – sem lâmina da água aparente	Cor: Verde e marrom Textura: granuloso heterogêneo Tom: claro ao escuro Estrutura: irregular com tamanhos variáveis
			

Tabela 2. Chave de interpretação das classes
Fonte: Adaptado de Moraes (2018).

Além disso, o SCP executa a classificação de acordo com o algoritmo classificador definido, sendo que o complemento possui três classificadores disponíveis: *Maximum Likelihood* (ML), *Minimum Distance* (MD) e *Spectral Angle Mapper* (SAM). Para realização deste trabalho foi utilizado o algoritmo ML, um dos métodos de classificação mais utilizados para imagens de SR. (FITZ, 2008). O algoritmo ML utiliza a média e a covariância dos pixels amostrados, sendo calculada

a probabilidade de um pixel externo a essas amostras pertencer a elas (FITZ, 2008; LIU, 2015).

Salienta-se ainda que após a classificação supervisionada e seleção das classes de interesse (água e charco) o polígono final foi realizado através do método usual, sendo que o polígono de AUs final foi gerado de acordo com a experiência do usuário/analista visualmente orientado e de acordo com o resultado da classificação supervisionada previamente. Neste método foram levados em consideração a experiência e o conhecimento do usuário/analista visualmente orientado para determinação dos polígonos das AUs.

A acurácia da classificação gerada foi realizada através de verificação *in loco* (campos) nas áreas mapeadas. Os pontos para a realização dos campos foram definidos de acordo com os resultados das classificações das imagens, sendo escolhidos pontos em que foram identificados como banhados (positivos) e não banhados (negativos). Durante a verificação a campo, foi efetuada uma documentação fotográfica da situação atual.

2.4 CLASSIFICAÇÃO DE AUs E AFERIÇÃO DA ACURÁCIA DAS IMAGENS COM USO DE VANT

Para aferição das AUs mapeadas foram utilizados voos de veículo aéreo não tripulado (VANT), popularmente conhecido por drone. A primeira etapa se deu com a definição dos locais/polígonos de AUs, ambos classificados na etapa anterior com as imagens de satélite GeoEye-1 de alta resolução espacial (0,5m/px), para definir a área de voo (Fig. 5).

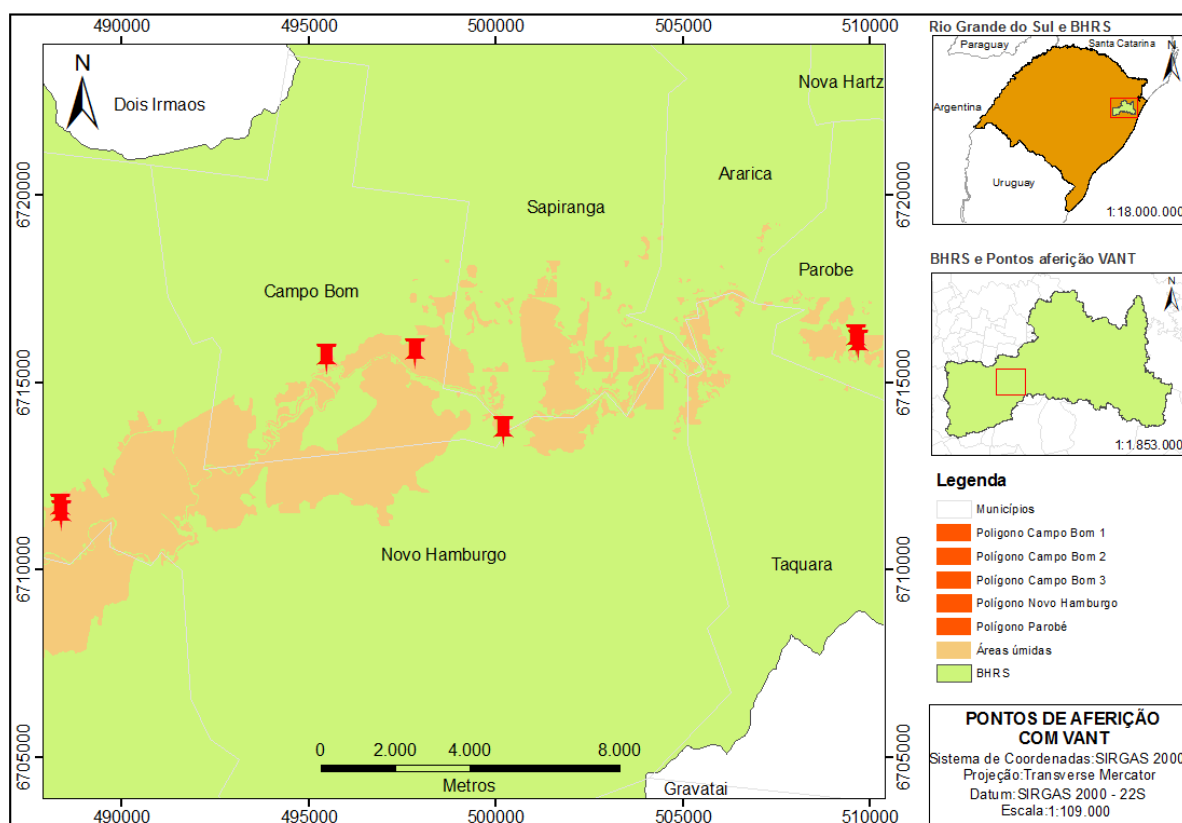


Fig. 5. Locais de amostragens para identificação de AUs, a partir de técnicas de captura de imagens por VANT

Foram escolhidas as cinco áreas para aferição com VANT apresentados no mapa da Figura 5 devido a logística para acesso as áreas, tendo em visto que nos mesmos locais/AUs foram realizadas as análises dos indicadores físicos de AUs, conforme metodologia de aferição apresentada no Guia de Identificação da Banhados da BHRs (Schulz et al. 2021).

A aquisição dos dados foi realizada com uso do VANT DJI Mavic Pro. Os sobrevoos foram realizados nos dias 19 de junho, 24 de julho e 07 de agosto de 2020. A câmera acoplada no VANT possui sensor 1/2.3", lente FOV 78.8° 26 mm. Para o planejamento do voo, foi utilizado o aplicativo DroneDeploy, sendo que o polígono escolhido foi importado e gerado o plano de voo (Rees, 2015). O pós-processamento, aerotriangulação e mosaicagem foi executada com o auxílio do software Agisoft Photoscan Pro 1.0.4.

Em campo, o processo de posicionamento do VANT teve início com a sua elevação à altitude de 80m com o aplicativo DJGO e a câmera em posicionada 90° para ficar em posição perpendicular ao solo, com o mesmo aplicativo foram ajustados

o foco e a exposição manualmente para obter a melhor imagem possível da AU. Posteriormente, a aeronave foi pousada e antes de iniciar o voo foram fixados 3 pontos de ancoragem para coletar as coordenadas geográficas e a altitude para corrigir durante o processamento. Por fim, foi iniciado o voo planejado no aplicativo DroneDeploy, indicando que o foco foi manualmente ajustado, desta forma, cancelando a exposição e foco automático do set up do aplicativo DroneDeploy. As imagens do voo foram realizadas com uma sobreposição frontal de 75% e lateral de 70% entre as imagens capturas de maneira consecutiva (Mazzoleni et al., 2020). As imagens capturadas mostraram a resolução de 0,06m/px.

Para a etapa posterior de processamento das imagens geradas pelo VANT, as imagens foram importadas para o Agisoft Photoscan para serem processadas. Ao serem importadas as imagens foram primeiramente alinhadas e tiveram os seus pontos de ancoragem corrigidos. Após este procedimento, iniciou-se a criação do modelo para determinação dos limites das AUs. Com as imagens importadas foi criado uma nuvem de pontos densa (Dense Cloud), utilizando o resultado da nuvem de pontos densa foi criado a malha, a textura e modelo digital de elevação (DEM). O resultado do modelo foi a criação do ortomosaico das imagens do VANT (Rahman et al., 2019).

O ortomosaico foi importado para o software QGIS 3.10, onde a imagem foi classificada utilizando o plugin SCP. Após a imagem ser classificada, o raster foi poligonizado para determinar o limite das AUs sobrevoadas (Cameron And Madumere, 2019; Rusnák et al., 2018).

3 RESULTADOS E DISCUSSÃO

Atualmente, a definição de áreas protegidas ainda é uma das principais estratégias na busca pela proteção da biodiversidade. Porém, as áreas protegidas representam apenas 14,6% da superfície terrestre, sendo que esta porcentagem está localizada em regiões específicas, não representando o globo em sua totalidade. A implementação de áreas protegidas garante a preservação de áreas determinadas que contenham alta biodiversidade, porém a biodiversidade não se limita apenas a essas áreas, ficando assim vulneráveis as pressões antrópicas (Buchart et al., 2015; Maltchick; Stenert; Batzer, 2017).

Neste contexto de áreas protegidas, no Brasil as AUs de grandes extensões de área integram listas de preservação internacional, como a lista Ramsar, pois são

reconhecidas por apresentarem critérios e parâmetros nacionais e internacionais. Mas quando analisadas a partir de um contexto municipal, que em sua maioria são AUs de extensões menores, as mesmas costumam ser negligenciadas, não sendo mapeadas e monitoradas. Diante desta situação, grande parte destas áreas existentes nos perímetros dos municípios poderão desaparecer (Bertoluci, 2004).

Por serem os ecossistemas mais ameaçados atualmente, a geração de inventários da situação atual e um sistema de monitoramento das AUs é de extrema importância e possibilita a aquisição de informações acerca do funcionamento das AUs, os fatores ambientais relacionados e as consequências da mudança climática nestas áreas (Gallant, 2015).

Frente a esse cenário e avaliando o desenvolvimento urbano dos municípios brasileiros, é urgente a necessidade da adoção de medidas de manejo e conservação das AUs. Porém, antes de mais nada, é necessária a realização de levantamentos desses ecossistemas e a obtenção de conhecimento prévio dos mesmos, possibilitando compreender as causas que resultam na perda de AUs. Também, a avaliação da eficácia das políticas públicas para proteção de AUs necessita de estudos que demonstrem a extensão das AUs existentes, assim como uma base para a análise dos padrões de distribuição das AUs e as alterações nas suas extensões ao longo do tempo (Mahdavi et al., 2018).

Um inventário de AUs mede a extensão das áreas, enquanto o monitoramento de AUs rastreia as mudanças no inventário ao longo do tempo. Neste sentido, a realização de inventários com o uso de dados de SR fornece uma estrutura espacial e estatística com acurácias expressivas. O processamento digital de imagem auxilia na caracterização de uma ampla gama de classes, formas e tipos de ecossistemas de AUs, destacando-se em áreas de difícil acesso, sendo que estas metodologias podem ser replicadas e executadas de forma temporal, trazendo dados com maiores informações sobre a dinâmica desses ecossistemas (Chasmer et al., 2020).

O presente estudo identificou um total de 350 feições nas cinco imagens de satélite centimétricas utilizadas. O mapeamento resultou em polígono com área total de 93,11km² de AUs remanescentes na BHRS. O mapa da Figura 6 apresenta o polígono total de AUs mapeadas (polígono vermelho). Esta área total mapeada compreende os municípios de Esteio, Nova Santa Rita, Sapucaia do Sul, Portão, São Leopoldo, Novo Hamburgo, Campo Bom, Sapiranga, Araricá, Parobé, Taquara e Santo Antônio da Patrulha. O resultado final foi compilado em um arquivo do tipo vetor

(*shapefile*), sendo que o mesmo foi entregue ao Comitê Sinos para divulgação técnica, em formato de mapa e em arquivo do tipo vetor (Fig. 6). Cabe ressaltar que o polígono da área total de AUs é um dos objetivos e metas principais do projeto junto ao Comitê Sinos.

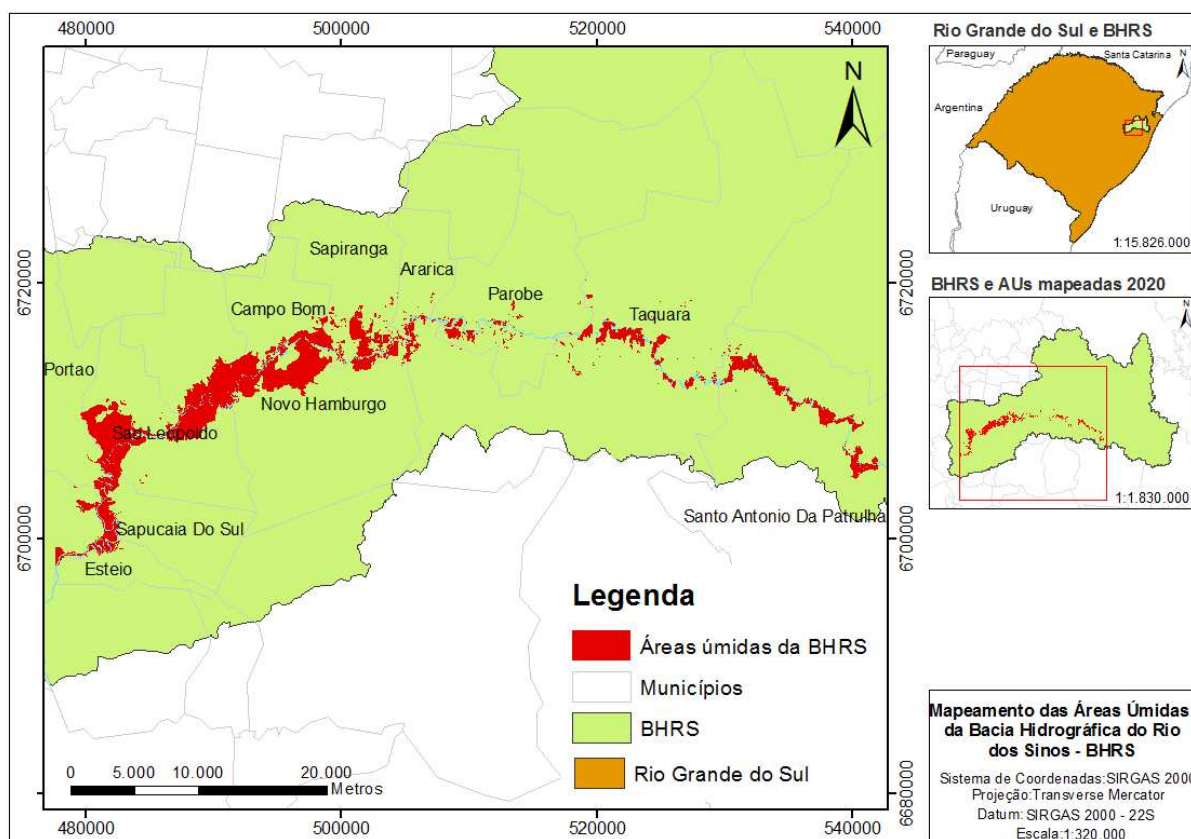


Fig. 6. Mapa final do mapeamento das AUs da BHRS – polígono total

Os resultados apresentados indicam que ainda resta uma significativa área de AUs na BHRS (93,11km²). O fator resolução espacial das imagens tem um impacto direto na acurácia da classificação da imagem, demonstrando que o uso de imagens de alta resolução espacial acarreta uma melhor classificação dos alvos, desta forma resultando em um inventário de AUs com maior precisão.

A BHRS é dividida em três grandes compartimentos, em que se destacam condições relativamente homogêneas de relevo e uso do solo (Comitesinos, 2014). As três divisões são caracterizadas de acordo com as altitudes encontradas no relevo, sendo divididas em Alto Sinos (altitudes acima de 900m), Médio Sinos (altitudes até 900m) e Baixo Sinos (altitudes até 200m, sendo a maioria do relevo abaixo de 50m). Neste contexto, a distribuição das AUs na bacia hidrográfica se apresenta de forma distinta, levando em consideração o relevo e a planície de inundação.

Conforme análise da distribuição da AUs na BHRS (Fig. 7), foi possível observar que as maiores concentrações de AUs encontram-se nas altitudes mais baixas do relevo da bacia, justamente onde se localiza a planície de inundação, sendo identificada uma concentração de $\sim 52\text{km}^2$ de AUs na porção do Médio Sinos, seguida de uma concentração de $\sim 40\text{km}^2$ de AUs na porção do Baixo Sinos. A menor concentração de AUs ocorre na porção do Alto Sinos, sendo apenas identificadas $\sim 2\text{km}^2$ de AUs da área total mapeada.

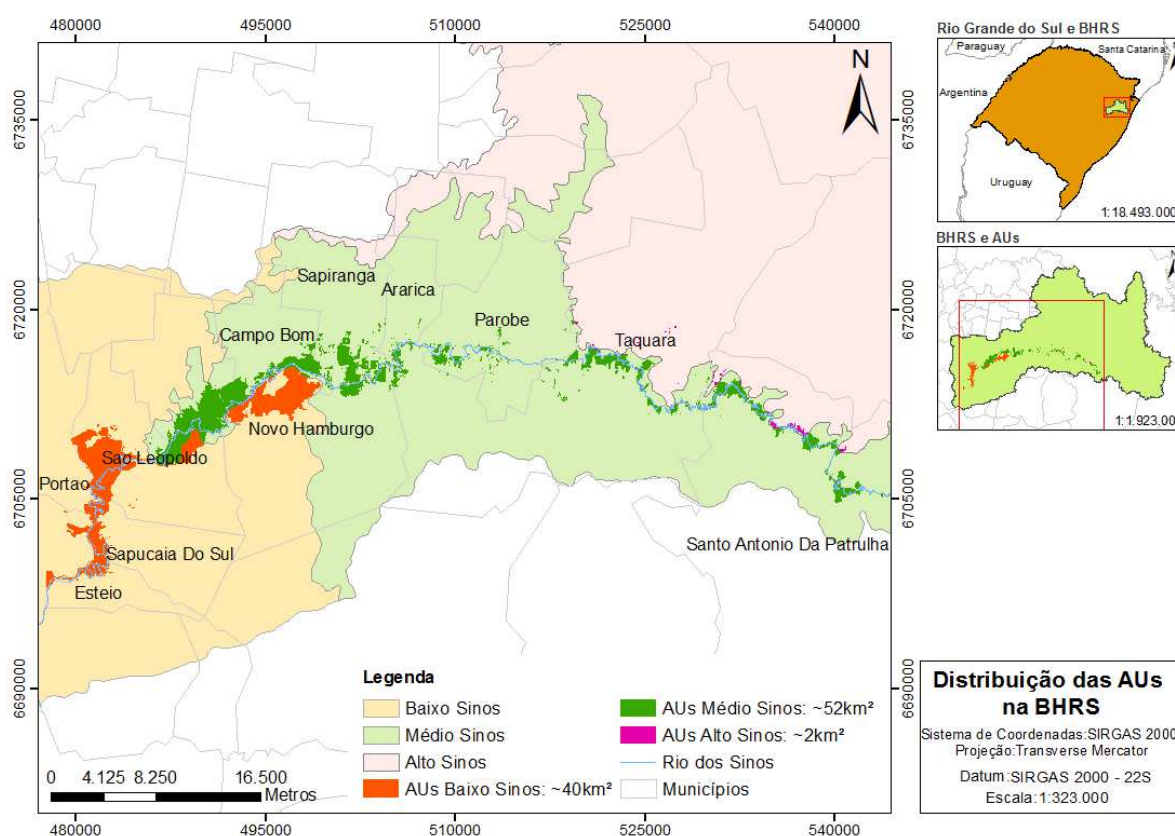


Fig. 7. Distribuição das AUs mapeadas de acordo com as porções da BHRS

Acerca dos tamanhos das AUs mapeadas, foram identificadas áreas de pequena escala, que não possuem nem $0,05\text{ha}$ de área, assim como áreas de maior extensão, alcançando $\sim 1,4\text{ha}$ de área. Esta análise também demonstra a heterogeneidade da bacia hidrográfica, quanto ao quesito de altitudes.

Quanto a execução da etapa de aferição de AUs com uso de VANT, foram aferidas um total de cinco AUs dentro da área total de estudo (Fig. 8). Todas as áreas aferidas com uso do VANT encontravam-se dentro do perímetro previamente mapeado. Quando sobrepostos os polígonos, pode-se verificar que as AUs das imagens D e E apresentaram um maior refinamento em seu polígono de AU mapeada

com o VANT. Uma das possíveis explicações para o ocorrido é o fato que as AUs sofrem influência direta com os eventos de precipitações, existindo a possibilidade de a lâmina da água possuir maior extensão. Além disso, a resolução do VANT é superior a resolução espacial das imagens de satélites utilizadas, possibilitando um refinamento na identificação destas áreas. Já na AU da imagem B, é importante ressaltar que a semelhança elevada em ambos os métodos de classificação resultou em polígonos quase idênticos.

Por este motivo, o uso de VANT é promissor pois o equipamento e a metodologia possibilitam aferir a AU, definindo os seus limites com uma alta precisão, analisando áreas de forma individualizada.

