



**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
MESTRADO EM MEIO AMBIENTE E  
DESENVOLVIMENTO REGIONAL**

**MARIANY KERRIANY GONÇALVES DE SOUZA**

**MAPEAMENTO DE RIOS EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL  
USANDO ALGORITMOS DE APRENDIZAGEM DE MÁQUINA**

Presidente Prudente - SP  
2022

**MARIANY KERRIANY GONÇALVES DE SOUZA**

**MAPEAMENTO DE RIOS EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL  
USANDO ALGORITMOS DE APRENDIZAGEM DE MÁQUINA**

Dissertação de Mestrado apresentada à Pró-reitora de Pesquisa e Pós-Graduação como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Desenvolvimento Regional (MMADRE). Área de Concentração: Ciências Ambientais.

Linha II: Planejamento Ambiental e Desenvolvimento Regional

**Orientadora:** Prof<sup>a</sup>. Dr<sup>a</sup>. Ana Paula Marques Ramos.

**Co-orientador:** Dr. Danillo R. Pereira

**Colaboradores:** Dr. Lucas Prado Osco

0000

Souza, Mariany Kerriany Gonçalves de.

000

Mapeamento de rios em imagens de alta resolução espacial usando algoritmos de aprendizagem de máquina / Mariany Kerriany Gonçalves de Souza. – Presidente Prudente, 2022.

(31)f.: il.

Dissertação (Mestrado em Meio Ambiente e Desenvolvimento Regional) - Universidade do Oeste Paulista – Unoeste, Presidente Prudente, SP, 2022.

Bibliografia.

Orientador: Profª Drª. Ana Pala Marques Ramos.

1. Imagens RGB. 2. Aprendizagem de Máquina. 3. Inteligência Artificial. I. Título.

**MARIANY KERRIANY GONÇALVES DE SOUZA**

**MAPEAMENTO DE RIOS EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL  
USANDO ALGORITMOS DE APRENDIZAGEM DE MÁQUINA**

Dissertação de mestrado apresentada à Pró-reitora de Pesquisa e Pós-Graduação como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Desenvolvimento Regional (MMADRE). Área de Concentração: Ciências Ambientais.  
Linha II: Planejamento Ambiental e Desenvolvimento Regional

Presidente Prudente, 23 de fevereiro de 2022.

**BANCA EXAMINADORA**

---

Prof. Dr. Ana Paula Marques Ramos  
Universidade do Oeste Paulista (UNOESTE)  
Presidente Prudente – SP

---

Prof. Dr. José Marcato Junior  
Universidade Federal do Mato Grosso do Sul (UFMS)  
Campo Grande – MS

---

Prof. Dr. Marcelo Rodrigo Alves  
Universidade do Oeste Paulista (UNOESTE)  
Presidente Prudente – SP.

## DEDICATÓRIA

Dedico este trabalho à Deus, meu guia, que sempre me deu forças e nunca me deixou desanimar.

A minha família, minha mãe e minha irmã, que sempre me apoiaram e torceram por mim.

Ao meu amado esposo, companheiro de vida, que sempre me deu forças e coragem para nunca desistir.

## **AGRADECIMENTOS**

Primeiramente à Deus que, com todo amor por mim, sempre esteve comigo me abençoando durante esta longa caminhada.

Em especial, agradeço a professora Dr. Ana Paula Marques Ramos, por acreditar que eu era capaz. Só tenho a agradecer de coração pelos seus ensinamentos, orientações, palavras de incentivo, paciência e dedicação. Tenho muito orgulho em dizer que um dia fui sua orientada. Um exemplo como pessoa e pesquisadora. Tem toda a minha admiração!

À banca, professor Dr. Marcelo Rodrigo Alves e ao professor Dr. José Marcato Junior, agradeço pelas contribuições que aprimoraram e enriqueceram este trabalho.

Aos prezados professores do PPGMADRE, pelos ensinamentos e embasamento teóricos e práticos.

Aos queridos amigos do NEAGEO e do grupo de estudos Gi3A, que sempre estiveram presentes compartilhando e colaborando com o andamento do trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – (Brasil) CAPES – Código de Financiamento 001, pela bolsa de estudo concedida, por viabilizar a oportunidade de realizar este sonho.

Por fim, a todos que acompanharam meu percurso colaborando de alguma forma ao longo dos últimos anos eu deixo uma palavra sincera de gratidão.