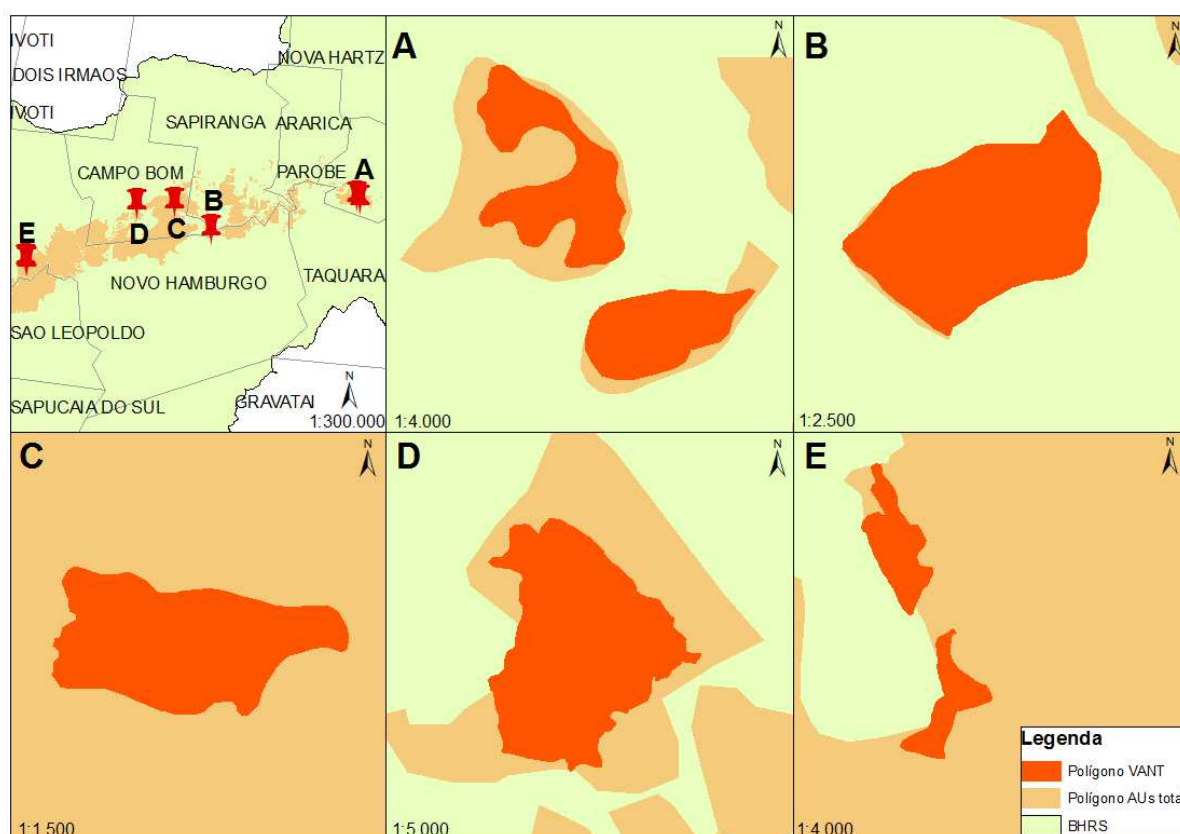


Fig. 8. Pontos de amostragens para identificação de AUs, a partir de técnicas de captura de imagens por VANT; A) Parobé; B) Campo Bom3; C) Campo Bom2, D) Campo Bom1; E) Novo Hamburgo.

Da mesma forma, foi realizada análise de sobreposição do polígono mapeado neste estudo e o polígono gerado pelo levantamento de AUs da Secretaria Estadual de Meio Ambiente (SEMA) do Rio Grande do Sul em 2019 (Fig. 9), no qual foi utilizado imagens do satélite RapidEye. Assim, aferiu-se que os dados se sobrepõem em sua

totalidade e ainda o perímetro levantado pelo projeto mapeou mais AUs. Uma das possíveis explicações para esse levantamento de AUs apresentar maior quantidade de AUs quando comparado ao levantamento da SEMA (62,29km²), é justamente a qualidade das imagens de satélite centimétricas, as quais possuem 0,5m de resolução espacial, conferindo um maior detalhamento dos alvos presentes nas imagens. A sobreposição do polígono de AUs com o polígono gerado pela SEMA, elucida que as AUs da BHRS continuam resistindo às atividades e pressões antrópicas.

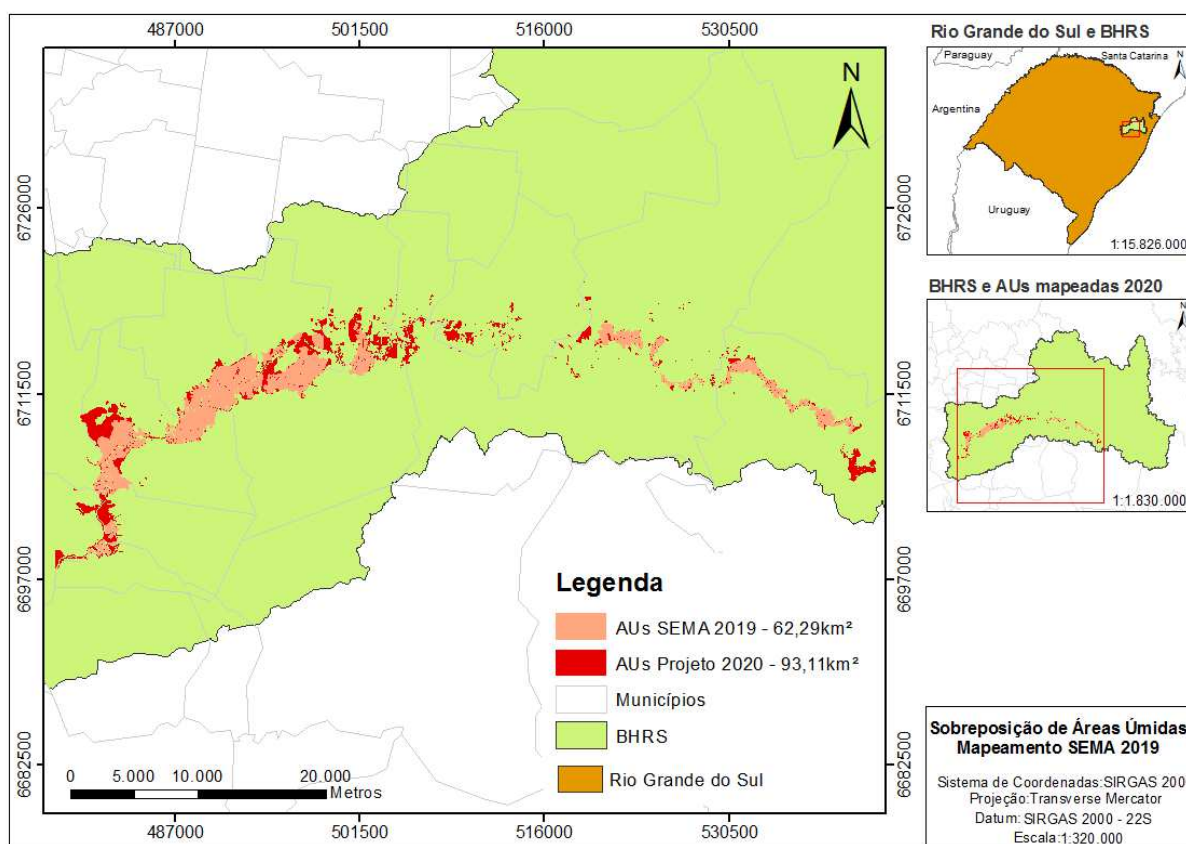


Fig. 9. Mapa com sobreposição das AUs levantadas pela SEMA e pelos resultados gerados no presente projeto

Quanto ao uso do solo na BHRS, existem relatos documentados por Rambo em 1942, em que ele descreve a descaracterização das matas ciliares e ribeirinhas para o uso da terra no plantio de arroz e demais culturas agrícolas naquela época. As atividades antrópicas apenas aumentaram ao longo das décadas.

No estudo de Oliveira et al. (2017), os autores utilizaram técnicas de SR e SIG para investigar e definir as Áreas de Preservação Permanente (APPs) no município de São Leopoldo/RS, e ao final do estudo, verificaram que as AUs representam cerca

de 10% da área total do município, concluindo que com a crescente expansão urbana aliada a busca por áreas habitáveis próximas ao rio, ocasionada pela diferença social e econômica da população, seria necessário um planejamento ambiental e urbanístico que busque aliar as demandas ambientais e sociais.

Seguindo o mesmo contexto, Dutra e Muller (2017) investigaram uma área de banhado no município de Campo Bom/RS, com o intuito de avaliar o impacto das ações antrópicas no local. O estudo concluiu que a busca por áreas habitáveis resultou na descaracterização da área, sendo que 36% da área foi caracterizada como banhado natural e 6% em banhados artificiais.

Conforme evidenciado nos resultados apresentados, o uso de imagens centimétricas, ou seja, de alta resolução espacial, e o uso de dados adquiridos por VANT, são capazes de gerar uma análise e processamento de imagem com um nível de detalhamento alto, concomitante a uma acurácia elevada. Consequentemente os dados com altas precisões resultam em inventários de AUs e estratégias para conservação e monitoramento desses ecossistemas mais eficientes e aplicáveis.

Cabe ressaltar que para o uso de dados de SR com altas resoluções, existem dificuldades no processamento destes dados em máquinas convencionais, pois as imagens possuem um peso e um tempo de processamento superiores as imagens de média e baixa resolução. E ainda, o custo de aquisição de imagens centimétricas geralmente não é englobada em orçamentos da gestão pública, restringindo o uso destes dados à projetos específicos.

4 CONCLUSÕES

A utilização de técnicas de SR para o mapeamento das AUs é uma ferramenta eficaz e necessária, diante da escala da degradação ambiental enfrentada nas últimas décadas. Com os avanços do SR nos últimos anos, uma gama maior de produtos com maiores resoluções espaciais e espectrais começaram a ser disponibilizados para uso civil, desta forma possibilitando a identificação de AUs com maior precisão.

O intenso crescimento urbano, aliado ao aumento da produção agrícola, demandam por mais áreas habitáveis e cultiváveis anualmente, ameaçando os ecossistemas ainda existentes. A elaboração de inventários é de extrema importância para a preservação destes mananciais hídricos, pois a partir destes estudos é possível diagnosticar a situação atual da conservação desses ambientes. No entanto, métodos

manuais e a campo podem ser desafiadores, devido principalmente ao tempo, o custo e a mão de obra investida para este tipo de estudo.

O uso de imagens de alta resolução mostrou-se eficiente no que diz respeito a uma localização mais precisa das AUs demonstrando que a ainda detém de uma área significativa (93,11km²). O método de classificação supervisionada das imagens, realizado no software gratuito, resultou em uma identificação com alta precisão. Consequentemente, conferiu ao método manual de delimitação dos polígonos uma exatidão maior, aliado também ao conhecimento do analista.

Somado ao método de classificação supervisionada e ao método usual de delimitação final dos polígonos das AUs, com base no conhecimento de campo e interpretação de imagem pelo analista, a técnica de identificação dos limites das AUs com uso de VANT revelou-se promissora. Os polígonos gerados pelo VANT apresentaram sobreposição aos polígonos resultantes do mapeamento prévio, confirmando a classificação inicial pelo software gratuito e gerando um polígono pontual com maior precisão, dada a altíssima resolução espacial do VANT.

Neste sentido, a utilização de produtos de SR e uso de um VANT proporcionaram uma eficiência elevada na identificação, principalmente em agilidade e ganho de tempo. Entretanto, mesmo apresentando uma alta precisão de levantamento através de imagens, as atividades de campo são indispensáveis para o processo de aferição das AUs que geraram dúvidas no processo de interpretação. Perante o cenário dos anos de 2020 e 2021, não foram realizadas todas as aferições a campo previstas no cronograma inicial. Sendo assim, como estudo futuro, devem ser consideradas as realizações das aferições a campo do polígono levantado.

Por fim, é importante ressaltar que o polígono das AUs está disponível para toda sociedade, podendo ser acessado pelo site do COMITESINOS, no qual a parte interessada pode verificar se sua propriedade está ou não inserida no polígono das AUs. Ainda, o mapeamento proporcionará aos municípios integrantes da área de estudo, uma base técnica para a elaboração de um planejamento ambiental e urbanístico estratégico, visando procedimentos e critérios de proteção das AUs remanescentes e ações de fiscalização.

REFERÊNCIAS

- AGÊNCIA NACIONAL DAS ÁGUAS (ANA). **Portal Hidroweb**. Disponível em: <<http://www.snirh.gov.br/hidroweb/apresentacao>>. Acesso em: 30 abr. 2021.
- ANSCHAU, C. **Atlas do Projeto Verdesinos**. Editora Anschau, Porto Alegre, p. 116, 2016.
- BANSAL, Sangeeta; KATYAL, Deeksha; GARG, J.K. A novel strategy for wetland area extraction using multispectral MODIS data. **Remote Sensing Of Environment**, [s.l.], v. 200, p.183-205, 2017.
- BERTOLUCI, Vilma Daniela Mânica. **Inventário, biodiversidade e conservação de áreas úmidas do município de São Leopoldo**. 2004. 70 f. Dissertação (Mestrado) - Curso de Biologia, Universidade do Vale do Rio dos Sinos, São Leopoldo, 2004.
- BUTCHART, Stuart H.M. Shortfalls and Solutions for Meeting National and Global. Conservation Area Targets. **Conservation Letters**, v. 8, n. 5, p. 329-337, 2015.
- CAMERON, Cortney; MADUMERE, Chibuike. Assessment of Open-source Software, QGIS, To Estimate Hurricane Matthew Flood Extent in Robeson County, North Carolina, Using Unsupervised Classification. **Environmental and Engineering Geoscience**, v.25, n.4, p.359–367, 2019.
- CHASMER, Laura, et al. Remote Sensing of Boreal Wetlands 1: Data Use for Policy and Management. **Remote Sensing**, v.12, n.8, p.1320. 2020.
- Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos (COMITESINOS). **Plano Sinos – Plano de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos-meta 3**. Consórcio Pró-Sinos [2014]. Disponível em: <<http://www.prosinos.rs.gov.br/downloads/Meta%203%20-%20Ativ.%203.3%20-%20Situa%C3%A7%C3%A3o%20Rec.%20H%C3%ADdricos.pdf>> Acesso em: 20 mai. 2020.
- Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos (COMITESINOS). **Caracterização da Bacia Hidrográfica do Rio dos Sinos**. 2019. Disponível em: <<http://www.comitesinos.com.br/bacia-hidrografica-do-rio-dos-sinos>>. Acesso em: 25 mai.2019.
- DUTRA, Márcia; MÜLLER, Jackson. Uso de sistema de informações geográficas-sig na avaliação dos impactos ambientais sobre o Banhado do Rio dos Sinos no Município de Campo Bom–Rs. **Revista de Iniciação Científica da ULBRA**, v. 1, n. 15, 2017.
- DVORETT, Daniel, et al. Developing a Hydrogeomorphic Wetland Inventory: Reclassifying National Wetlands Inventory Polygons in Geographic Information Systems. **Wetlands**, v.32, p.83–93, 2011.
- ENGESAT (Curitiba). **GEOEYE**. 2019. Disponível em: <<http://www.engesat.com.br/imagem-de-satelite/geoeye/>>. Acesso em: 12 out. 2019.

FITZ, Paulo Roberto. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008. ISBN 978-85-86238-82-6 e ISBN 978-85-7975-048-91.

GALLANT, Alisa L. The challenges of remote monitoring of wetlands. **Remote Sensing**, v.7, n.8, p. 10938-10950, 2015.

INSTITUTO Nacional de Pesquisas Espaciais Divisão de Sensoriamento Remoto – INPE. **Introdução ao sensoriamento remoto**. 2019. Disponível em: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>> Acesso em: 02 out. 2019.

JUNK, Wolfgang. J. et al. Brazilian wetlands: their definition, delineation, and classification for research, sustainable management, and protection. **Aquatic Conservation: Marine and Freshwater Ecosystems**, [s.l.], v. 24, n. 1, p.5-22, 2013.

KURTZ, Fabio C.; ROCHA, José S. M. da; KURTZ, Silvia M. de J. M. Zoneamento ambiental em Pantanais (Banhados). **Revista Brasileira de Engenharia Agrícola e Ambiental**, [s.l.], v. 5, n. 2, p.308-312, 2001.

LIU, William Tse Horng. **Aplicações de sensoriamento remoto**. 2ed. São Paulo: Oficina de Textos, 2015. Livro eletrônico.

MAHDAVI, Sahel et al. Remote sensing for wetland classification: A comprehensive review. **GIScience & Remote Sensing**, v. 55, n. 5, p. 623-658, 2018.

MALTCHIK, Leonardo; STENERT, Cristina; BATZER, Darold Paul. Can rice field management practices contribute to the conservation of species from natural wetlands? Lessons from Brazil. **Basic and Applied Ecology**, v. 18, p. 50-56, 2017.

MAZZOLENI, Maurizio et al. Testing UAV-derived topography for hydraulic modelling in a tropical environment. **Natural Hazards: Journal of the International Society for the Prevention and Mitigation of Natural Hazards**, v. 103, n. 1, p. 139-163, 2020.

MENESES, Paulo Roberto; ALMEIDA, Tati de (Org.). **Introdução ao processamento de imagens de Sensoriamento Remoto**. Brasília - DF: Unb, 2012. 266 p.

MILLENNIUM ECOSYSTEM ASSESSMENT. **Ecosystems and human wellbeing: wetlands and water**. 2005. Disponível em: <<https://www.millenniumassessment.org/documents/document.358.aspx.pdf>>. Acesso em: 02 de out. 2019.

MORAES, Sofia Royer. **Abordagem GEOBIA para a classificação do uso e cobertura da terra em área urbana associadas ao desenvolvimento de framework para monitoramento de inundações no município de Lajeado-RS**. Dissertação de Mestrado em Sensoriamento Remoto e Geoprocessamento. Universidade Federal do Rio Grande do Sul. Porto Alegre – RS. 2018.

RAMBO, Balduino. **A fisionomia do Rio Grande do Sul: Ensaio de monografia natural**. Porto Alegre: Livraria Selbach, 1956.

RAMSAR, Ramsar Convention on Wetlands. **Global Wetland Outlook: State of the World's Wetlands and their Services to People**. Gland, Switzerland: Ramsar Convention Secretariat, 2018. Disponível em: <<https://www.global-wetland-outlook.ramsar.org/outlook>> Acesso em: 24 fev. 2021

RAPINEL, Sebastien, et al. Mapping potential, existing and efficient wetlands using free remote sensing data. **Journal of Environmental Management**, v. 247, p. 829–839, 2019.

ROLON, Ana Silvia. MALTCHIK, Leonardo. Áreas palustres: classificar para proteger. **Ciência hoje**, v.38, n 228, 2006.

RUSNÁK, Miloš et al. Modelo para mapeamento de paisagem de rio em alta resolução usando tecnologia UAV. **Medição**. v. 115, p. 139-151, 2018.

SCHULZ et al. **Guia de Identificação de Banhados da Bacia Hidrográfica do Rio dos Sinos**. 1. ed. São Leopoldo: Casa Leiria. 2021.

THE RAMSAR CONVENTION SECRETARIAT (Switzerland). **World Wetlands Day, 2 February: Urban wetlands: prized land, not wasteland**. 2018. Disponível em: <<http://www.worldwetlandsday.org/>>. Acesso em: 03 out. 2019.

3. CAPÍTULO III

Predição de bandas espectrais a partir de técnicas de Inteligência Artificial para classificação de áreas úmidas: um estudo de caso na Bacia Hidrográfica do Rio dos Sinos

(Manuscrito nas normas da revista “Plos One”)

PREDIÇÃO DE BANDAS ESPECTRAIS A PARTIR DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE ÁREAS ÚMIDAS: um estudo de caso na Bacia Hidrográfica do Rio dos Sinos

Ana Caroline Ruppenthal¹

¹ Laboratório de Ecologia de Peixes-LEP, Universidade Unisinos, São Leopoldo RS 93022-750, Brasil.

RESUMO

O uso de produtos de sensoriamento remoto (SR) para geração de inventários da situação das áreas úmidas (AUs) se mostra eficiente, tendo em vista que os levantamentos a campo desses ecossistemas muitas vezes são de difícil acesso, demandam muito tempo e altos custos. Para a elaboração de mapeamentos de AUs com altas acurácias se faz necessário o uso de imagens de satélites com altas resoluções espaciais e espectrais, tendo em vista a singularidade e complexidade em identificar esses ambientais. Nos últimos anos diversas técnicas para aumentar a resolução espectral de imagens de satélite foram criadas, com o objetivo de melhorar os produtos de SR e assim aumentar a acurácia dos mapeamentos. Nesta perspectiva, o objetivo deste trabalho foi propor um método para predizer bandas espectrais a partir de imagem RGB (Red, Green, Blue) de resolução centimétrica por meio de Rede Neural Artificial (RNA), com o intuito de gerar uma imagem com alta resolução espacial e mais alta resolução espectral para posterior classificação de AUs em um determinado perímetro da Bacia Hidrográfica do Rio dos Sinos-BHRS localizada no Sul do Brasil. Com a metodologia validada e a RNA treinada, foi possível predizer bandas espectrais, gerando uma imagem predita com 2m de resolução espacial e dez bandas espectrais RGB + Near Infrared (NIR) + RedEdge (RE) + Short Wave Infra-Red (SWIR). A posterior classificação supervisionada da imagem bruta e imagem predita, constatou-se um aumento de ~5% na acurácia global para a imagem predita. A utilização de bandas do NIR, RE e SWIR configuraram uma maior acurácia e delimitação das AUs.

Palavras-chave: Rede Neural Artificial, alta resolução, predição, multiespectral, classificação supervisionada, áreas úmidas.

INTRODUÇÃO

As áreas úmidas (AUs) são ecossistemas responsáveis por várias funções ecológicas, além de proverem diversos serviços ecossistêmicos importantes à sociedade [1]. Por apresentarem processos bióticos e abióticos singulares e complexos, as AUs desempenham papéis importantes, como o fornecimento de habitats para a fauna e flora, recarga de aquíferos, regulação de enchentes, controle do regime hídrico e do clima, purificação da água e retenção de carbono [2] [3] [4] [5] [6].

Apesar de serem amplamente reconhecidas por suas funções ecológicas e sociais, as atividades antrópicas vêm causando um aumento expressivo na degradação das AUs nas últimas décadas [6]. Estima-se que as perdas de AUs no século 20 foram de 64% a 71%, e em algumas regiões do globo, principalmente na Ásia, essas taxas foram ainda maiores [7]. Além disso, as taxas de perda das AUs naturais de interiores têm sido consistentemente maiores, em um ritmo mais acelerado do que as AUs costeiras naturais [7].

Por apresentarem singularidades e diferentes formações estruturais que variam ao longo das regiões do globo, a proteção destes ecossistemas ainda é muito frágil [8]. Um grande número de tipologias e nomenclaturas de AUs são resultado dessa alta heterogeneidade, dificultando a classificação, o mapeamento e, conseqüentemente, a conservação desses ambientes [8] [9].

Neste sentido, a elaboração de ferramentas e estratégias para proteção das AUs depende das informações existentes acerca da situação desses ecossistemas [10]. Por este motivo, o mapeamento de AUs possibilita a aquisição de informações sobre a quantidade de áreas e a situação atual das mesmas [4] [11].

As metodologias de mapeamento de AUs a campo, ou chamado *in situ*, acabam sendo caras, além de muitas AUs possuírem o seu acesso restrito, tornando a logística do levantamento em campo muito mais difícil [4]. Frente a esta dificuldade, o levantamento por sensoriamento remoto (SR) desses ecossistemas é uma opção viável e que apresenta altas taxas de acurácias, reduzindo assim custos e otimizando tempo e recursos.

Devido a rapidez da expansão e melhorias das tecnologias de SR, assim como de métodos analíticos, a precisão dos mapeamentos das AUs e a identificação das tipologias por imagens de satélite tiveram um salto gigante nas últimas décadas.

Porém, tendo em vista a complexidade das estruturas das AUs, a busca por melhorias nas imagens de satélite e nos métodos de classificação são constantes [12].

Atualmente, diversos sensores ópticos podem ser utilizados na classificação de AUs, mas duas características dos sensores é que definirão a qualidade do mapeamento, sendo elas a resolução espectral (faixa e o número de bandas espectrais) e a resolução espacial (tamanho do pixel da imagem) que os sensores agregam [13].

Ao realizar a classificação de AUs com imagens multiespectrais, é importante investigar as características dos sensores de satélites disponíveis e avaliar as diferentes bandas espectrais para aferir quais fornecem uma melhor identificação espectral. Avaliando específicos estudos sobre levantamentos de AUs, a maioria dos trabalhos realizados argumentou que as bandas do infravermelho próximo (NIR) e do RedEdge são as mais eficazes e úteis para delinear tipos de AUs [13] [14] [15] [16] [17] [18]. As bandas do infravermelho de ondas curtas (SWIR), que possuem sensibilidade à umidade do solo e da vegetação, já foram relatadas como eficientes na identificação de alguns tipos de AUs [13].

Neste contexto, os novos sensores de satélite como o Sentinel-2, agregam mais bandas espectrais com comprimentos de onda contendo informações significativas, sem o custo necessário ou as restrições espaciais do uso de um sensor de imagens hiperespectral. Por exemplo, o sensor Sentinel-2 incorpora a refletância da banda RedEdge (694,4 nm – 713,4 nm) e os comprimentos de ondas do SWIR que auxiliam significativamente a identificação da vegetação [12].

Para Amani et al. (2018) as bandas do RedEdge produziram a segunda melhor discriminação entre pares de classes de AUs, seguidas das bandas do NIR, fornecendo informações importantes sobre os parâmetros bioquímicos e biofísicos das AUs.

Neste mesmo sentido, Kaplan e Avadn (2019) utilizaram imagem Sentinel-2 para classificação de AUs, a qual resultou em uma acurácia de 92%, sendo que as bandas espectrais do RedEdge influenciaram significativamente na classificação. Os autores também elucidam que a capacidade do classificador em separar completamente as classes de AUs das demais, como florestas, campos e áreas agrícolas, é um problema recorrente nas técnicas de classificação, e o uso da banda RedEdge auxilia nessa melhor discriminação.

As imagens de alta resolução espacial, como é o caso das imagens do satélite GeoEye-1, possuem mais geometria e informações de textura nas características da superfície, além de auxiliar facilmente na identificação das características do solo. Todavia, elas normalmente agregam poucas bandas espectrais e apresentam um alto custo de aquisição [19]. Em comparação com as imagens de média resolução espacial, por exemplo imagens do Sentinel-2, as mesmas possuem uma resolução espacial média (10m a 60m), porém são compostas por uma quantidade maior de bandas espectrais, e em sua maioria, são gratuitas [19].

Diante da problemática, diversas técnicas para aumentar a resolução espectral de imagens de satélite foram criadas, como o uso de técnicas de fusão de imagens ou *Pansharpening* [20]. O *Pansharpening* busca integrar a informação complementar de imagens multiespectrais de baixa resolução (LR-MS) e imagens pancromáticas de alta resolução (HR-PAN), resultando em uma imagem com maior resolução espectral e mesma resolução espacial da pancromática [21].

Com o constante avanço da capacidade computacional e técnicas avançadas de aprendizado de máquina (AM), o uso de redes neurais artificiais (RNAs) tem se mostrado uma técnica eficiente e com resultados promissores no quesito de melhoramento da resolução espectral e espacial de imagens de satélite [22] [23] [24] [25].

As arquiteturas de rede do tipo MLP são os modelos de RNAs mais utilizados e conhecidos. Neste tipo de rede, foram adicionadas camadas de neurônios artificiais intermediárias, desta forma sendo possível aproximar qualquer função desde que contenha o número de neurônios suficiente. Além disso, em uma MLP, cada neurônio executa uma função específica [26] [27].

Neste sentido, o objetivo principal deste trabalho foi propor um método para prever bandas espectrais a partir de imagem RGB de resolução centimétrica por meio de RNA, com o intuito de gerar uma imagem com alta resolução espacial e mais alta resolução espectral para posterior classificação de AUs em um determinado perímetro da Bacia Hidrográfica do Rio dos Sinos, localizada no Sul do Brasil.

MATERIAL E MÉTODOS

A metodologia para o desenvolvimento do trabalho está representada no fluxograma metodológico da **Fig. 1**.

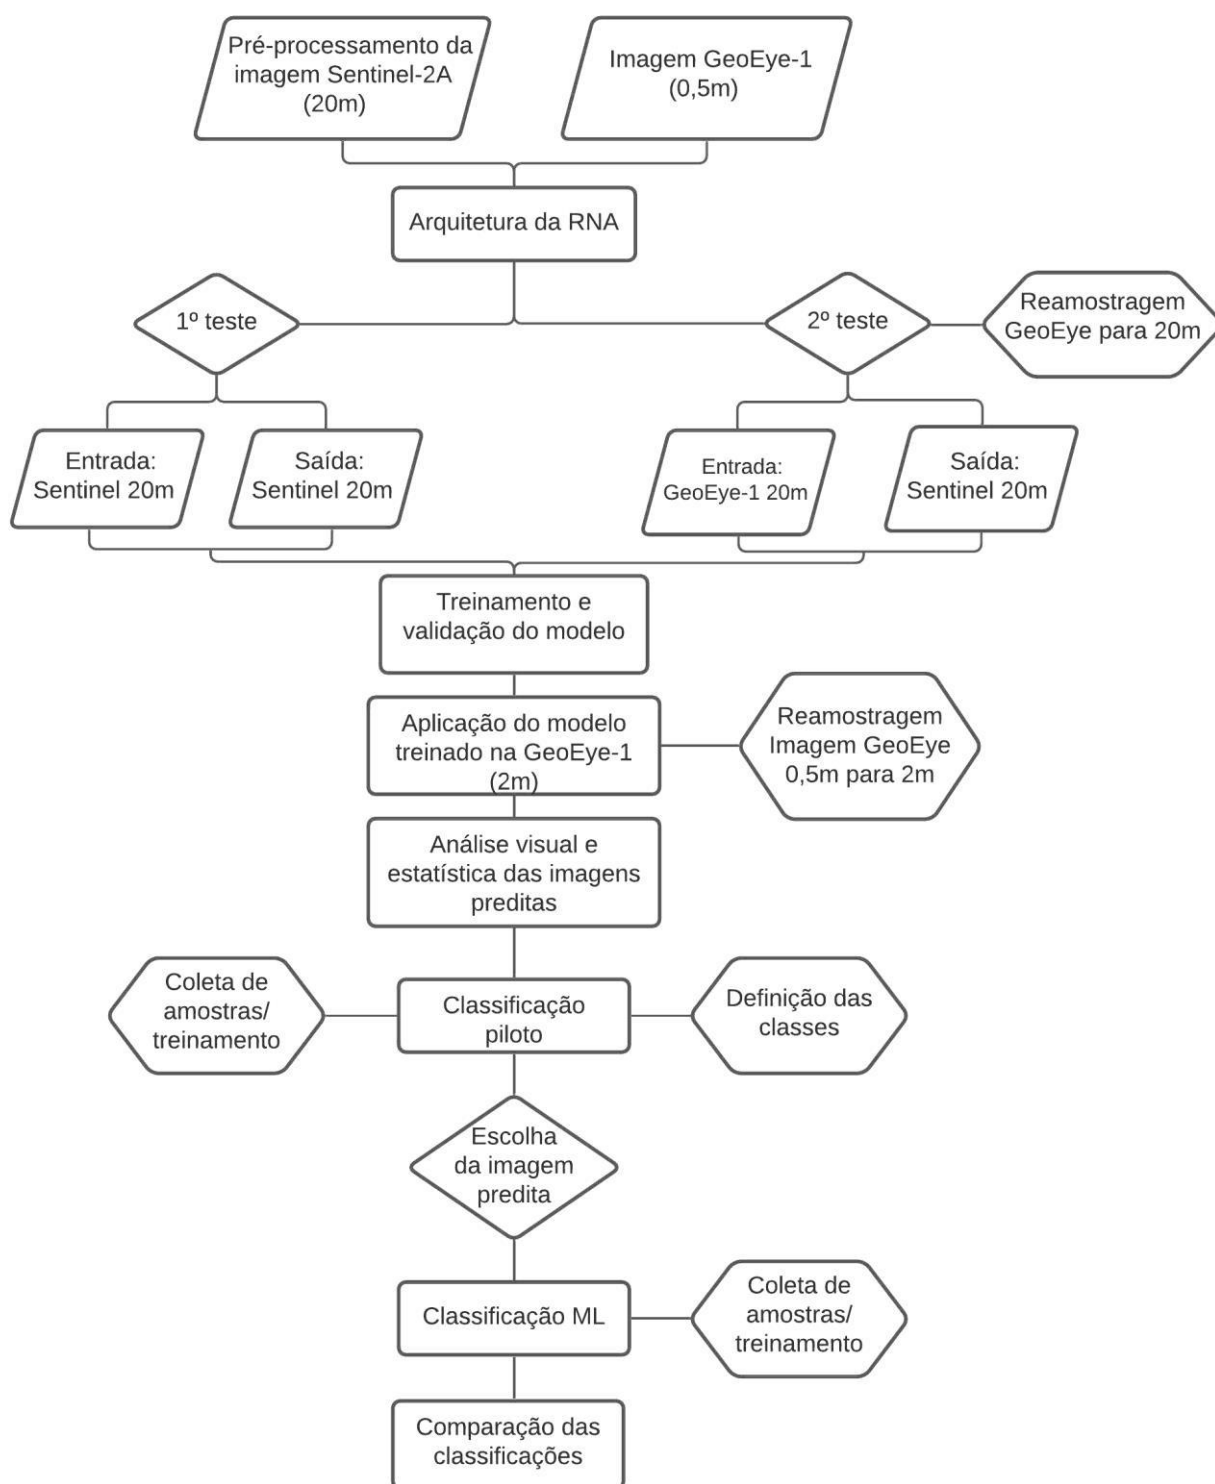


Fig. 1. Fluxograma metodológico.

ÁREA DE ESTUDO

A área de estudo está localizada na BHRS **Fig. 2**, situada na região Nordeste do Estado do Rio Grande do Sul. A bacia possui uma área de 3.696km² e um total de

aproximadamente 4.000km² de malha hídrica [28]. O curso d'água principal da BHRS é o Rio dos Sinos, possuindo uma extensão aproximada de 190 Km, apresenta precipitação pluviométrica anual de 1.350mm e suas nascentes estão localizadas na Serra Geral, no município de Carará [29] [30]. Um total de 32 municípios são abrangidos pela BHRS, sendo que a maior concentração populacional e atividades industriais se concentra na sua porção mais inferior da bacia [31].

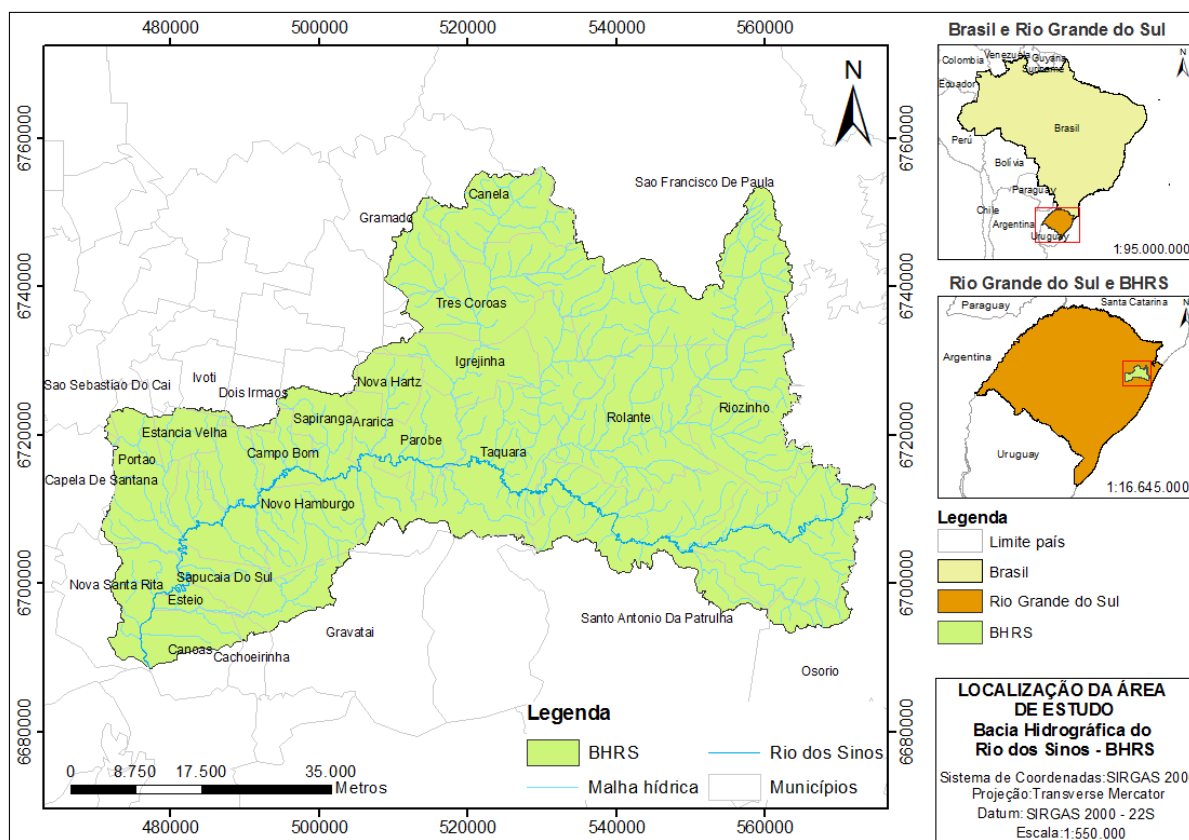


Fig. 2. Área de estudo, localizada em na BHRS, conforme detalhado no mapa.

O projeto de mapeamento e identificação de AUs na BHRS em sua totalidade, contempla o mapeamento das AUs em um polígono de 606km², sendo este polígono total composto por cinco imagens do satélite GeoEye-1, datadas do período de 22/05/2017 e 01/10/2017, ambas com resolução espacial de 0,5m e bandas RGB e NIR. Embora o projeto abranja uma área maior, para a realização do estudo sobre a predição de bandas espectrais foi utilizada apenas uma imagem de satélite (imagem de nº 01), a qual compreende trechos dos municípios de São Leopoldo, Novo Hamburgo, Canoas, Sapucaia do Sul, Portão, Esteio e Nova Santa Rita (**Fig. 3**).

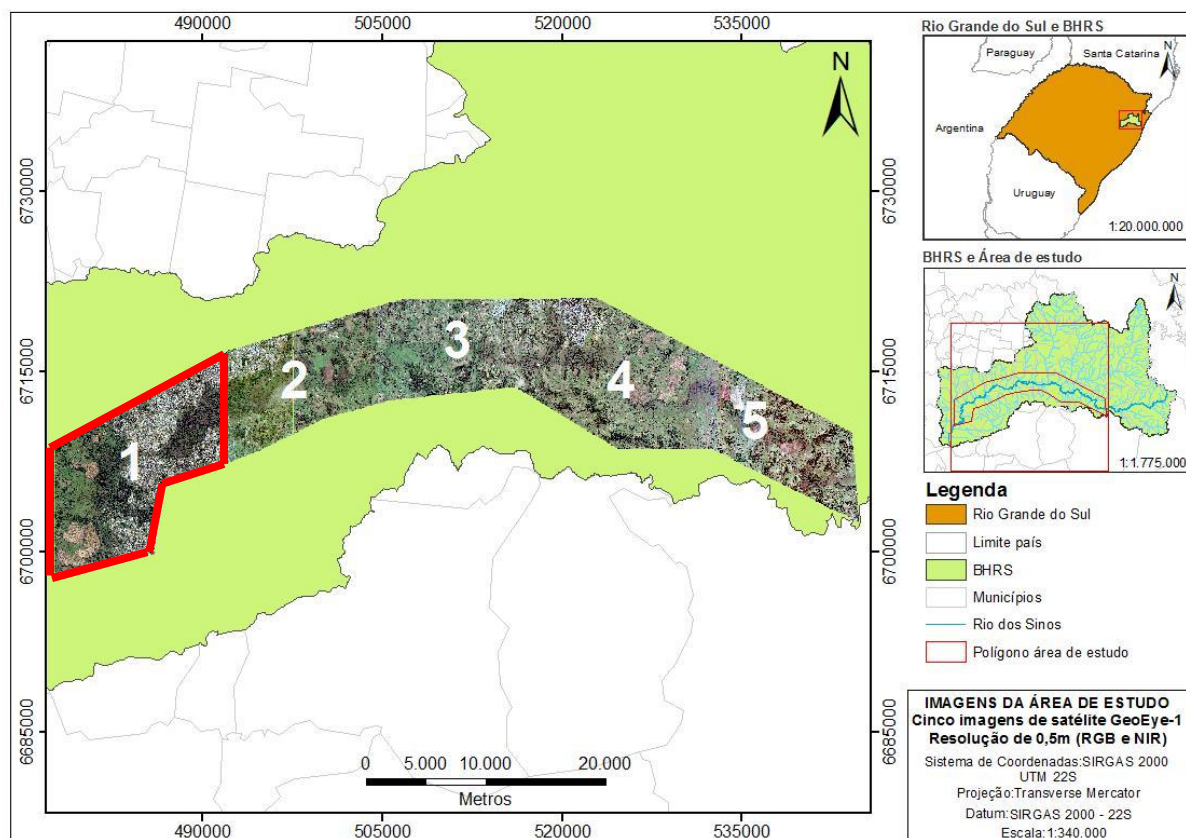


Fig. 3. Mosaico das cinco imagens do projeto na íntegra. A imagem nº 1 do perímetro total foi utilizada para este estudo (sinalizado em vermelho)

AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS

Como pode ser observado na **Fig. 1**, o ponto de partida para o desenvolvimento da RNA foi a aquisição e pré-processamento das imagens de satélite. A imagem de satélite de alta resolução foi adquirida da empresa Globalgeo, pelo COMITESINOS, datada do período de 2017. A imagem é proveniente do satélite GeoEye-1, sendo a mesma referência em termos de imagens de alta resolução. Ela possui resolução espacial de 0,5m e bandas do tipo Pancromático P&B e Multiespectrais no Azul, Verde, Vermelho (RGB) e NIR [32]. A imagem foi entregue já processada (ortoretificadas, mosaicadas e realçadas), em formato GeoTIFF - 8 bits, projeção UTM e projeção SIRGAS 2000. Salienta-se que não existe a informação de quais parâmetros foram utilizados para o pré-processamento da imagem de satélite.

Para a etapa de predição de bandas espectrais a imagem GeoEye foi reamostrada duas vezes, com o objetivo de realizar dois testes e comparar os resultados. Primeiramente a imagem de 0,5m foi reamostrada para 2m de resolução

espacial, e em um segundo momento a mesma imagem foi reamostrada de 0,5m para 20m de resolução espacial.

A aquisição da imagem de satélite Sentinel-2A foi realizada por meio da busca no catálogo de imagens disponíveis do satélite Sentinel-2, fornecido pelo Portal Copernicus, da Agência Espacial Europeia (ESA), datada de 23 de agosto de 2017. Em sua forma bruta a imagem contém 13 bandas espectrais variando de 443 a 2190 nm, com resolução espacial de 10m para as bandas do visível, 20m para o infravermelho e 60m para as bandas de correção atmosférica.

Para o presente estudo, foram utilizadas 10 bandas espectrais do Sentinel-2A, sendo elas a banda do Azul (492.4nm), Verde (559.8nm), Vermelho (664.6nm), RE 1 (704.1nm), RE 2 (740.5nm), RE 3 (782.8nm), NIR (832.8nm), RE 4 (864.7nm), SWIR 1 (1613.7nm) e SWIR 2 (2202.4nm).

As bandas espectrais de 10m de resolução espacial, foram reamostradas para 20m, desta forma igualando a resolução espacial para todas as bandas espectrais. Após a reamostragem, as bandas foram mescladas, gerando a imagem final. O processamento de Nível 2A inclui uma classificação de cena e uma correção atmosférica aplicada a produtos de ortoimagem de topo da atmosfera (TOA) Nível 1C. A imagem já passou pelo processo de correção de efeitos de reflectância dos alvos. Por fim, a imagem Sentinel-2A foi recortada utilizando a camada máscara da imagem GeoEye.