*"Dê-me, Senhor, agudeza para entender, capacidade para reter, método e faculdade para aprender, sutileza para interpretar, graça e abundância para falar. Dê-me, Senhor, acerto ao começar, direção ao progredir e perfeição ao concluir." (São Tomás de Aquino)*

## RESUMO

### **Mapeamento de rios em imagens de alta resolução espacial usando algoritmos de aprendizagem de máquina**

A proteção das águas é um problema de interesse de diversos órgãos ambientais dentro do Pontal do Paranapanema. Neste estudo foi realizada uma abordagem de classificação e segmentação de rios em imagens de alta resolução espacial baseada em algoritmos rasos de aprendizagem de máquina. Composta por quatro etapas: (1) vetorização de rios em imagens de alta resolução espacial; (2) segmentação das imagens e treinamento dos algoritmos rasos de aprendizagem de máquina; (3) teste dos algoritmos na segmentação dos rios nas imagens RGB; (4) descrição qualitativa dos cursos d'água. A área de estudo de caso é a região pertencente à 22ª Unidade de Gerenciamento de Recursos Hídricos do Pontal do Paranapanema (UGRHI-22), na qual estão inseridos 26 municípios do oeste do estado de São Paulo. As imagens utilizadas são ortofotografias RGB de alta resolução espacial (1 m) provenientes do projeto Mapeia-SP. Para compor os dados de treinamento e teste, organizou-se um banco de dados geográficos no SIG ESRI ArcGIS Pro 2.8. Na sequência, fizemos a classificação de interesse (rios x não rio) nessas imagens. Um total de 04 ortofotos compuseram o estudo de caso inicial. Verificou-se o desempenho dos algoritmos Random Forest (RF), com diferentes métricas de avaliação, e o Support Vector Machine (SVM), ambos aplicados sobre as imagens RGB segmentadas pelo método Mean Shift. Os resultados de desempenho, analisados a partir das métricas de validação da acurácia (90%), como F1-Score (91%), Recall (99%) e Precision (85%), demonstraram que o SVM apresenta os melhores valores. Obteve-se métricas acima de 90% nos dados de teste em termos de F1-measure. Esses resultados foram utilizados em somente 04 imagens, no qual demonstram a capacidade dos algoritmos rasos, como o SVM, em realizar o mapeamento de feições em imagens com alto nível de detalhe. Os produtos cartográficos que se pode gerar a partir do emprego dessas metodologias pautadas em inteligência artificial podem apoiar diversos estudos ao que tange às tarefas de planejamento e monitoramento ambiental e análise de impacto ambiental relacionada à proteção dos cursos d'água.

**Palavras-chave:** Support Vector Machine; Random Forest; Aprendizagem de máquina.

## **ABSTRACT**

### **River mapping in high spatial resolution images using machine learning algorithms.**

Water protection is a problem of interest to several environmental agencies within Pontal do Paranapanema. In this study, an approach for classifying and segmenting rivers in high spatial resolution images based on shallow machine learning algorithms was carried out. Composed of four steps: (1) vectorization of rivers in high spatial resolution images; (2) image segmentation and training of shallow machine learning algorithms; (3) testing the algorithms in the segmentation of the rivers in the RGB images; (4) qualitative description of water courses. The case study area is the region belonging to the 22nd Water Resources Management Unit of Pontal do Paranapanema (UGRHI-22), which includes 26 municipalities in the west of the state of São Paulo. The images used are RGB orthophotographs of high spatial resolution (1 m) from the Mapeia-SP project. To compose the training and test data, a geographic database was organized in GIS ESRI ArcGIS Pro 2.8. Next, we made the classification of interest (rivers x non-river) in these images. A total of 04 orthophotos composed the initial case study. The performance of the Random Forest algorithms was verified, with different evaluation metrics, and the Support Vector Machine (SVM), both applied on RGB images segmented by the Mean Shift method. The performance results, analyzed from the validation metrics of accuracy (90%), such as F1-Score (91%), Recall (99%) and Precision (85%), showed that the SVM presents the best values. Metrics above 90% were obtained in the test data in terms of F1-measure. The Random Forest (RF) input parameters were also tested and showed that the highest regularization parameter obtained a result of 90%. These results were obtained from only 04 images, which demonstrate the ability of shallow algorithms, such as SVM, to perform the mapping and segmentation of rivers in images with a high level of detail. The cartographic products that can be generated from the use of these methodologies based on artificial intelligence can support several studies regarding environmental planning and monitoring tasks and environmental impact analysis related to the protection of water courses.

**Keywords:** Support Vector Machine; Random Forest; Machine Learning.

## LISTA DE SIGLAS

CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior  
PPGMADRE – Programa de Pós Graduação em Meio Ambiente e Desenvolvimento Regional  
UNOESTE - Universidade do Oeste Paulista.  
PROINTER - Programa de Pesquisa Interdisciplinar  
UGRHI – Unidade de Gerenciamento de Recursos Hídricos  
NDWI - Índice de Água por Diferença Normalizada  
IA – Inteligência Artificial  
ML – Machine Learning  
RF - Random Forest  
DT – Decision Tree  
SVM – Support Vector Machine  
GSD - Ground Sample Distance  
UTM - Universal Transversa de Mercator  
SIG – Sistema de Informação Geográfica  
LULC – Uso e Cobertura da Terra  
RBF – Função de Base Radial  
CBH-PP - Comitê de Bacias Hidrográficas do Pontal do Paranapanema  
ANA - Agência Nacional de Águas e Saneamento Básico  
MMA - Ministério do Meio Ambiente  
CONAMA - Conselho Nacional do Meio Ambiente  
IBAMA - Instituto Brasileiro do Meio Ambiente e dos Recursos Renováveis  
SRM - Minimização de Risco Estrutural  
ERM - Minimização de Risco Empírico  
ACC – Acurácia  
VC - Vapnik-Chervonenkis  
UHE - Usina hidrelétrica