ARQUITETURA E CONFIGURAÇÕES DA RNA

O método de RNA utilizada para este trabalho foi elaborado, proposto e validado por Marques Júnior et al. (2020). A RNA recebeu algumas modificações na sua arquitetura no âmbito das camadas de entrada e nas camadas de saída. A RNA foi estruturada na linguagem Python (versão 3.7.6), com o suporte do pacote Anaconda, com a integração da biblioteca Tensorflow (versão 2.1.0) e a Scikit-learn (versão 0.24.1) para o AM e a biblioteca Keras (2.3.1) para a criação das camadas da rede neural. Cada etapa de treinamento teve duração de 60 épocas em uma máquina com CPU Intel® Core™ i7-9750H, 2.60GHz, 16,0GB de RAM.

A rede neural estruturada utiliza a arquitetura *feedforward* densa (FFNN) sequencial, totalmente conectada, uma vez que todos os neurônios de uma camada estão conectados com todos os *inputs* da próxima camada. As redes *feedforward*

propagam as informações em uma única direção, ou seja, as informações seguem o sentido da camada de entrada para a camada de saída (unidirecional) [33].

As redes *feedforward* são divididas em dois tipos, a de uma única camada e a de múltiplas camadas, sendo que a segunda se distingue pela presença de uma ou mais camadas intermediárias ou escondidas na rede. Com o acréscimo de uma ou mais camadas intermediárias, é possível elevar o poder computacional de processamento não-linear e o armazenamento na rede [34].

Na camada de entrada foram utilizadas quatro bandas espectrais (RGB e NIR). Assim, a camada de entrada da rede é composta por um quadrado 3×3 de pixels (9 pixels para cada banda espectral), ou seja, 36 neurônios. A camada de saída contém seis bandas espectrais da imagem Sentinel-2A (RE 1, 2, 3 e 4, e SWIR 1 e SWIR 2), resultando em um total de seis neurônios como saída (um para cada banda espectral). Complementando a rede, foram utilizadas três camadas densas ocultas, totalmente conectadas, com 150, 70 e 35 neurônios cada (**Fig. 4**).

Outrossim, o método de RNA proposto considerou os pixels de vizinhança em *kernels* (filtros), ou seja, a rede calcula os valores dos pixels vizinhos para estimar o valor do pixel central. Esta é uma estratégia para fornecer mais informações à RNA, logo possibilitando estimar um único pixel na imagem com maior resolução, no caso, as bandas espectrais geradas.

Além disso, o processo de treinamento da RNA utilizou o mecanismo de *backpropagation*, o qual é composto pela fase *forward* na qual cada objeto de entrada é apresentado à rede e recebido por cada um dos neurônios da camada intermediária, os quais aplicam a função de ativação a sua entrada total e produzem um valor de saída que é aplicado as camadas seguintes até a camada de saída [27]. A diferença entre os valores de saída produzidos e os desejados para cada neurônio da camada de saída indica o erro cometido pela RNA para o objeto apresentado. Dessa forma, é aplicada a fase *backward*, a qual ajusta os pesos da entrada de acordo com o valor do erro de cada neurônio da camada de saída [27].

A ativação das três camadas ocultas da rede neural utilizou a função de ativação da unidade linear retificada (ReLU), enquanto que na última camada a função de ativação utilizada foi a sigmoide.

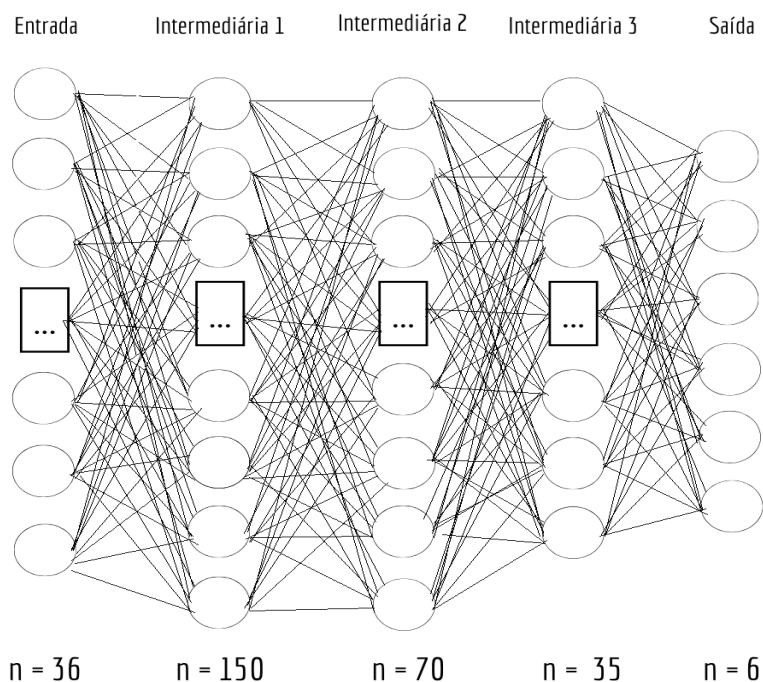


Fig. 4. Arquitetura da RNA

Treinamento da RNA

Após cada treinamento de RNA, a rede “aprende” qual a resposta espectral em regiões do espectro como RE e SWIR determinado alvo possui, considerando como entrada dados RGB e NIR das respectivas imagens. Sendo assim, esta relação pode ser “extrapolada” para imagens de outras resoluções, neste caso para a imagem GeoEye (2m), que não possui as bandas de interesse (RE e SWIR), desta forma gerando uma imagem de alta resolução espacial e mais alta resolução espectral. Cada modelo treinado é aplicado à imagem GeoEye de alta resolução (2m).

Por fim, os produtos finais da predição de bandas espectrais foram duas imagens de alta resolução espacial (2m) e espectral (10 bandas, sendo elas Blue, Green, Red, NIR, 4 Red Edge e 2 SWIR) que possibilitem uma melhor classificação e delimitação de AUs.

Como já apresentado no fluxograma metodológico (**Fig. 2**), foram executadas duas abordagens de treinamento para a predição de bandas espectrais:

- 1) O primeiro teste utilizou, para a fase de treinamento da rede, bandas da imagem de satélite Sentinel-2A (resolução de 20m), na camada de entrada e na camada de saída.

- 2) O segundo teste utilizou, para fase de treinamento da rede, a imagem de satélite GeoEye reamostrada para 20 m de resolução espacial na camada de entrada e a imagem de satélite Sentinel-2A (20m) na camada de saída.

Destaca-se que a necessidade da realização de dois testes nesta etapa de treinamento e validação da RNA deu-se em virtude dos resultados do primeiro teste não terem sido considerados suficientemente adequados ao objetivo proposto, tópico este que será detalhado na seção de “Resultados”.

Métodos de avaliação da RNA

A etapa fundamental em qualquer modelo de AM é avaliar a precisão do modelo. Para validação da rede neural proposta, os valores desejados e previstos no conjunto de teste são comparados para que seja possível avaliar quão boa é a capacidade preditiva do modelo da rede. As métricas mais utilizadas incluem o erro quadrático médio (MSE) (que também é usado como função de custo durante o treinamento da rede) e o coeficiente de determinação R^2 .

O MSE representa a média da diferença quadrática entre os valores originais e previstos no conjunto de dados. Ele mede a variância dos resíduos. Seu cálculo é dado pela equação (1):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (1)$$

Em que \hat{y} indica o valor previsto e y_i o valor esperado.

Apesar do MSE demonstrar como o modelo funciona, ele não diz explicitamente como o modelo é eficiente para prever os valores corretos. Neste contexto, o coeficiente de determinação R^2 está empregado.

O cálculo do R^2 é dado pela equação (2):

$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (2)$$

Em que \bar{y} é a média dos valores observados de y . O valor resultante estará na faixa de 0 a 1, com 1 indicando um ajuste perfeito entre os valores esperados e os valores preditos.

CLASSIFICAÇÃO DAS IMAGENS

A classificação de imagens é definida como a identificação de determinados objetos de acordo com a atribuição de cada pixel de uma imagem a um grupo de classes [35]. Entre os tipos de classificação de imagem, destacam-se a classificação não-supervisionada, a classificação supervisionada e a classificação orientada a objetos (OBIA).

Para o presente estudo foi utilizada a abordagem de Classificação Supervisionada, pois ela permite gerenciar o número de classes a serem criadas, baseadas nas amostras de treinamento pré-definidas pelo usuário.


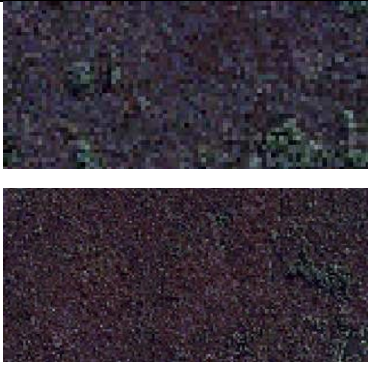
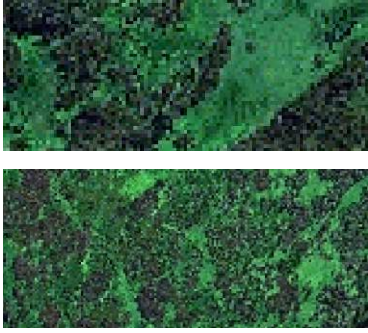

O processo de classificação das imagens foi executado no *software* ArcGis 10.8, sendo dividido nas etapas de definição do algoritmo de classificação supervisionada, definição das classes, coleta das amostras de treinamento, execução da classificação e avaliação da acurácia.

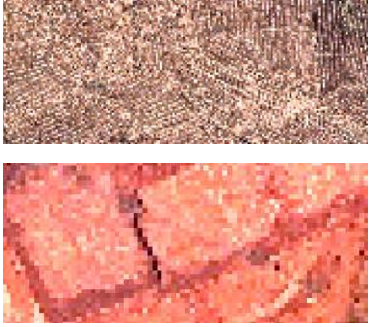
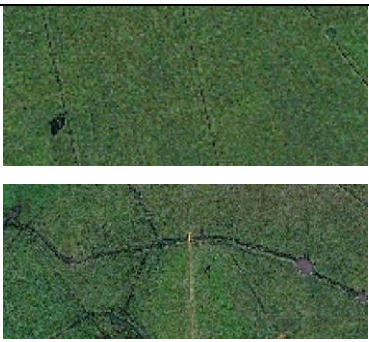


A classificação supervisionada deve ser aplicada em ambas as imagens para comparar e analisar a qualidade da informação espectral prevista pela RNA. O método de classificação escolhido foi o Máxima Verossimilhança (ML) para a classificação. O método ML considera as médias e covariâncias das assinaturas de cada classe ao atribuir cada célula a uma das classes representadas no arquivo de assinatura.

A partir das imagens, oito classes de uso do solo foram definidas para gerar as amostras de treinamento: Água; AU de solo encharcado; AU de macrófitas flutuantes; Vegetação arbórea; Solo exposto; Rizicultura; Campo _ vegetação rasteira; Áreas urbanizadas.

É importante enfatizar que as demais classes apresentadas na tabela de classes de interpretação auxiliaram no processo de delimitação usual do polígono das AUs da BHRS, visto que este processo de delimitação manual levou em consideração o reconhecimento do operador, o qual toma decisão da marcação baseada nas classes de interpretação **Tab.1**.

Tabela 1. Chave de interpretação para definição das amostras de treinamento

Classe	Imagem Geoeye (2m) Escala: 1:2000	Definição	Chave de interpretação
Água		Água	Cor: marrom e azul Textura: lisa Tom: escuro Estrutura: lisa/homogênea
AU com solo encharcado		AUs com presença de vegetação mais saturada de água. Vegetação aparentemente seca	Cor: Marrom Textura: granuloso heterogêneo Tom: verde escuro marrom escuro Estrutura: irregular e com tamanhos variáveis
AU com macrófitas flutuantes		AUs com presença de vegetação superficial característica – macrófitas flutuantes	Cor: Verde Textura: granuloso heterogêneo Tom: claro a tons mais escuros Estrutura: irregular com tamanhos variáveis
Vegetação arbórea		Vegetação densa	Cor: verde Textura: rugosa Tom: médio a escuro Estrutura: irregular com tamanhos variáveis

<p><i>Solo exposto</i></p>		<p>Solo exposto (mineração, solo pós colheita de culturas agrícolas, etc)</p>	<p>Cor: marrom Textura: granulado orientado Tom: claro ao escuro Estrutura: geometria retangular a irregular.</p>
<p><i>Rizicultura</i></p>		<p>Plantações de arroz</p>	<p>Cor: verde Textura: lisa Tom: claro Estrutura: retangular homogênea</p>
<p><i>Campo vegetação rasteira</i></p>		<p>Vegetação de gramados de residências, campos de pastagens e outras plantações agrícolas</p>	<p>Cor: verde claro Textura: lisa Tom: claro Estrutura: retangular homogênea</p>
<p><i>Áreas antropizadas</i></p>		<p>Área urbana com construções (telhados cinza claro e escuros e telhados de cerâmica marrom)</p>	<p>Cor: cinza claro e escuro e tons de marrom Textura: lisa Tom: claro Estrutura: geometria retangular e quadrada</p>

Fonte: Adaptado de Moraes (2018) [35].

Após a definição das classes, foram selecionadas as amostras de treinamento. Essas amostras consistem em polígonos que foram coletados considerando cada imagem, a experiência visual e de campo do usuário, configurando uma maior certeza na escolha das amostras. Com os parâmetros de classificação definidos, o algoritmo ML foi aplicado para cada imagem. A classificação supervisionada das imagens ocorreu em duas etapas, sendo:

- 1) Na primeira etapa delimitou-se um perímetro menor de interesse, aplicado às três imagens a serem avaliadas (GeoEye bruta (2m), imagem predita no teste 1 e imagem predita no teste 2), para realização de uma classificação piloto com o intuito de validar qual das duas imagens preditas apresentaria a classificação com maior valor de acurácia. Para esta classificação piloto foram definidas 15 amostras de treinamento para cada classe de interesse. Após a classificação supervisionada em cada imagem, foi realizada a análise da acurácia das classificações;
- 2) A segunda etapa consistiu na classificação supervisionada da imagem GeoEye bruta (2m) e a imagem predita com melhor acurácia na classificação piloto, ambas em sua totalidade. Para esta classificação foram definidas 45 amostras de treinamento para cada classe. Após a classificação supervisionada em cada imagem, foi realizada a análise da acurácia das classificações.

Concluída a classificação supervisionada das imagens, foi executada a validação da classificação. A validação permite avaliar o desempenho do classificador. Este processo foi realizado no ArcGis com a criação de pontos de referência (pontos de verdade) e posteriormente a geração da matriz de confusão da classificação no Excel, assim como o cálculo dos índices de avaliação.

A partir da matriz de confusão são calculados alguns índices como acurácia geral, a precisão, a revocação, o F1 Score e coeficiente de concordância Kappa, para cada uma das imagens classificadas.

A acurácia geral mostra como nosso modelo classificou corretamente os Verdadeiros Positivos (VP) e os verdadeiros negativos (VN) considerando todas as previsões possíveis a serem feitas pelo classificador (3).

$$Acurácia\ geral = \frac{VP+VN}{Total} \quad (3)$$

A acurácia geral pode variar entre 0 e 1, mas pode ser expressa como a porcentagem de acerto do classificador.

Embora alguns trabalhos traduzam a métrica anterior (acurácia) como precisão, a métrica precisão (*precision*) demonstra quantas amostras o classificador classificou como valores positivos de forma correta. Seu cálculo é dado pela equação (4):

$$Precisão = \frac{VP}{VP+FP} \quad (4)$$

Esta métrica é muito importante na análise individual das classes, sendo possível verificar quais classes o classificador realmente classificou corretamente. Quanto maior o número de FP, menor será a medida de precisão.

A Revocação (*recall*) é uma métrica parecida com a precisão, porém sua importância incide em demonstrar como o classificador pode classificar corretamente o VP, mesmo que alguns pixels possam ser atribuídos a classe FN. Seu cálculo é dado pela equação (5):

$$Revocação = \frac{VP}{VP+FN} \quad (5)$$

O coeficiente de concordância Kappa, sugerido por Cohen em 1960, mostra o grau de concordância entre os pixels classificados e a os pixels de referência (verdade). Esse coeficiente varia entre 0 e 1, onde 0 indica que não há concordância entre os valores classificados e verdade, enquanto 1 indica uma concordância perfeita. O coeficiente Kappa é calculado através da equação (6):

$$Kappa = \frac{ACC-ACCexp}{1-ACCexp} \quad (6)$$

Neste contexto, o Kappa é um índice que demonstra o grau de acerto da classificação supervisionada, diminuindo o efeito dos acertos esperados simplesmente por fatores incertos.

A métrica F1 Score combina precisão e revocação trazendo um número único que indique a qualidade geral do modelo. Um modelo perfeito deve resultar em um valor de 1. Seu cálculo é dado pela equação (7):

$$F1 = \frac{2*precisão*revocação}{precisão+revocação} \quad (7)$$

RESULTADOS

Nesta seção são apresentados os resultados da predição de bandas espectrais com os modelos de RNA, a comparação das imagens preditas e a análise da classificação espectral entre a imagem de baixa resolução espectral e as imagens preditas pelo modelo de RNA, com alta resolução espacial e mais alta resolução espectral.

PREDIÇÃO DE BANDAS ESPECTRAIS

As métricas MSE e R^2 , que avaliam a eficiência do aprendizado do modelo de RNA para predição de bandas espectrais, mostram que o primeiro teste realizado com os dados da imagem Sentinel-2A na camada de entrada e na saída apresentaram valores superiores ao segundo teste. Ainda é possível analisar os valores das métricas de acordo com cada banda espectral predita segundo o modelo treinado.

Comparando as métricas entre o primeiro e o segundo treinamento, o primeiro modelo apresentou valores de R^2 e MSE superiores ao segundo modelo, destacando a banda RE 4 (que capta a luz refletida entre a faixa do visível e do infravermelho) apresentou a menor variação dos dados entre as demais (R^2 0,9831), sendo 98% da variância explicada pelo modelo. Enquanto a banda RE 1 apresentou o menor valor de erro quadrático médio (**Tab. 2**).

Quanto ao segundo treinamento (**Tab. 2**), as bandas espectrais preditas que apresentaram melhor desempenho da predição foram a RE 1 (R^2 0,7206) e a SWIR 2 (R^2 0,7361). Além disso, ambas as bandas espectrais apresentaram valores de MSE baixos, próximos a 0, indicando uma alta precisão no modelo treinado.

Tabela 2. Tabela das métricas de avaliação da predição de bandas: Avaliação do MSE e R^2 para o treinamento da RNA para cada banda espectral no teste 1 e 2.

<i>Bandas espectrais</i>	<i>TESTE 1</i>		<i>TESTE 2</i>	
	MSE	R^2	MSE	R^2
<i>RedEdge 1</i>	2,5e-05	0,973	0,000263	0,7206
<i>RedEdge 2</i>	4,6e-05	0,9734	0,000676	0,6139
<i>RedEdge 3</i>	5,4e-05	0,9788	0,000951	0,631
<i>RedEdge 4</i>	5,6e-05	0,9831	0,001111	0,6652
<i>SWIR 1</i>	0,000342	0,8789	0,000913	0,6769
<i>SWIR 2</i>	0,000291	0,881	0,000686	0,7361

Embora as métricas apresentadas acima indiquem que a predição de bandas do primeiro modelo treinado deveria gerar uma imagem com um resultado superior ao segundo, quando estes foram aplicados à imagem Geoeye de 2m, isso não ocorreu. Esta

afirmação surge, pois, outras informações adicionais acerca das duas imagens preditas devem ser levadas em consideração, como por exemplo o comportamento espectral da imagem quando submetida a composições de RGB distintas. Neste sentido, foi realizada uma análise das imagens conforme as mudanças de composição de bandas, para visualizar o comportamento das imagens preditas em relação a imagem Sentinel-2A original (considerada como *ground truth*).

Utilizando o modelo de RNA apresentado na seção anterior, foram realizados dois testes, o primeiro com as bandas RGB e NIR da imagem Sentinel-2A nas camadas de entrada e as bandas RE e SWIR da imagem Sentinel-2A nas camadas de saída, e após aplicado na imagem GeoEye (2m). No segundo teste a RNA foi treinada com as bandas espectrais RGB e NIR da imagem GeoEye (20m) nas camadas de entrada e as bandas RE e SWIR da imagem Sentinel-2A nas camadas de saída. A fase de aprendizado de cada treinamento decorreu durante 60 épocas. Após o treinamento e validação de cada modelo, os mesmos foram aplicados na imagem GeoEye (2m) resultando em duas imagens preditas com mais alta resolução espectral e espacial, ambas contendo dez bandas espectrais (RGB, NIR, RE 1,2,3,4 e SWIR 1 e 2).

Conforme pode ser observado na **Fig. 5** a imagem predita a partir do modelo gerado no primeiro teste, apresentou uma coloração muito distinta da imagem Sentinel-2A quando aplicada à composição de bandas 8-9-10, sendo que esta diferença abrupta não deveria ocorrer.

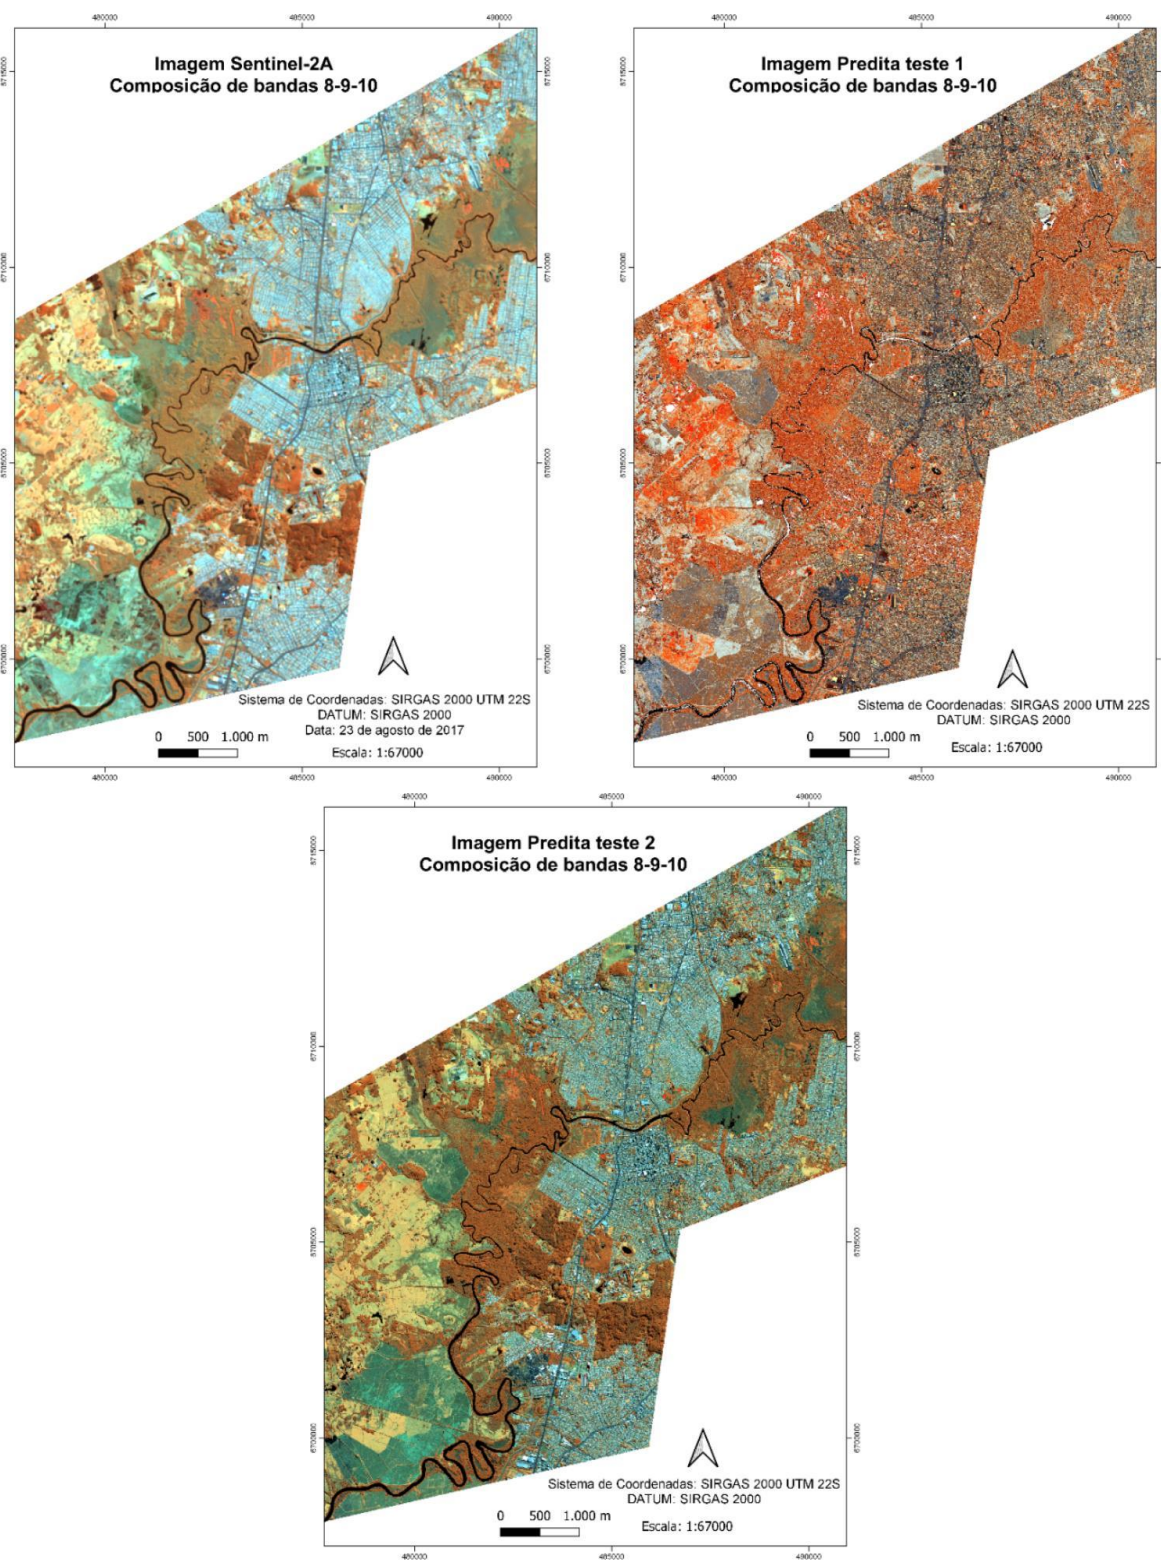

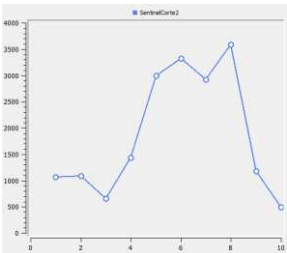
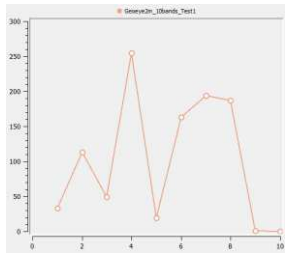
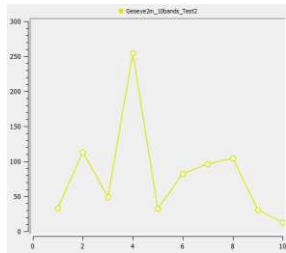

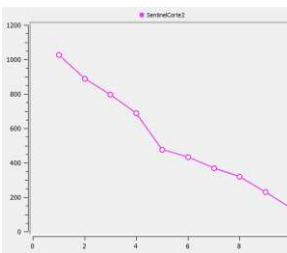
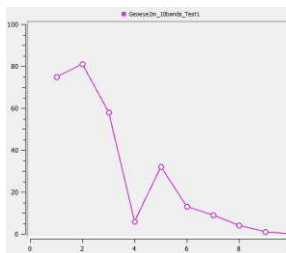
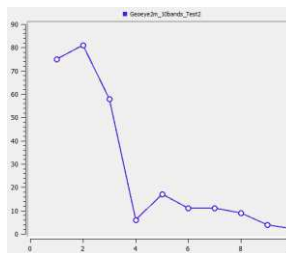
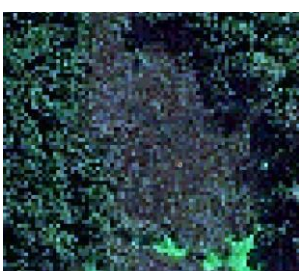
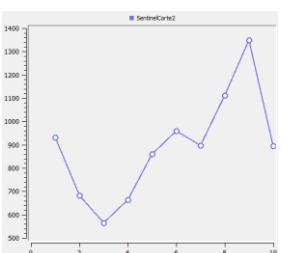
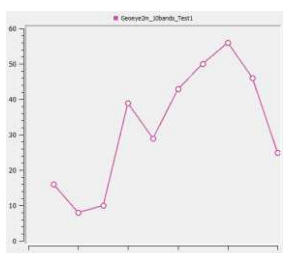
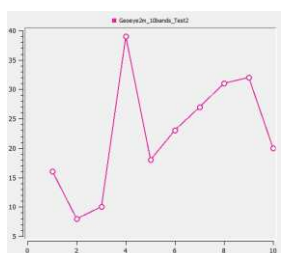


Fig. 5 - Comparação visual da composição de bandas espectrais entre as imagens: a) Sentinel-2A; b) predita no teste 1; e 3) predita no teste 2.

Esta diferença do comportamento espectral da imagem predita no primeiro e no segundo teste em comparação com a imagem Sentinel-2A também pode ser visualizada quando analisada o comportamento espectral de pixels isolados. Foram escolhidos três pixels aleatórios nas imagens de satélite, um em cada classe de maior interesse, sendo AU com macrófitas flutuantes, Água e AU com solo encharcado (Quadro 1).

Quadro 1. Análise do comportamento da curva espectral de um pixel selecionado.

Classe	Sentinel-2 ^a	Predita teste 1	Predita teste 2
AU macrófitas flutuantes 			
Água 			
AU solo encharcado 			

Com base nos gráficos de comportamento da curva espectral dos pixels foi possível verificar que as bandas RGB e NIR apresentam uma assinatura espectral distinta entre a imagem Sentinel-2A e a imagem GeoEye predita no primeiro e no segundo teste. O comportamento espectral das bandas RGB e NIR das duas imagens preditas pela RNA são iguais pois estas quatro bandas são as originais obtidas pelo sensor, sendo a partir da banda 5 as preditas pela RNA.

CLASSIFICAÇÃO DAS IMAGENS

Para realização da primeira etapa da classificação supervisionada foi extraído um perímetro menor de cada imagem, buscando desta forma verificar se de fato o processo de predição de bandas espectrais aprimora a classificação e identificação de AUs. A partir desta classificação piloto foi possível validar qual das imagens preditas apresentou melhor resultado de acurácia, sem a necessidade de classificar as imagens em sua totalidade.

As Tabelas 3, 4 e 5 apresentam a matriz de confusão da classificação de cada perímetro, com seus respectivos valores de acurácia global e índice Kappa. Também são apresentados os valores calculados individualmente de precisão (=acurácia do usuário) e revocação (=acurácia do produtor) para as classes utilizadas.

Tabela 3. Matriz de confusão da classificação do perímetro da imagem Geoeye bruta.

<i>Classes</i>	<i>Água</i>	<i>AU solo encharcado</i>	<i>AU macrófitas aparentes</i>	<i>Vegetação arbórea</i>	<i>Solo exposto</i>	<i>Rizicultura</i>	<i>Campo</i>	<i>Áreas urbanizadas</i>	<i>TOTAL</i>
Água	43	0	0	0	0	0	0	0	43
AU solo encharcado	1	42	0	0	1	0	0	0	44
AU macrófitas aparentes	0	0	44	0	0	0	4	0	48
Vegetação	0	2	0	33	0	1	1	0	37
Solo exposto	0	0	0	0	38	0	0	3	41
Rizicultura	0	0	0	7	0	36	18	0	61
Campo	0	0	1	5	0	8	22	0	36
Áreas urbanizadas	1	1	0	0	6	0	0	42	50
TOTAL	45	45	45	45	45	45	45	45	360
Precisão	100%	95,5%	91,7%	89,2%	92,7%	59%	61,1%	84%	
Revocação	95,6%	93,3%	97,8%	73,3%	84,4%	80%	48,9%	93,3%	
F1 Score	97,7%	94,4%	94,6%	80,5%	88,4%	67,9%	54,3%	88,4%	

Acurácia global = 83,33%

Índice Kappa = 0,81

F1 Score geral = 83,28%

Tabela 4. Matriz de confusão da classificação do perímetro da imagem predita 1.

<i>Classes</i>	<i>Água</i>	<i>AU solo encharcado</i>	<i>AU macrófitas aparentes</i>	<i>Vegetação arbórea</i>	<i>Solo exposto</i>	<i>Rizicultura</i>	<i>Campo</i>	<i>Áreas urbanizadas</i>	<i>TOTAL</i>
Água	40	0	0	0	0	0	0	0	40
AU solo encharcado	0	45	0	0	1	0	0	0	46
AU macrófitas aparentes	0	0	44	0	0	0	0	0	44
Vegetação	0	0	0	43	0	0	0	0	43
Solo exposto	0	0	0	0	38	0	0	2	40
Rizicultura	0	0	0	2	0	35	4	0	41
Campo	0	0	1	0	0	10	41	0	52
Áreas urbanizadas	5	0	0	0	6	0	0	43	54
TOTAL	45	45	45	45	45	45	45	45	360
Precisão	100%	97,8%	100%	100%	95%	85,4%	78,8%	79,6%	
Revocação	88,9%	100%	97,8%	95,6%	84,4%	77,8%	91,1%	95,6%	
F1 Score	94,1%	98,9%	98,9%	97,7%	89,4%	81,4%	84,5%	86,9%	
Acurácia global = 91,39%									
Índice Kappa = 0,90									
F1 Score geral = 91,48%									

Tabela 5. Matriz de confusão da classificação do segmento da imagem predita 2.

<i>Classes</i>	<i>Água</i>	<i>AU solo encharcado</i>	<i>AU macrófitas aparentes</i>	<i>Vegetação arbórea</i>	<i>Solo exposto</i>	<i>Rizicultura</i>	<i>Campo</i>	<i>Áreas urbanizadas</i>	<i>TOTAL</i>
Água	44	0	0	0	0	0	0	0	44
AU solo encharcado	0	43	0	0	1	0	0	0	44
AU macrófitas aparentes	0	0	43	0	0	0	1	0	44
Vegetação	0	0	1	45	0	0	0	0	46
Solo exposto	0	2	0	0	40	0	0	0	42
Rizicultura	0	0	0	0	0	41	8	0	49
Campo	0	0	0	0	0	4	36	0	40
Áreas urbanizadas	1	0	1	0	4	0	0	45	51
TOTAL	45	45	45	45	45	45	45	45	360
Precisão	100%	97,7%	97,7%	97,8%	95,2%	83,7%	90%	88,2%	
Revocação	97,8%	95,6%	95,6%	100%	88,9%	91,1%	80%	100%	
F1 Score	98,9%	96,6%	96,6%	98,9%	92%	87,2%	84,7%	93,8%	
Acurácia global = 93,61%									
Índice Kappa = 0,93									
F1 Score geral = 93,58%									

Através da análise da matriz de confusão de cada perímetro classificado, foi possível aferir que entre as duas imagens preditas, a imagem do teste 2 apresentou maior acurácia global (93,61%) e maior índice Kappa (0,93). Quando comparada a imagem bruta (Acurácia global=83,33%; Kappa=0,81), houve uma melhora de aproximadamente 10% na classificação e delimitação de AUs.

Para melhor visualizar o resultado da classificação, aproximou-se um recorte da área de interesse para verificar as diferenças visuais nas classificações (**Fig. 6**). Em ambas as comparações é possível analisar a classificação em áreas de água (azul), AU com macrófitas flutuantes (verde claro) e AU de solo encharcado (rosa).

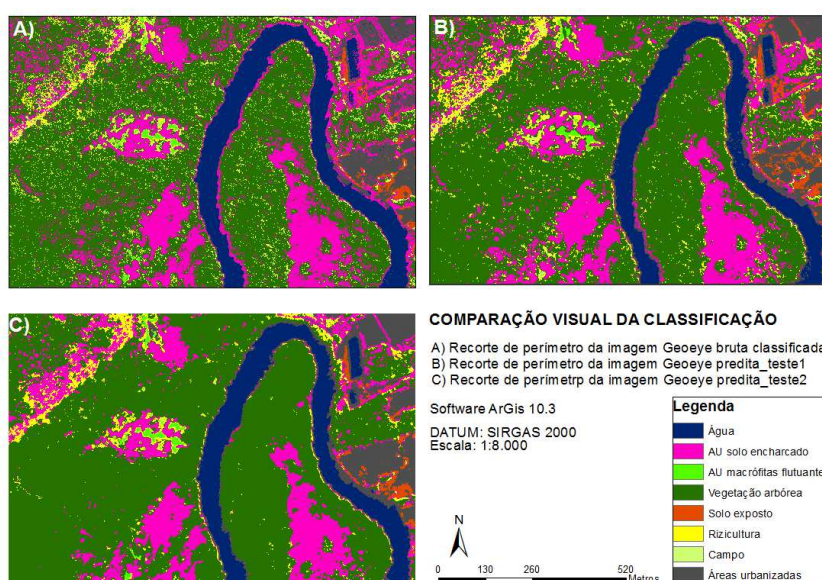


Fig. 6. Comparação visual da classificação realizada em um recorte de perímetro de cada uma das imagens

Além da acurácia global ter sido superior, a imagem predita no segundo teste gerou uma classificação mais uniforme, com menos ruído. É possível verificar que a classificação da imagem predita 2 delimitou com mais homogeneidade as áreas de AUs, diminuindo a confusão entre os pixels classificados.

Sendo assim, optou-se por realizar a classificação total da imagem GeoEye-1 bruta e da imagem predita no teste 2, levando em consideração o tempo de processamento do computador para uma imagem de alta resolução espacial, além das diferenças significativas no comportamento espectral da imagem demonstrado em seção anterior. Na **Fig. 7** são apresentadas as classificações das imagens de satélite em sua totalidade.

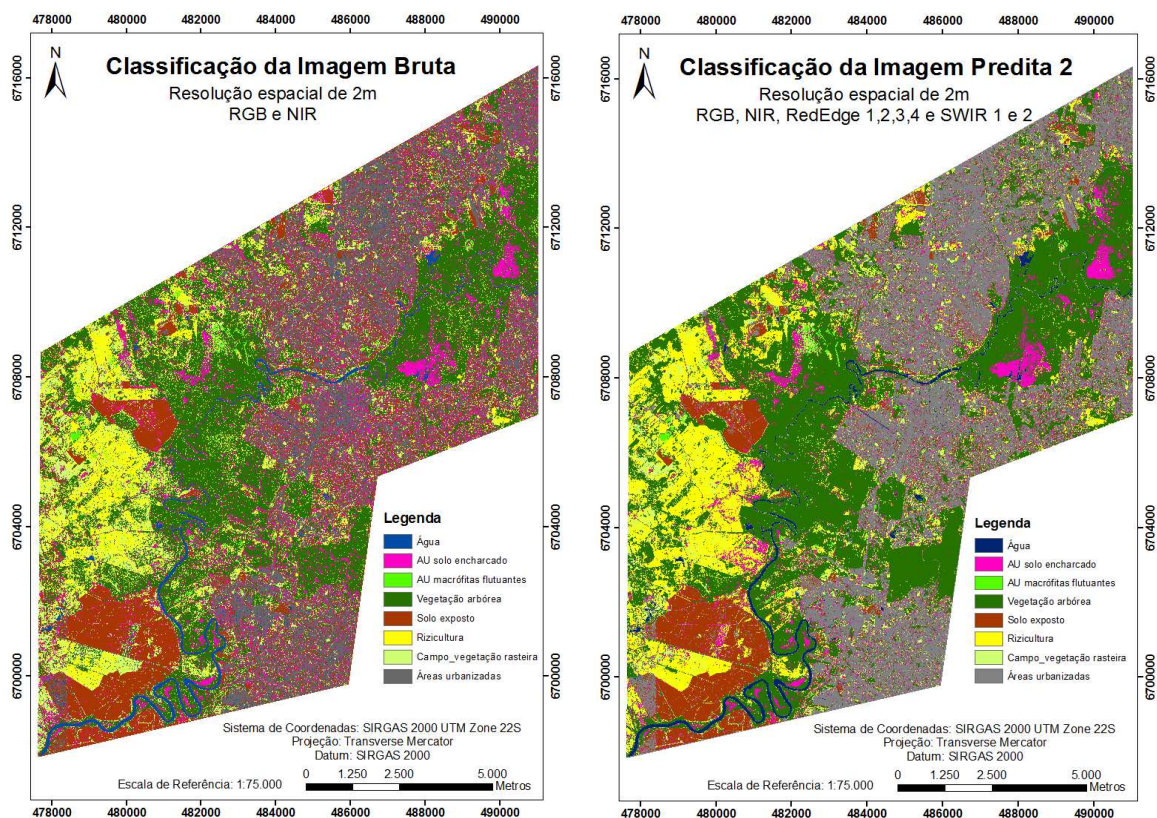


Fig. 7. Resultado da classificação total da imagem GeoEye-1 bruta e imagem predita no teste 2.

Posteriormente, foi realizada uma análise visual em três recortes das classificações geradas nas duas imagens, com o objetivo de avaliar a classificação nas classes de maior interesse, sendo elas água, AU com macrófitas flutuantes e AU com solo encharcado (**Fig. 8 e Fig. 9**).

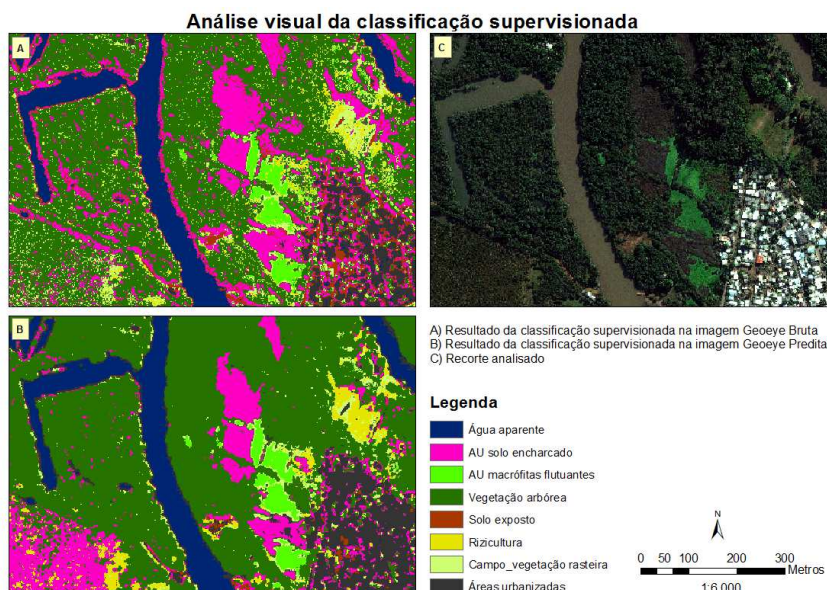


Fig. 8. Análise visual da classificação da imagem GeoEye bruta e da imagem predita no teste 2




Fig. 9. Análise visual da classificação da imagem GeoEye bruta e da imagem predita no teste 2.

As Tabelas 6 e 7 apresentam a matriz de confusão da classificação de cada perímetro, com seus respectivos valores de acurácia global e índice Kappa. Também são apresentados os valores calculados individualmente de precisão (=acurácia do usuário) e revocação (=acurácia do produtor) para as classes utilizadas.

Tabela 6. Matriz de confusão da imagem Geoeye bruta em sua totalidade.

Classes	Água	AU solo encharcado	AU macrófitas flutuantes	Vegetação	Solo exposto	Rizicultura	Campo	Áreas urbanizadas	TOTAL
Água	142	0	0	0	0	0	0	0	142
AU solo encharcado	1	141	0	0	0	0	0	0	142
AU macrófitas flutuantes	0	0	143	1	0	3	9	0	156
Vegetação	0	8	0	144	0	3	4	0	159
Solo exposto	0	0	0	0	150	0	0	21	171
Rizicultura	0	0	3	3	0	104	47	0	157
Campo	0	1	4	2	0	40	90	0	137
Áreas urbanizadas	7	0	0	0	0	0	0	129	136
TOTAL (produtor)	150	150	150	150	150	150	150	150	1200
Precisão	100%	99,3%	91,67%	90,57%	87,72%	66,24%	65,69%	94,85%	
Revocação	94,67%	94%	95,33%	96%	100%	69,33%	60%	86%	
F1 Score	97,26%	96,58%	93,46%	93,2%	93,46%	67,75%	62,72%	90,21%	
Acurácia global = 86,92%									
Índice Kappa = 0,85									
F1 Score geral = 86,83%									

Tabela 7. Matriz de confusão da imagem predita no teste 2 em sua totalidade.

Classe	Água	AU solo encharcado	AU macrófitas flutuantes	Vegetação arbórea	Solo exposto	Rizicultura	Campo	Áreas urbanizadas	TOTAL
Água	142	0	0	0	0	0	0	0	142
AU solo encharcado	0	144	0	0	0	0	0	0	144
AU macrófitas flutuantes	0	0	147	1	0	0	3	0	151
Vegetação arbórea	0	4	0	146	0	0	1	0	151
Solo exposto	0	2	0	0	147	0	0	14	163
Rizicultura	0	0	0	1	0	129	41	0	171
Campo	0	0	3	2	0	21	105	0	131
Áreas urbanizadas	8	0	0	0	3	0	0	136	147
TOTAL produtor	150	150	150	150	150	150	150	150	1200
Precisão	100%	100%	97,35%	96,69%	90,18%	75,44%	80,15%	92,52%	
Revocação	94,67%	96,00%	98%	97,33%	98%	86%	70%	90,67%	
F1 Score	97,26%	97,96%	97,67%	97,01%	93,93%	80,37%	74,73%	91,58%	
Acurácia global = 91,33%									
Índice Kappa = 0,90									
F1 Score geral = 91,32%									

DISCUSSÃO

O desenvolvimento de técnicas para solucionar problemas de resolução espacial e espectral tem sido explorado com maior intensidade nos últimos anos. Este aumento do interesse na geração de imagens hiperespectrais e multiespectrais, com alta resolução espacial e espectral, coincide com os avanços nas técnicas de AM e poder computacional. Além disso, o alto custo de aquisição de imagens de alta resolução espacial e espectral impulsionou a busca por técnicas inovadoras que proporcionem resultados promissores na área de melhoramento das resoluções das imagens de satélite disponíveis.

A RNA utilizada neste estudo foi elaborada e validada por Marques et al. (2020), sendo que no referido trabalho, os autores concluíram que o método gerou resultados semelhantes aos encontrados em outros trabalhos da mesma linha de pesquisa, demonstrando a validade da metodologia proposta como uma alternativa a Redes Neurais Convolucionais (CNN) para reconstrução espectral, sem necessitar de grandes conjuntos de dados para o treinamento, tendo em vista que a RNA proposta possui uma arquitetura mais simples e com mesma eficácia [24].

Conforme apresentado na seção de resultados, o primeiro modelo de rede treinado gerou uma imagem com altos valores de MSE e R^2 para cada banda espectral predita. Deste modo, analisando e comparando apenas os valores das métricas estatísticas, o primeiro modelo seria considerado o que apresenta bandas espectrais preditas com o menor nível de distorção espectral.

Para uma análise mais ampla da imagem predita no primeiro teste, optou-se por observar o comportamento espectral da imagem quando submetida a composições de RGB distintas, ou seja, quando diferentes bandas espectrais eram combinadas. Logo, se constatou que a imagem predita no primeiro teste apresentava uma coloração muito diferente da imagem Sentinel-2A.

A diferença no comportamento espectral da imagem predita no primeiro teste pode estar relacionada ao fato de que o mesmo foi treinado apenas com as bandas espectrais da imagem Sentinel-2A. Teoricamente, o treinamento de uma RNA para fins de predição de bandas espectrais para a melhoria da resolução espectral de outra imagem, deve ser realizado com a mesma imagem de satélite na camada de entrada e na camada de saída.

No entanto, o modelo treinado aprendeu o comportamento espectral das bandas RGB e NIR da imagem Sentinel-2A e no momento que este modelo treinado

foi aplicado a imagem GeoEye-1, que possui bandas espectrais RGB e NIR com comportamento diferente, o modelo pode ter sofrido alguma confusão na predição de bandas. Este comportamento diferente pode estar associado ao fato de que não se tem o conhecimento acerca do pré-processamento da imagem GeoEye-1 adquirida pelo COMITESINOS. As únicas informações recebidas pela empresa responsável pelo fornecimento das imagens é de que as mesmas foram ortoretificadas, mosaicadas e realçadas. Porém, não se obteve a informação de qual realce foi utilizado na imagem, desta forma, o realce utilizado pode ter gerado uma grande diferença entre a imagem GeoEye-1 e a Sentinel-2A.

Neste caso, decidiu-se adaptar a RNA e executar um segundo teste, tendo como camada de entrada as bandas espectrais RGB e NIR da imagem GeoEye-1 e as bandas espectrais do RE e SWIR da imagem Sentinel-2A. Salienta-se ainda que neste segundo teste, para manter a mesma resolução espacial, a imagem GeoEye-1 sofreu uma degradação da sua resolução de 2m para 20m. Após o treinamento do segundo modelo, e aplicação na imagem GeoEye-1, a imagem resultante apresentou um comportamento espectral que manteve um padrão de similaridade com a imagem Sentinel-2A, apresentando resultados próximos ao ideal com distorção espectral mínima.

Após a escolha da melhor imagem predita, foi realizada a classificação supervisionada com o algoritmo ML na área total da imagem, com o objetivo de verificar se a imagem predita do segundo teste realmente melhoraria a classificação de AUs.

De acordo com o estudo de Chasmer et al. (2020), as classificações supervisionadas baseadas em pixels foram muito utilizadas ao longo da história do SR e ainda são utilizadas frequentemente (por exemplo, o método de classificação de ML), apresentando significativo sucesso na classificação de AUs ao longo da história da classificação destes ecossistemas com produtos de SR. De acordo com os autores, a acurácia da classificação supervisionada baseada em pixels para classes de AUs se mantém numa faixa de 75% e 95% [12].

No contexto da classificação das imagens com o uso do algoritmo ML, obteve-se resultados satisfatórios, os quais tiveram aumento da acurácia global e índice Kappa conforme maior quantidade de bandas espectrais na imagem. Nesta lógica, o aspecto da diferença de informação espectral das imagens deve ser observado, além de analisar qual o impacto que a quantidade de bandas espectrais detém sobre a

classificação. Como já mencionado, a imagem GeoEye bruta tem bandas espectrais limitadas (apenas quatro bandas, sendo elas RGB e NIR), limitando assim em certo grau a classificação supervisionada, pelo fato de que a identificação das classes de água, AUs e Vegetação é melhorada com o uso de bandas espectrais do RE e SWIR.

A classificação da imagem GeoEye bruta resultou em uma acurácia global (86,92%) e um índice Kappa (0,85) satisfatórios, porém quando realizadas as análises visuais, a classificação se mostra de forma desuniforme e com maior presença de ruídos na imagem classificada.

Já a imagem predita no segundo teste, a qual possui uma carga de informação espectral superior, pelo fato de possuir dez bandas espectrais (RGB, NIR, RE 1,2,3 e 4 e SWIR 1 e 2), resultou em uma acurácia global de 91,33% e um índice Kappa de 0,90, sendo que tais resultados indicam uma concordância quase que perfeita entre os dados classificados e os dados de referência. Ao analisar a classificação das três classes de maior interesse, água, AU de solo encharcado e AU com macrófitas flutuantes, ambas apresentaram um aumento do índice de precisão (água=100%; AU solo encharcado=100%; AU macrófitas flutuantes=97,35%), bem como um aumento do índice revocação (água=94,97%; AU solo encharcado=96%; AU macrófitas flutuantes=98%) com a adição das bandas espectrais preditas ao conjunto de bandas originais (RGB e NIR). O F1 Score geral, que representa a média harmônica entre a precisão e a revocação, resultou em um valor de 91,32%, afirmando que a acurácia obtida é relevante, sendo os valores de VP, VN, FP, FN aferidos não apresentando grandes distorções.

Levando em consideração o valor de F1 score de cada classe, pode-se concluir que a classe "AU solo encharcado" foi a mais bem classificada, seguida das classes "AU macrófitas flutuantes", "Água", "Vegetação arbórea", "Solo exposto", enquanto as classes "Áreas urbanizadas", "Rizicultura" e "Campo" tiveram as menores precisões e revocações. A maior confusão espectral foi entre as classes de "Rizicultura" e "Campo", podendo ser explicada pela alta similaridade da assinatura espectral da vegetação de campo e a vegetação do plantio de arroz.

A melhoria da resolução espectral da imagem de satélite justifica o aumento da acurácia na classificação de AUs. Quando analisada a classificação da imagem bruta, que contém apenas as bandas RGB e NIR, a classificação se mostra muito mais confusa, no sentido de atribuir maior número de pixels de AUs à outras classes. Ao realizar a análise visual, a classificação da imagem predita no segundo modelo mostra

as classes mais organizadas e uma classificação mais límpida, com menos ruído de outras classes.

Importante destacar que o método utilizado apresenta certa limitação teórica, tendo em vista que não existe uma sobreposição espectral exata entre os canais preditos de menor energia, como SWIR, e os canais RGB de maior energia. Desta forma as bandas preditas não se sobrepõem em sua totalidade, sendo que este erro é propagado ao processo de classificação. Porém, nota-se que na área de estudo deste trabalho (e considerando as classes de interesse de mapeamento), parece existir uma correlação entre as bandas espectrais utilizadas como entrada e saída da rede neural, o que facilitou o processo de predição das bandas. Possíveis erros associados a predição de bandas para alvos ou materiais onde não haja essa correlação espectrais não foram abordados neste trabalho, mas é algo que deve ser considerado em pesquisas futuras.

Além disso, no estudo de Marques Júnior et al. (2020), os autores apresentaram evidências sobre a qualidade esperada nas melhorias de resolução espacial das razões 2, 4, 8, 16 e 32, sendo que a medida que o “salto” da resolução aumenta, a probabilidade de erros crescente concomitante. Para diminuir estes possíveis erros, quando realizado o teste 2 de treinamento da rede, a imagem GeoEye teve sua resolução reamostrada para 20m, justamente para apresentar a mesma resolução da Sentinel-2. Na aplicação do modelo treinado, para diminuir o “salto” da resolução espacial de 40x, optou-se em reamostrar a imagem de 0,5m para 2m, resultando em um “salto” de 20x na resolução.

Outro aspecto importante a ser discutido, é o fato de que a área de estudo está localizada numa planície de inundação. Ou seja, nas épocas de cheia do Rio dos Sinos as áreas de sub-bosque da formação florestal adjacente ao rio são inundadas por água. Porém, com os recursos disponíveis para este estudo, a classificação da imagem fica limitada as assinaturas espectrais das copas das árvores, não realizando uma classificação que adentre a formação vegetal para identificação da presença de água. Neste contexto, sabendo da configuração da área, devem ser considerados estudos futuros que utilizem dados de radar multitemporais como uma adição aos conjuntos de dados apresentados neste estudo.

CONCLUSÕES

O trabalho propôs uma metodologia que permite o aumento da resolução espectral de uma imagem de alta resolução espacial através da predição de bandas espectrais, buscando assim melhorar a classificação de AUs por SR. Este método consistiu na aplicação de uma RNA para prever bandas espectrais de interesse a partir de uma imagem de alta resolução espectral, neste caso uma imagem Sentinel-2A, a qual possui as bandas RE e SWIR que auxiliam na delimitação de AUs.

O estudo mostrou resultados promissores a partir da geração de uma imagem com alta resolução espacial (2m) e mais alta resolução espectral (bandas RGB+NIR+RE 1,2,3 e 4 + SWIR 1 e 2). A RNA utilizada neste estudo também considerou os pixels vizinhos nos *kernels* como estratégia para fornecer mais dados ao processo de predição de único pixel na imagem com maior resolução, no caso, as bandas espectrais geradas. Como informado, a arquitetura da RNA foi validada no trabalho de Marques Júnior et al. (2020), sendo que as alterações realizadas em ambos os testes de treinamento da rede dizem respeito as camadas de entrada e de saída. Como descrito na seção de resultados e discussão, foram realizados dois testes com dados de entrada e saída diferentes.

Após a avaliação dos dados estatísticos e análise visual das imagens preditas em ambos os testes, o segundo teste gerou resultados mais próximos ao ideal com uma distorção espectral mínima, conforme visto na seção de resultados. Sendo assim, a metodologia empregada demonstrou ser uma alternativa viável para predição de bandas espectrais e conseqüentemente geração de imagens com maior resolução espectral, mas sem depender de grandes conjuntos de dados para treinamento.

Assim, como verificado na literatura apresentada, quando se trata de identificação de tipos de AUs através de produtos de SR, a utilização de bandas do NIR, RE e SWIR configuram uma maior acurácia e delimitação das AUs. Neste sentido, a utilização da imagem Sentinel-2A que apresenta uma alta resolução espectral se mostrou eficaz.

Quanto a classificação supervisionada com o uso do algoritmo ML, foi possível confirmar que a predição de bandas espectrais realmente elevou a acurácia na delimitação das AUs do perímetro estudado. A classificação da imagem bruta GeoEye-1 (2m) resultou em uma acurácia global de 86,92%, sendo que a classificação da imagem predita no teste 2 resultou em uma acurácia global de 91,33%. Houve um aumento de aproximadamente 5% da acurácia na delimitação das

AUs a partir da predição de bandas espectrais, com o uso da imagem em sua totalidade. Além disso, a imagem predita apresentou menos ruído visual na classificação, ou seja, mostrou uma menor confusão entre classes com características espectrais similares.

Cabe ressaltar que mesmo a predição de bandas espectrais ter elevado a precisão do algoritmo em delimitar as AUs, ainda assim correm algumas confusões pontuais entre pixels, como por exemplo alguns pixels de AU com macrófitas flutuantes foram confundidos com pixels da classe campo. Isso se deve ao fato de que o comportamento espectral da vegetação é muito semelhante.

A metodologia de predição de bandas espectrais aplicada neste trabalho, embora aqui utilizada como entrada da RNA a imagem Geoeye-1, ou seja, uma imagem com alto custo de aquisição, o mesmo método pode ser extrapolado para outras imagens que não tenham custos e ainda assim tenham uma boa qualidade espacial.

Por fim, é importante frisar que mesmo a imagem predita gerando uma classificação com alta acurácia, a validação das áreas em campo é indispensável, justamente para comprovar os resultados apresentados a partir das metodologias aplicadas. Outrossim, a verificação a campo pode solucionar dúvidas que ocorrem ao longo do processo de interpretação de imagens.

REFERÊNCIAS

1. Fournier RA, Grenier M, Lavoie A, Hélie R. Towards a strategy to implement the Canadian Wetland Inventory using satellite remote sensing. *Canadian Journal of Remote Sensing*. 2007; 33 (sup1):S1–S16.
2. Junk WJ, Piedade MTF, Lourival R, Wittmann F, Kandus P, Lacerda LD, et al. Brazilian wetlands: their definition, delineation, and classification for research, sustainable management, and protection. *Aquatic Conservation: marine and freshwater ecosystems*. 2014;24(1):5–22.
3. da Cunha CN, Piedade MTF, Junk WJ. Classificação e delineamento das áreas úmidas brasileiras e de seus macrohabitats. EdUFMT; 2014.
4. Gallant AL. *The challenges of remote monitoring of wetlands*; 2015.
5. Gomes CS, Junior APM. ÁREAS ÚMIDAS (WETLANDS): panorama e desafios teórico-conceituais.
6. Gardner RC, Finlayson C. Global wetland outlook: state of the World's wetlands and their services to people. In: Ramsar Convention Secretariat; 2018.
7. Davidson NC. How much wetland has the world lost? Long-term and recent trends in global wetland area. *Marine and Freshwater Research*. 2014;65(10):934–941.
8. Junk WJ, Piedade MTF. Áreas Úmidas (AUs) brasileiras: avanços e conquistas recentes. *Boletim da Associação Brasileira de Limnologia*. 2015;41(2):20–24.
9. Maltchik L, Stenert C, Batzer DP. Can rice field management practices contribute to the conservation of species from natural wetlands? Lessons from Brazil. *Basic and applied ecology*. 2017;18:50–56.
10. Dvoretz D, Bidwell J, Davis C, DuBois C. Developing a hydrogeomorphic wetland inventory: reclassifying national wetlands inventory polygons in geographic information systems. *Wetlands*. 2012;32(1):83–93.
11. Rolon A, Maltchik L. Áreas palustres: classificar para proteger. *Ciência Hoje* 2006;38(228):66–70.
12. Chasmer L, Cobbaert D, Mahoney C, Millard K, Peters D, Devito K, et al. Remote sensing of boreal wetlands 1: data use for policy and management. *Remote Sensing*. 2020;12(8):1320.

13. Mahdavi S, Salehi B, Granger J, Amani M, Brisco B, Huang W. Remote sensing for wetland classification: A comprehensive review. *GIScience & Remote Sensing*. 2018;55(5):623–658.
14. Ozesmi SL, Bauer ME. Satellite remote sensing of wetlands. *Wetlands ecology and management*. 2002;10(5):381–402.
15. Schmidt K, Skidmore A. Spectral discrimination of vegetation types in a coastal wetland. *Remote sensing of Environment*. 2003;85(1):92–108.
16. Adam E, Mutanga O, Rugege D. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. *Wetlands Ecology and Management*. 2010;18(3):281–296.
17. Amani M, Salehi B, Mahdavi S, Brisco B. Spectral analysis of wetlands using multi-source optical satellite imagery. *ISPRS journal of photogrammetry and remote sensing*. 2018;144:119–136.
18. Kaplan G, Avdan U. Evaluating the utilization of the red edge and radar bands from sentinel sensors for wetland classification. *Catena*. 2019;178:109–119.
19. Guo M, Li J, Sheng C, Xu J, Wu L. A review of wetland remote sensing. *Sensors*. 2017;17(4):777.
20. Shahdoosti HR, Ghassemian H. Fusion of MS and PAN images preserving spectral quality. *IEEE Geoscience and Remote Sensing Letters*. 2014;12(3):611–615.
21. Meng X, Shen H, Li H, Zhang L, Fu R. Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: Practical discussion and challenges. *Information Fusion*. 2019;46:102–113.
22. Han XH, Shi B, Zheng Y. Ssf-cnn: Spatial and spectral fusion with cnn for hyperspectral image super-resolution. In: 2018 25th IEEE International Conference on Image Processing (ICIP). IEEE; 2018. p. 2506–2510.
23. Marques A, Rossa P, Horota RK, Brum D, De Souza EM, Aires AS, et al. Improving spatial resolution of LANDSAT spectral bands from a single RGB image using artificial neural network. In: 2019 13th International Conference on Sensing Technology (ICST). IEEE; 2019. p. 1–6.
24. Marques Junior A, De Souza EM, Müller M, Brum D, Zanotta DC, Horota RK, et al. Improving Spatial Resolution of Multispectral Rock Outcrop Images Using RGB Data and Artificial Neural Networks. *Sensors*. 2020;20(12):3559.

25. Mei S, Jiang R, Li X, Du Q. Spatial and spectral joint super-resolution using convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*. 2020;58(7):4590–4603.
26. Fleck L, Tavares MHF, Eyng E, Helmann A, Andrade MdM. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*. 2016;1(13):47–57.
27. Carvalho A, Faceli K, Lorena A, Gama J. Inteligência Artificial—uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC. 2011; p. 45.
28. Anschau C. Atlas do Projeto Verdesinos. Editora Anschau, Porto Alegre. 2016; p. 116.
29. FEPAM. Qualidade Ambiental - Região Hidrográfica Do Guaíba; 2021. Available from: <http://www.fepam.rs.gov.br/qualidade/guaiba.asp>. 30. SEMA. G020 - Bacia Hidrográfica do Rio dos Sinos; 2021. Available from: <https://sema.rs.gov.br/g020-bh-sinos>.
30. Bieger L, Carvalho A, Strieder M, Maltchik L, Stenert C. Are the streams of the Sinos River basin of good water quality? Aquatic macroinvertebrates may answer the question. *Brazilian journal of Biology*. 2010;70:1207–1215.
31. ENGESAT. GeoEye; 2021. Available from: <http://www.engesat.com.br/imagem-de-satelite/geoeye/>.
32. Leijnen S, Veen Fv. The neural network zoo. In: *Multidisciplinary Digital Publishing Institute Proceedings*. vol. 47; 2020. p. 9.
33. Ramos MAF. Sistema de identificação e localização de faltas em linhas de transmissão baseado em redes neurais. Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio. <https://www.maxwell.vrac.pucRio.br/colecao.php?strSecao=resultado&nrSeq=3509@1>; 2003.
34. Roberto FP. Geoprocessamento sem complicação. São Paulo: Oficina de Textos. 2008.
35. MORAES, Sofia Royer. Abordagem GEOBIA para a classificação do uso e cobertura da terra em área urbana associadas ao desenvolvimento de framework para monitoramento de inundações no município de Lajeado-RS. Dissertação de Mestrado em Sensoriamento Remoto e Geoprocessamento. Universidade Federal do Rio Grande do Sul. Porto Alegre – RS. 2018.

4. CAPÍTULO IV

Guia de Identificação de Banhados da Bacia Hidrográfica do Rio dos Sinos

(Publicado pela Editora Casa Leiria, em 2021)

PROJETO VERDESINOS — ETAPA 3

GUIA DE IDENTIFICAÇÃO DE BANHADOS

*da Bacia
Hidrográfica do
Rio dos Sinos*





Uwe Horst Schulz
Ana Caroline Ruppenthal
Bruna Peixoto Lovato
Caroline dos Santos Brückmann
Fernanda Gabriela da Silva
Julian Mauhs
Marlon Ferraz
Tiago Closs de Marchi

GUIA DE IDENTIFICAÇÃO DE BANHADOS NA BACIA HIDROGRÁFICA DO RIO DOS SINOS



CASA LEIRIA
SÃO LEOPOLDO
2021

REALIZAÇÃO: PROJETO VERDESINOS – ETAPA 3

ELABORAÇÃO: Universidade do Vale do Rio dos Sinos – UNISINOS

EXECUÇÃO:

Ana Caroline Ruppenthal
Bruna Peixoto Lovato
Caroline dos Santos Brückmann
Fernanda Gabriela da Silva
Julian Mauhs
Marlon Ferraz
Tiago Closs de Marchi

COLABORAÇÃO:

**Fundação Estadual de
Proteção Ambiental Henrique
Luiz Roessler – FEPAM**
Claudia Bos Wolff
Glaucus Vinicius Biasetto Ribeiro
Lilian Waquil Ferraro
Luciana Petry Anele

**Comitê de Gerenciamento da
Bacia Hidrográfica do Rio dos
Sinos – COMITESINOS**

Magali Schmitt
Viviane Nabinger

COORDENAÇÃO TÉCNICA:

Uwe Horst Schulz

**Secretaria do Meio Ambiente
e Infraestrutura - RS**

Luiza Chomenko
Ricardo Aranha Ramos

**Promotoria de Justiça
Regional Ambiental da Bacia
Hidrográfica do Rio dos Sinos**

Ximena Cardozo Ferreira

APOIO:

Movimento Roessler para a Defesa Ambiental
Promotoria de Justiça Regional Ambiental da Bacia Hidrográfica do Rio dos Sinos
Universidade do Vale do Rio dos Sinos – UNISINOS
Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos – COMITESINOS

Ficha catalográfica

G943 Guia de identificação de banhados na bacia hidrográfica do Rio dos Sinos 2020 [recurso eletrônico] / Uwe Horst Schulz... [et. al]. - São Leopoldo: Casa Leiria, 2021. - Projeto Verdesinos, etapa 3.

Disponível em: <<http://www.guaritadigital.com.br/casaleiria/acervo/unisinos/guiabanhados2020/index.html> >

ISBN 978-65-89503-03-3

1. Hidrologia – Rio Grande do Sul. 2. Hidrologia – Rio dos Sinos. 3. Bacias hidrográficas – Rio dos Sinos. I. Schulz, Uwe Horst.

CDU 556(816.5RIO DOS SINOS)

Catálogo na Publicação:
Bibliotecária: Carla Inês Costa dos Santos. - CRB 10/973



SUMÁRIO

Apresentação	7
Introdução	9
O QUE É BANHADO?	10
IMPORTÂNCIA DOS BANHADOS	11
BACIA HIDROGRÁFICA DO RIO DOS SINOS	12
SOBRE OS INDICADORES DE BANHADOS	15
Hidrologia	16
Solo hidromórfico	17
Vegetação	18
FORMAS DE MACRÓFITAS AQUÁTICAS	19
METODOLOGIA PARA LEVANTAMENTO DA VEGETAÇÃO	20
INDICADORES DE VEGETAÇÃO	21
Anexo 1	38
Glossário	39
Referências bibliográficas	40



APRESENTAÇÃO

O Guia dos Banhados é uma ferramenta de apoio técnico desenvolvida através do Projeto VerdeSinos com o objetivo de garantir a integridade das áreas úmidas qualificadas como Áreas de Proteção Permanente — APPs no território da bacia hidrográfica do Rio dos Sinos. Seu conteúdo foi elaborado para oferecer referência científica preliminar à identificação e mapeamento de áreas úmidas na várzea do Rio dos Sinos. Os termos áreas úmidas e banhados são aplicados neste trabalho como conceitos análogos, suplantando o preciosismo que a ciência apregoa. A razão se dá pela urgência e necessidade de preservação das áreas mapeadas nas quais eventuais e distintas especificidades e peculiaridades não invalidam a condição de APP.

A partir da confirmação dos indicadores e evidências que caracterizam esses espaços naturais, será possível traçar e indicar as respectivas coordenadas geográficas

e, assim, estabelecer os limites físicos destas APPs. Esta aferição auxiliará os gestores públicos na tomada de decisão referente aos licenciamentos de empreendimentos nos municípios que compõem a bacia, contribuindo à preservação desses importantes ecossistemas. Caberá ao empreendedor intencionado em ocupar as áreas mapeadas a complementação de estudos que demonstrem o contraditório, através de comprovação técnica elaborada por profissional habilitado. Ao gestor público caberá a avaliação cuidadosa sobre a fundamentação técnica de contestação para a tomada de decisão e licenciamento, se procedente.

O esforço coletivo empenhado nesta publicação, resultado da convergência de esforços e cooperação entre instituições que atuam em prol da revitalização e sustentabilidade da bacia do Sinos, atende ao Programa Gestão de Áreas Protegidas do Plano de Bacia deliberado pelo Comitesinos.





INTRODUÇÃO

No Brasil, existem leis que buscam garantir a preservação de banhados devido à elevada presença de vida aquática e aos serviços ecossistêmicos essenciais que estas áreas proporcionam, não somente ao meio ambiente, como também para a economia e bem-estar da comunidade em geral. Este guia foi elaborado para auxiliar a população a identificar esses banhados.

A função destas áreas também é discutida, juntamente com instruções passo a passo para preenchimento da planilha de indicadores de banhados incluída neste documento.

Este guia será utilizado por colaboradores capacitados previamente. As capacitações serão coordenadas pelo Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos — Comitesinos.

O QUE É BANHADO?

De acordo com Junk et al. (2013) “áreas úmidas (banhados no Rio Grande do Sul) são ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanente ou periodicamente inundados ou com solos encharcados. As águas podem ser doces, salobras ou salgadas, com comunidades de plantas e animais adaptados à sua dinâmica hídrica.”

Os banhados da Bacia Hidrográfica do Rio dos Sinos (BHRS) são de água doce e caracterizados por três fatores principais:



Hidrologia

Período de inundação



Solo

Hidromórfico, formado pelo período de inundação



Vegetação

Comunidade de macrófitas



IMPORTÂNCIA DOS BANHADOS

Os banhados são ecossistemas que abrigam uma diversidade elevada de espécies de plantas e animais, além de sua capacidade de armazenar e filtrar água nos períodos de cheia – garantindo, assim, o reabastecimento dos aquíferos e auxiliando na retenção de água.

Banhados exercem um papel fundamental para a conservação da biodiversidade. A preservação destas áreas deve receber especial atenção, devido aos seus serviços ecossistêmicos.

SERVIÇOS ECOSSISTÊMICOS DOS BANHADOS:

- Armazenamento de água
- Purificação da água
- Recarga do lençol freático
- Retenção de sedimentos
- Diminuição das situações extremas de vazão do rio
- Sítios de reprodução e alimentação de muitas espécies

BACIA HIDROGRÁFICA DO RIO DOS SINOS

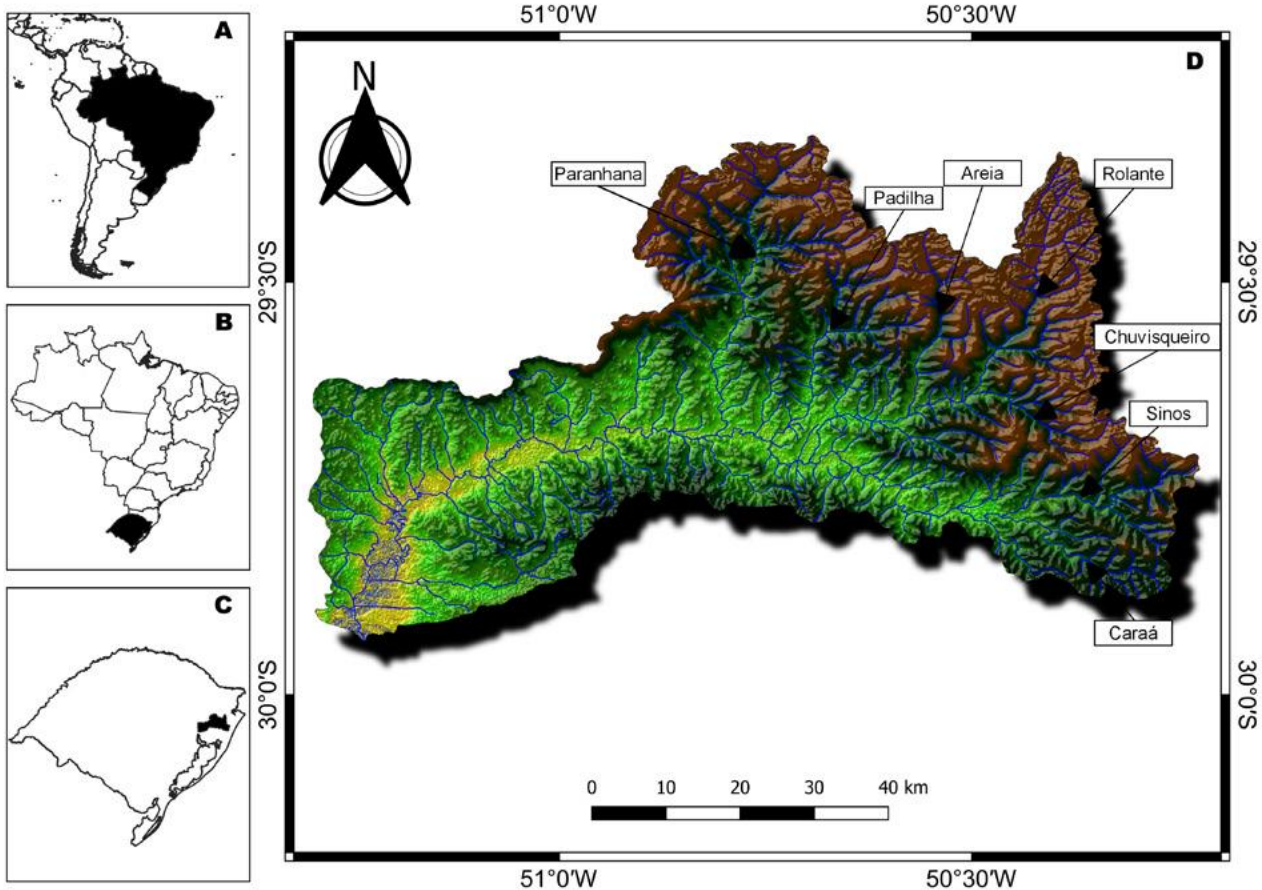
A Bacia Hidrográfica do Rio dos Sinos (BHRS) está localizada na porção leste do Rio Grande do Sul/Brasil. Sua área é de 3.694km², correspondendo a 4,35% da Região Hidrográfica do Guaíba e 1,5% da área total do Estado. É formada por 30 municípios que, em grande maioria, têm seus territórios integralmente inseridos neste divisor hidrogeográfico. A extensão da malha hídrica é de aproximadamente 4.000km, sendo o Rio dos Sinos seu curso d'água principal, com extensão próxima de 190km.

O clima da região é predominantemente subtropical e a precipitação anual média é de 1.600 mm, bem distribuídos nas quatro estações, com temperaturas que variam em torno de 20 graus.

A população da bacia é de aproximadamente 1,44 milhão de habitantes, correspondente a 12% da população do Estado e responsável por 21,2% do PIB gaúcho, fruto de um parque industrial e de uma produção agrícola expressivos. Grande parte dos municípios da bacia integra a região metropolitana de Porto Alegre, a capital do Rio Grande do Sul. Como a maioria das regiões metropolitanas do país, esta foi progressivamente se transformando em um grande corredor de ocupação urbana.

A infraestrutura para atender as demandas do saneamento básico não acompanhou as necessidades da população local — cujo passivo é refletido na qualidade e na quantidade das águas do Rio dos Sinos e de seus formadores.

As áreas alagáveis que acompanham o leito do Rio dos Sinos e os banhados não tiveram seus limites respeitados em muitos casos. Desta forma, enchentes e escassez de água são eventos extremos recorrentes, colocando a vida e a economia da região em permanente risco, além de provocar conflitos entre usuários das águas pela disputa deste recurso natural.



Localização da bacia hidrográfica do Rio dos Sinos.

- **A** – América do Sul;
- **B** – Rio Grande do Sul;
- **C** – Bacia Hidrográfica do Rio dos Sinos;
- **D** – Bacia Hidrográfica do Rio dos Sinos com os principais tributários. As cores escuras indicam as partes mais altas.

A comunidade da bacia tem, no entanto, trabalhado para preservar e, quando necessário, recuperar áreas estratégicas que assegurem a sustentabilidade da bacia hidrográfica. Há um esforço permanente das instituições e setores organizados com atuação na região, empenhados e comprometidos com a execução das ações estabelecidas no Plano de Bacia. Entre estas, encontra-se a delimitação para fins de recuperação e proteção das áreas dos banhados localizados na Bacia Hidrográfica do Rio dos Sinos.



SOBRE OS INDICADORES DE BANHADOS

As informações fornecidas neste guia objetivam auxiliar os colaboradores na identificação de banhados, com a finalidade de garantir a preservação dessas áreas, conforme previsto por normas federais e estaduais (Lei Federal nº 6.938, de 31 de agosto de 1981; Decreto Federal nº 1.905 de 1996; Lei Federal nº 12.651, de 25 de maio de 2012; Decreto Estadual nº 52.431, de 23 de junho de 2015; Resolução CONSEMA nº 380/2018 e Lei Estadual nº 15.434 de 09 de janeiro de 2020).

Cabe lembrar, também, que o Brasil é signatário da Convenção de RAMSAR. Esta convenção, incorporada na legislação brasileira através do decreto nº 1.905/96, promove a conservação das áreas úmidas (banhados) e seu uso sustentável.

Ao final de cada seção o usuário encontrará uma planilha, que deve ser preenchida. Para caracterizar um banhado a área deve atender a três critérios específicos:

- 1** Ser alagada ou inundada periodicamente
- 2** Apresentar solo hidromórfico, que se forma durante o período alagado ou inundado*
- 3** Ter a presença de plantas específicas, adaptadas ao alagamento ou à inundação

Todos os banhados apresentam estas três características.

**Vide glossário*



HIDROLOGIA

O regime hidrológico dos rios reflete o clima de sua bacia hidrográfica. Nas bacias hidrográficas destacam-se as planícies de inundação, onde se encontram as maiores extensões dos banhados, que dependem de pulsos de inundação. Sendo assim, os pulsos de inundação são os principais fatores responsáveis pela existência,

produtividade e interações nestes ecossistemas. Assim, a hidrologia é um fator determinante, uma vez que os banhados precisam ter água presente em alguma época do ano. A área não precisa ter água aparente o tempo todo, mas deve ter água na superfície do solo ou próximo a ela.

SOLO HIDROMÓRFICO

O solo hidromórfico é o solo que em condições naturais se encontra saturado por água, permanentemente ou em determinado período do ano, independentemente de sua drenagem atual e que, em virtude do processo de sua formação, apresenta cores acinzentadas, azuladas ou esverdeadas e/ou cores pretas resultantes do acúmulo de matéria orgânica. A falta de oxigênio desencadeia uma reação química, que é a redução do elemento ferro. A forma reduzida do ferro (Fe^{2+}) pode ser identificada por um indicador químico, que mostra a presença do elemento reduzido em tons de vermelho (Figura 1 A).



Antes da aferição do banhado *in loco* é necessário preparar a solução indicadora. (Vide Anexo 1).




Figura 1. Resultado do teste de campo após 5 min. A cor em tons de vermelho no tubo **A** indica solo hidromórfico. No tubo **B** não há presença de solo hidromórfico.



VEGETAÇÃO

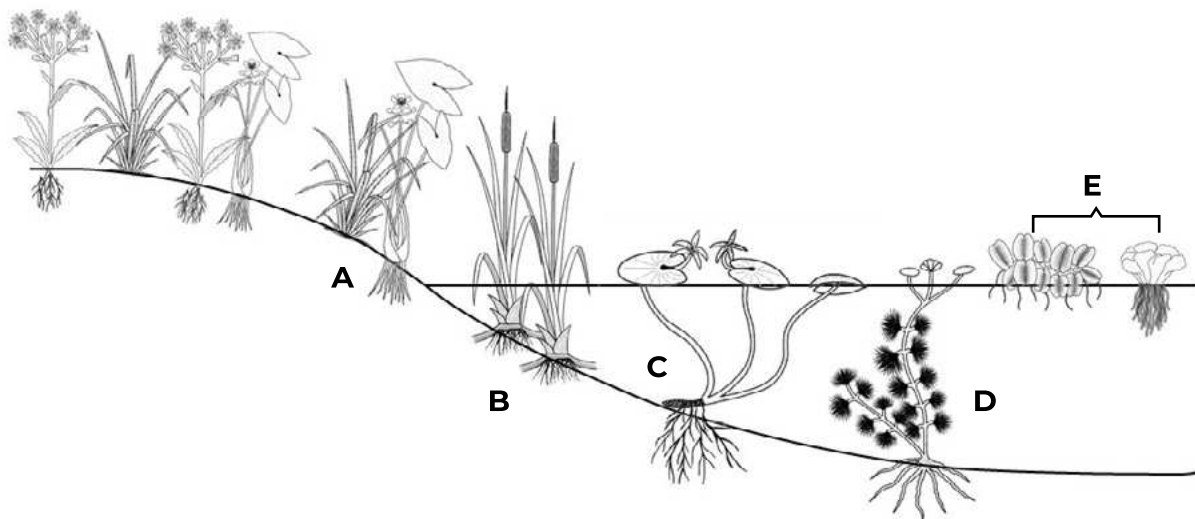
Nos banhados ocorrem plantas chamadas de macrófitas aquáticas, que são espécies vegetais adaptadas a esses ambientes e à dinâmica dos períodos de inundação, sendo, por isso, utilizadas como indicadoras de banhados. Estas plantas desempenham um papel fundamental na dinâmica dos ecossistemas aquáticos, como: alta produtividade primária, estocagem e ciclagem de nutrientes e carbono, habitat para outros organismos, podendo ser também utilizadas na recuperação de ambientes poluídos.

A seguir estão listadas as formas de macrófitas aquáticas e as espécies mais comuns cuja presença, em conjunto com o hidroperíodo e solo hidromórfico, caracterizam o local como um banhado.

FORMAS DE MACRÓFITAS AQUÁTICAS

Apenas certas espécies de plantas podem sobreviver em condições de banhados. Por exemplo, o aguapé (*Eichhornia crassipes*). Outras são mais tolerantes a situações mais secas, como a taboa (*Typha domingensis*).

FIGURA 2 – Grupos ecológicos das macrófitas aquáticas



- A - Anfíbias:** plantas capazes de viver tanto em área alagada como fora da água.
- B - Emergentes:** plantas enraizadas no fundo, parcialmente submersas e parcialmente fora da água.
- C - Flutuantes fixas:** enraizadas no fundo com caule e/ou folhas flutuantes.
- D - Submersas fixas:** enraizadas no fundo, predominantemente submersas.
- E - Flutuantes livres:** não enraizadas no fundo, podendo ser levadas por correntezas, vento ou animais.

METODOLOGIA PARA LEVANTAMENTO DA VEGETAÇÃO

O levantamento da vegetação ocorre através da busca visual das espécies indicadoras de banhados (listadas neste guia), presentes no local amostrado.


Para o levantamento devem ser observados todos os microhabitats do local amostrado.

RECOMENDAÇÃO

Se houver dúvida quando à identificação do espécime vegetal, quando possível, realizar registro fotográfico e/ou a coleta de amostras para identificação em laboratório.



Foto: Sérgio Bordignon



PLANTAS INDICADORAS

Para realizar o levantamento das plantas indicadoras, recomenda-se utilizar as descrições e imagens abaixo apresentadas. Esta seção de vegetação identifica apenas as plantas mais comuns de banhados na Bacia Hidrográfica do Rio dos Sinos.

Quando da execução do levantamento da vegetação, sinalize a presença das espécies ocorrentes no local amostrado. A presença de uma única espécie vegetal listada como indicadora neste Guia, para esta metodologia apresentada, é suficiente para afirmar que a área avaliada é potencialmente um banhado.



Echinodorus grandiflorus

Chapéu-de-couro

(*Echinodorus grandiflorus*)

Família: Alismataceae

Possui grandes folhas, caracterizadas pelas nervuras principais ou transversais, que variam em número, de 7 a 9. Essa planta anfíbia ou emergente tem flores brancas - com uma mancha amarela na base - que podem chegar a 3 cm de diâmetro.



Foto: Eduardo L. Hettwer Giehl

Echinodorus tenellus

(*Echinodorus tenellus*)

Família: Alismataceae

Planta submersa ou anfíbia, encontrada em solos arenosos de banhados ou campos úmidos. Quando se encontra totalmente submersa, sua reprodução é somente vegetativa. Possui flores brancas e a floração ocorre somente quando está emersa, na primavera, verão e outono.



Foto: Ângelo A. Schneider



Foto: Rosângela Gonçalves Rolim



Sagittaria montevidensis

**Aguapé-de-flecha
(*Sagittaria montevidensis*)
Família: Alismataceae**

Espécie submersa ou emergente, encontrada nas margens de rios, banhados, lagos e canais de drenagem. As sementes servem de alimento para aves aquáticas, enquanto caules e flores alimentam roedores. As pétalas de sua flor podem ser brancas ou amareladas, com mancha purpúrea em sua base.

Alternanthera philoxeroides

**Perna-de-saracura, brejo-
d'água, carrapicho-do-
brejo (*Alternanthera
philoxeroides*)
Família: Amaranthaceae**

Submersa, emergente e/ou anfíbia, essa planta possui floração e frutificação durante todo o ano. Cresce em água doce ou locais pantanosos e, também, pode tolerar água salobra. Pode crescer também sobre solos secos modificados.



Foto: Rosângela Gonçalves Rolim



Fotos: Angelo A. Schneider e Rosângela Gonçalves Rolim

Eryngium chamissonis

5 Gravatá ou caraguatá-de-banhados (*Eryngium chamissonis*)
 Família: Apiaceae



As folhas são longas e serreadas, providas de espinhos nas margens. Floresce em glomérulos e sua floração e frutificação ocorrem entre o verão e o outono.

Pistia stratiotes

6 Erva-de-santa-luzia ou marrequinha (*Pistia stratiotes*) Família: Araceae

Planta flutuante livre de águas paradas, cresce flutuando em águas calmas e pode sobreviver semi-enraizada em períodos de pouca água. Possui coloração verde aveludada na parte superior da folha e verde pálida na superfície inferior. Sua inflorescência ocorre no período do verão. Não resiste às baixas temperaturas do inverno.



Fotos: Luciano Rodrigues Soares e Ana Maria Obino Mastella



Foto: Arnildo Pott (Reflora)

Lemna *spp*

Lentilha-da-água
(*Lemna spp.*)

Família: Araceae

Pequena planta flutuante em água parada. Não há registros de floração no estado do Rio Grande do Sul.

Wolffia spp

Lentilha-da-água
(*Wolffia spp.*)

Família: Araceae

Pode ser flutuante livre ou submersa, de acordo com a espécie. Não há registro de floração no estado do Rio Grande do Sul.



Foto: Paulo Robson de Souza (Reflora)



Foto: Luís Funez (Reflora)



Hydrocotyle *ranunculoides*

Cairuçu-do-brejo (*Hydrocotyle ranunculoides*) **Família: Araliaceae**

Essa espécie pode ser encontrada em corpos d'água de todo o RS, na forma emergente ou flutuante. Sua floração e frutificação ocorrem durante a primavera e o verão.



Foto: Mondin, C. A. (Reflora)

Enydra anagallis

(*Enydra anagallis*)
Família: Asteraceae

Encontrada na forma emergente, flutuante, anfíbia, fixa ou submersa, essa planta tem sua floração e frutificação entre a primavera e o verão.

Senecio bonariensis

Margarida-do-banhado
(*Senecio bonariensis*)
Família: Asteraceae

Planta anfíbia ou emergente, que pode ser encontrada em banhados e beira de rios. Se destaca pelo porte e por sua grande inflorescência, apresentando flores brancas e, por vezes, amareladas.



Fotos: João Augusto Bagatini e Marcio Verdi



Cabomba caroliniana

12
Cabomba
(*Cabomba caroliniana*)
Família: Cabombaceae

Planta submersa na água, encontrada em águas paradas ou lentas, em ambientes não muito profundos. Sua frutificação e floração ocorrem no período do verão.

Fotos: Juliana Gonçalves da Silva e Herbarium Anchieta - PACA, UNISINOS

Cyperus giganteus

13
Tiririca ou Palha-cortadeira
(*Cyperus giganteus*)
Família: Cyperaceae

Essa planta pode chegar a 2,5m de altura. Seu caule apresenta nós evidentes verdes, lisos, subcilíndricos, com três quinas na porção superior, e caule de crescimento paralelo ao solo, com raízes. Folhas reduzidas a bainhas membranáceas pardas sem lâmina foliar. São plantas estéreis, com ramos mais longos que o eixo vertical.



Foto: Luciano Rodrigues Soares



Schoenoplectus californicus, Juncus spp.

Junco (Schoenoplectus ssp., Juncus spp.)
Família: Cyperaceae

Abundante em todo o continente americano, especialmente em lagoas, margens de rios e pântanos de água doce. Plantas anfíbias e/ou emergentes em beiras de banhados e rios. Pode chegar até 3m de altura e seu caule apresenta nós evidentes.

Fotos: Marcio Verdi e Christian Linck da Luz

Myriophyllum aquaticum

Pinheirinho-da-água (Myriophyllum aquaticum)
Família: Haloragaceae

São encontradas emergentes ou submersas em todos os tipos de ambiente e sua floração e frutificação ocorrem quase o ano inteiro. Bastante peculiar pela semelhança com o pinheiro. As estruturas reprodutivas ficam expostas quando a planta está em período fértil.



Foto: João Augusto Bagatini



Fotos: Martin Grings | *Utricularia laxa* na imagem

Utricularia *spp.*

**Boca-de-leão-do-
banhado**
(*Utricularia* spp.)

Família: Lentibulariaceae

Essas plantas podem ser encontradas na forma emergente, anfíbia ou flutuante, dependendo da espécie. O gênero tem como característica pequenas bolsas submersas. Sua floração e frutificação ocorrem praticamente o ano todo.

Marsilea *ancylopoda*

(*Marsilea ancylopoda*)
Família: Marsileaceae

A principal característica do gênero são as folhas compostas por dois pares de folíolos, lembrando um trevo de quatro folhas. Geralmente são encontradas em águas rasas paradas ou com suave correnteza, áreas sazonalmente inundáveis, pântanos, lamaçais e lagos.




Foto: Universidade Federal do Paraná - Departamento de Zootecnia <http://www.gege.agrarias.ufpr.br/plantastoxicas/marsilea.htm>



Fotos: Sérgio Bordignon e Milena Fermina Rosenfield

Regnellidium diphyllum

(Regnellidium diphyllum)

Família: Marsileaceae

Essa planta pode ser encontrada na forma emergente, anfíbia ou com folhas flutuantes, em águas paradas e banhados. Sua ocorrência se dá em todo o estado do Rio Grande do Sul.

Nymphoides indica

Soldanela-da-água ou ninféia-rendada (*Nymphoides indica*)

Família: Menyanthaceae

Erva aquática que ocorre em lagos, açudes ou áreas alagadiças. Considerada uma planta emergente, cujas raízes são fixas. As folhas são verdes, flutuantes cordiformes e com ápice arredondado.

As flores, que surgem na primavera e no verão, geralmente apresentam cinco pétalas brancas com base amarela, sendo cobertas por numerosos tricomas.




Foto: Jacques Klein



Foto: Marcio Verdi

Eichhornia crassipes

Aguapé
(*Eichhornia crassipes*)
Família: Pontederiaceae

Planta perene, aquática, flutuante livre. Ocorre nos remansos. É alimento para roedores e habitat para peixes (inclusive como local de desova) e pequenos invertebrados aquáticos. Sua floração e frutificação ocorrem no período do verão.

Pontederia cordata

Rainha-das-lagoas
(*Pontederia cordata*)
Família: Pontederiaceae

Planta emergente. Folhas em roseta, emersas. Flores roxo-azuladas. Folhas ovadas a lanceoladas ou cordadas.



Fotos: Gabriela Hoff Silveira e Luciano Rodrigues Soares



Foto: Angelo A. Schneider

Heteranthera reniformis

Aguapé-mirim
(*Heteranthera reniformis*) Família:
Pontederiaceae



Planta anfíbia ou emergente, com aproximadamente 15 cm de altura e ramos sem pelos. Possui disposição das folhas do tipo alterna, com folhas modificadas na base do pecíolo. Cabos longos e reniformes (em formato de rim) ou cordiformes (em formato de coração) com margens inteiras. Flores com seis tépalas desiguais (internas e externas) e cor variando de branca a levemente azulada.

Potamogeton *spp.*

(*Potamogeton* spp.) Família:
Potamogetonaceae

Plantas desse gênero podem ser encontradas na forma flutuante ou submersa fixa, de acordo com a espécie. Podem ter pequenas flores dispostas em espigas, que se projetam para fora d'água.



Foto: Márcio Verdi – *Potamogeton illinoensis* Morong




Foto: Herbário Vale do São Francisco, UNIVASF

Azolla filiculoides

(Azolla filiculoides)
Família: Salviniaceae

Flutuante livre,
encontrada em águas
calmas. Quando jovem
é verde, posteriormente
se torna parda ou
avermelhada. Por
ser rica em proteínas
serve de alimento para
peixes e aves. Auxilia no
tratamento de efluentes
domésticos.

Salvinia *spp.*

Marrequinha-do-banhado
(Salvinia spp.)
Família: Salviniaceae

Planta aquática flutuante livre, é encontrada em variados corpos d'água. Apresenta três folhas dispostas em cada verticilo, sendo que duas folhas são inteiras e flutuantes e a terceira folha é submersa, coberta de pelos, possuindo função de raiz. Esse gênero se caracteriza por ocupar grandes porções juntando-se entre espécies de mesmo gênero.



Foto: Paulo Schwirkowski (FloraSBS)



Typha domingensis

Taboa (*Typha domingensis*)

Família: Typhaceae

Emergente, perene, rizomatosa e ereta. Floresce na primavera e verão. A parte superior da espiga contém flores masculinas que caem. A inferior é engrossada, de cor castanha, com flores femininas. Fruto com plumas. Sua floração e frutificação ocorrem na primavera e no verão.

Fotos: Teylor Rodrigo Comunello e João Augusto Bagatini

Xyris jupicai

(*Xyris jupicai*)

Família: Xyridaceae

Planta anfíbia ou emergente, que pode ser encontrada em banhados, lagoas e rios. Sua floração ocorre na primavera, no verão e no outono.



Foto: Milena Fermina Rosenfield

PROCEDIMENTOS PARA AFERIÇÃO EM CAMPO

PLANILHA - HIDROLOGIA

Ferramentas que você irá precisar para ir a campo:



Pá de corte ou picareta: usada para cavar buraco para coletar amostra de solo



Câmera fotográfica: registro da situação atual de uso e ocupação das áreas úmidas visitadas



GPS ou aplicativo apropriado de celular: auxilia na demarcação dos pontos visitados e amostrados

1 Indique se há água parada no local em alguma época do ano. Por favor, marque apenas uma caixa. Se não, prossiga para a questão 2.

Sim

Não

2 Nem sempre a água está visível sobre a superfície do solo. Cave um buraco de 30 centímetros de profundidade. Aguarde 10 minutos e veja se está vertendo água.

Sim

Não



Se você respondeu SIM em uma das duas questões, o critério hidrologia foi atendido. Prossiga para a próxima sessão.

PLANILHA - SOLO

3

Cave uma vala de 30 cm de profundidade (ou use a vala da sessão anterior) e retire aproximadamente 1 g de solo com ajuda de uma espátula. Adicione aproximadamente 1 g de amostra de solo em um tubo Falcon com a solução indicadora (2 a 3 ml), agite suavemente, guarde o tubo no bolso e aguarde de 2 a 5 minutos. Se a amostra estiver com uma coloração avermelhada, Fe^{2+} está presente (Figura 1A). Assinale a opção que mais se assemelhar ao seu resultado:

- Coloração rosa ou avermelhada
- Não ficou nem vermelho nem rosa



Se o resultado do teste apresentou uma coloração variando de rosa a vermelho, o critério solo hidromórfico foi atendido. Prossiga para a próxima sessão.

PLANILHA - VEGETAÇÃO

4

Existem plantas aquáticas desta lista na área úmida candidata?
(Marque todas as opções identificadas)

- | | |
|--|--|
| <input type="checkbox"/> 1. Chapéu-de-couro
(<i>Echinodorus grandiflorus</i>) | <input type="checkbox"/> 14. Junco (<i>Schoenoplectus californicus</i> , <i>Juncus spp.</i>) |
| <input type="checkbox"/> 2. <i>Echinodorus tenellus</i> | <input type="checkbox"/> 15. Pinheirinho-da-água
(<i>Myriophyllum aquaticum</i>) |
| <input type="checkbox"/> 3. Aguapé-de-flecha (<i>Sagittaria montevidensis</i>) | <input type="checkbox"/> 16. Boca-de-leão-do-banhado
(<i>Utricularia spp.</i>) |
| <input type="checkbox"/> 4. Perna-de-saracura, brejo-d'água, carrapicho-do-brejo
(<i>Alternanthera philoxeroides</i>) | <input type="checkbox"/> 17. <i>Marsilea ancylopoda</i> |
| <input type="checkbox"/> 5. Gravatá ou caraguatá-de-banhados
(<i>Eryngium chamissonis</i>) | <input type="checkbox"/> 18. <i>Regnellidium diphyllum</i> |
| <input type="checkbox"/> 6. Erva-de-santa-luzia ou marrequinha (<i>Pistia stratiotes</i>) | <input type="checkbox"/> 19. Soldanela-da-água ou ninféia-rendada (<i>Nymphoides indica</i>) |
| <input type="checkbox"/> 7. Lentilha-da-água (<i>Lemna spp.</i>) | <input type="checkbox"/> 20. Aguapé (<i>Eichhornia crassipes</i>) |
| <input type="checkbox"/> 8. Lentilha-da-água (<i>Wolffia spp.</i>) | <input type="checkbox"/> 21. Rainha-das-lagoas
(<i>Pontederia cordata</i>) |
| <input type="checkbox"/> 9. Caiçu-do-brejo
(<i>Hydrocotyle ranunculoides</i>) | <input type="checkbox"/> 22. Aguapé-mirim
(<i>Heteranthera reniformis</i>) |
| <input type="checkbox"/> 10. <i>Enydra anagallis</i> | <input type="checkbox"/> 23. <i>Potamogeton spp.</i> |
| <input type="checkbox"/> 11. Margarida-do-banhado
(<i>Senecio bonariensis</i>) | <input type="checkbox"/> 24. <i>Azolla filiculoides</i> |
| <input type="checkbox"/> 12. Cabomba (<i>Cabomba caroliniana</i>) | <input type="checkbox"/> 25. Marrequinha-do-banhado
(<i>Salvinia spp.</i>) |
| <input type="checkbox"/> 13. Tiririca ou palha-cortadeira
(<i>Cyperus giganteus</i>) | <input type="checkbox"/> 26. Taboa (<i>Typha domingensis</i>) |
| | <input type="checkbox"/> 27. <i>Xyris jupicai</i> |

ANEXO 1

SOLO HIDROMÓRFICO

Durante o período de inundação forma-se solo hidromórfico, pela escassez de oxigênio. Esta falta de oxigênio desencadeia uma reação química, que é a redução do elemento ferro. A forma reduzida do ferro (Fe^{2+}) pode ser identificada por um indicador químico, que mostra a presença de Fe^{2+} em tons de vermelho.

Preparação da solução para imersão de amostras de solo

- 1** Dissolver 0,2 g de α, α' - dipiridil em 25 ml de ácido acético 10%, usando um balão volumétrico de 1 l
- 2** Adicionar 400 ml de água destilada
- 3** Adicionar 77 g de acetato de amônio, dissolver e completar até 1 l com água destilada

Para as amostras, use 2-3 ml desta solução para fazer o teste.

Guarde a solução em um local escuro e fresco (geladeira)

IMPORTANTE

A solução rende 1 litro. Todavia, a quantidade pode ser ajustada proporcionalmente conforme a necessidade específica de cada local.

GLOSSÁRIO

Alagamento: acúmulo momentâneo de águas em determinados locais por deficiência no sistema de drenagem.

Área úmida: vide banhado.

Bacia Hidrográfica: conjunto de terras drenadas por um corpo d'água principal e seus afluentes. Representa a unidade mais apropriada para o estudo qualitativo e quantitativo do recurso água e dos fluxos de sedimentos e nutrientes.

Banhado: caracteriza-se pelo período de inundação, que deve ser longo o suficiente para o desenvolvimento de solos hidromórficos e para o desenvolvimento de organismos aquáticos. Possui alta diversidade biológica e produtividade, oferecendo benefícios à população, como a minimização do impacto em caso de inundações, purificação da água e a recarga de aquífero. São locais estratégicos de conservação.

Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos

(COMITESINOS): organismo oficial com atribuições no Sistema Estadual de Recursos Hídricos do Rio Grande do Sul. Formado por representantes de usuários da água, da população e dos órgãos da administração direta.

Hidrologia: ciência que estuda a água sobre a Terra, suas propriedades, ocorrência, distribuição, circulação e ainda seus efeitos sobre o meio ambiente e a vida.

Hidroperíodo: ocorrência periódica ou regular de inundação ou saturação do solo em

função do balanço hídrico, da topografia e das condições subsuperficiais.

Inundação: transbordamento das águas de um curso d'água, atingindo a planície de inundação ou área de várzea.

Macrófitas aquáticas: vegetação visível, cujas partes ativas responsáveis pela fotossíntese estão por diversos meses ou permanentemente, total ou parcialmente submersas ou flutuantes em água doce ou salobra.

Oxidação – redução de ferro (Fe): em solo seco o elemento Fe ocorre normalmente na forma oxidada (Fe^{3+}). Quando ocorre uma enchente, o solo é desprivado do contato com o ar e a concentração de oxigênio cai. Nesta situação ocorre a redução do Fe^{3+} em Fe^{2+} . Fe^{2+} é a forma reduzida do elemento Fe, indicando solo hidromórfico.

Serviços ecossistêmicos: qualquer processo natural benéfico decorrente de ecossistemas saudáveis, como purificação da água e do ar, polinização de plantas e decomposição de resíduos.

Solo hidromórfico: é o solo que em condições naturais se encontra saturado por água, permanente ou em determinado período do ano, independente da sua drenagem atual e que, em virtude do processo de sua formação, apresenta comumente, dentro de 50 (cinquenta) centímetros a partir da superfície, cores acinzentadas, azuladas ou esverdeadas e/ou cores pretas resultantes do acúmulo de matéria orgânica.

REFERÊNCIAS BIBLIOGRÁFICAS

ANSCHAU, Carla. Atlas do Projeto Verdesinos. Editora Anschau, Porto Alegre, p. 116, 2016.

BOVE, Cláudia Petean; PAZ, Josele. Guia de campo das plantas aquáticas do Parque Nacional da Restinga de Jurubatiba, Rio de Janeiro, Brasil. Museu Nacional, 2009.

CHILDS, C. W. Field tests for ferrous iron and ferric- organic complexes (on exchange sites or in water- soluble forms) in soils. Soil Research, v. 19, n. 2, p. 175- 180, 1981.

COMITESINOS – Comitê de Gerenciamento da Bacia Hidrográfica do Rio dos Sinos, 2009. Disponível em: < [http:// www. comitesinos. com. br/ bacia- hidrografica- do- rio- dos- sinos](http://www.comitesinos.com.br/bacia-hidrografica-do-rio-dos-sinos)>. Acesso em: 03 dez de 2019.

CORDAZZO, C. V.; SEELIGER, U. Guia ilustrado da vegetação costeira no extremo sul do Brasil. Rio Grande: FURG, 1995.

GUIMARÃES, M. G. Q.; MOREIRA, A. D. R.; BOVE, C. P. Flora do Rio de Janeiro: Pontederiaceae. Rodriguésia, v. 68, n. 1, p. 103- 108, 2017.

HEFLER, S. M.; LONGHI- WAGNER, H. M. Cyperus L. subg. Cyperus (Cyperaceae) na Região Sul do Brasil. Revista Brasileira de Biociências, v. 10, n. 3, p. 327, 2012.

IRGANG, B. E.; Gastal Jr., C. V. S. Macrófitas Aquáticas da Planície Costeira do RS. Porto Alegre: UFRGS, 1996.

JUNK, Wolfgang. J. et al. Brazilian wetlands: their definition, delineation, and classification for research, sustainable management, and protection. Aquatic Conservation: Marine and Freshwater Ecosystems, v. 24, n. 1, p. 5- 22, 2013.

LICCO, E. A.; MAC DOWELL, S. F. Alagamentos, Enchentes Enxurradas e Inundações: Digressões sobre seus impactos sócio econômicos e governança. Área de Pesquisa em Sustentabilidade Centro Universitário Senac, 2015.

MALTCHIK, L. Biodiversidade E Conservação De Áreas Úmidas Da Bacia Do Rio Dos Sinos. Editora Unisinos. 2003

MOTTA MARQUES, D. M. L.; IRGANG, B.; GIOVANNINI, S. G. T. A importância do hidroperíodo no gerenciamento de água em terras úmidas (wetlands) com uso múltiplo– o caso da Estação Ecológica do Taim. Anais do XII Simpósio Brasileiro de Recursos Hídricos, Vitória (ES), p. 1- 8, 1997.

PIRES, J. S.; SANTOS, J. E.; DEL PRETTE, M. E. A utilização do conceito de bacia hidrográfica para a conservação dos recursos naturais. In: SCHIAVETTI, A.; CAMARGO, A. F. M. (Eds.) Conceitos de bacias hidrográficas: teorias e aplicações. Ilhéus, BA: Editus, 2002.

SANCHES, A. L.; CERVI, ARMANDO CARLOS.; POTT, V. J. Levantamento taxonômico de Pontederiaceae Kunth do Pantanal, nos estados de Mato Grosso e Mato Grosso do Sul, Brasil. III Simpósio sobre Recursos Naturais e Sócio- econômicos do Pantanal: os desafios do novo milênio, Cuiabá/ MS. 31p, 2000.

SCHÄEFER, A. E.; ONZI, A. C. Lagoas Costeiras 3 - Caderno Ambiental Escolar: Conhecendo a Biodiversidade do Município de Osório. Caxias do Sul: Educs, 2016.

SKALSKI, J. et al. Ingestão voluntária de *Marsilea ancylopoda* por equinos em área de pastagem. Revista Acadêmica Ciência Animal, v. 14, p. 13- 18, 2016.

TRINDADE, C. R. T. et al. Caracterização e importância das macrófitas aquáticas com ênfase nos ambientes límnicos do campus carreiros. Cadernos de Ecologia Aquática. Vol 5 N° 2. Ago – dez 2010

PROJETO VERDESINOS — ETAPA 3

GUIA DE IDENTIFICAÇÃO DE BANHADOS

da Bacia Hidrográfica do Rio dos Sinos

REALIZAÇÃO



COORDENAÇÃO GERAL



EXECUÇÃO



APOIO





GUIA DE IDENTIFICAÇÃO DE BANHADOS

da Bacia Hidrográfica do Rio dos Sinos



ISBN 978-65-89503-03-3