## LISTA DE FIGURAS

Figura 1. Fluxo de trabalho descrevendo as principais etapas. ....	18
Figura 2. Ortofotos da área de estudo localizadas dentro da UGRHI 22 e seus cursos d'água.....	20
Figura 3. Ortofoto com aplicação do buffer de 50 metros.....	21
Figura 4. Segmentação da Ortofoto (sf-22-y-a-vi-1-no) pelo método MeanShift.....	22
Figura 5. Resultado qualitativo do Random Forest nos dados de treino.....	23
Figura 6. Distribuição dos pontos para classificação nos dados de teste .....	24
Figura 7. Matriz de Confusão.....	24
Figura 8. Resultado das Classificações das imagens de cada algoritmo.....	27
Figura 9. Análise falsos positivos.....	27

## LISTA DE TABELAS

Tabela 1. Informações referente às 4 ortofotos utilizadas neste estudo .....	22
Tabela 2. Performance dos modelos nos dados de treino.....	26
Tabela 3. Performance dos modelos nos dados de testes... ..	26

## SUMÁRIO

<b>1 CONSIDERAÇÕES INICIAIS.....</b>	<b>14</b>
<b>2 MANUSCRITO.....</b>	<b>15</b>
INTRODUÇÃO.....	16
MATERIAIS E MÉTODOS .....	18
RESULTADOS E DISCUSSÃO .....	25
CONCLUSÃO .....	28
REFERÊNCIAS .....	29
<b>3 CONSIDERAÇÕES FINAIS.....</b>	<b>31</b>

## 1 CONSIDERAÇÕES INICIAIS

Este documento está organizado em três seções. A primeira seção consiste no contexto geral da presente pesquisa que é promovida pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e desenvolvida no Programa de Pós-Graduação em Meio Ambiente e Desenvolvimento Regional (PPGMADRE) da Universidade do Oeste Paulista (UNOESTE). A segunda seção consiste em um manuscrito que discute a capacidade de mapear rios usando imagens de alta resolução espacial, a partir de um banco de dados rotulados no qual foram avaliadas as métricas de classificação de imagem estimados por algoritmos de aprendizagem de máquina. A terceira seção apresenta considerações sobre o desenvolvimento deste trabalho.

O PPGMADRE é composto por duas linhas de pesquisa: Avaliação e análise de impactos ambientais; e Planejamento ambiental e desenvolvimento regional, que se enquadra no presente trabalho. O programa é interdisciplinar e conecta as questões ambientais ao desenvolvimento regional. As linhas de pesquisa atuam em um Programa de Pesquisa Interdisciplinar denominado PROINTER.

Este relatório compõe o documento para a realização de defesa do mestrado, no qual se discute o desempenho de mapeamento de rios e a sua classificação aplicada em imagens RGB de alta resolução espacial baseada em algoritmos de aprendizagem de máquina. Essas imagens estão disponíveis no banco de dados gratuito do Projeto Mapeia São Paulo, de 2011. O estudo oferece suporte aos estudos de planejamento ambiental e análise de impacto ambiental relacionados aos cursos d'água da 22ª Unidade de Gerenciamento de Recursos Hídricos do Pontal do Paranapanema - São Paulo. Isso atesta a proposta do PPGMADRE de discutir o processo de desenvolvimento regional frente às questões ambientais.

## 2 MANUSCRITO

### RESUMO

#### MAPEAMENTO DE RIOS EM IMAGENS DE ALTA RESOLUÇÃO ESPACIAL USANDO ALGORITMOS DE APRENDIZAGEM DE MÁQUINA.

A qualidade dos cursos d'água são muitas vezes influenciadas por ações antrópicas, tal como atividades agrícolas e socioeconômicas em torno desses recursos. O mapeamento desses cursos d'água é uma medida essencial para desenvolver atividades de proteção ambiental. Esse trabalho tem por objetivo segmentar rios em imagens RGB de alta resolução espacial com algoritmos rasos de aprendizagem de máquina (Machine Learning), na 22ª Unidade de Gerenciamento de Recursos Hídricos do Pontal do Paranapanema - São Paulo. Nesse trabalho verificou-se o desempenho de técnicas de machine learning (ML) em mapear cursos d'água em imagens aéreas multiespectrais com superposição das bandas associada as cores RGB. Essas imagens de 01 metro de resolução espacial, foram coletadas pelo projeto Mapeia São Paulo, em 2011. Fez-se a rotulação nessas imagens usando ambiente de sistema de informação geográfica das feições de rios, dividindo-as em subconjuntos de treinamento e teste. Os resultados, foram avaliados usando métricas como Acurácia Global, Medida F1 (F1-score), Precisão e Recall, que demonstrou que o algoritmo Support Vector Machine (SVM) tem maior capacidade em mapear rios com alta acurácia (média superior a 90%) comparado ao Random Forest (RF). Pelos resultados quantitativos, notou-se que a média do F1-Score, tanto para o conjunto de treinamento quanto de teste, foi superior a 90% no caso do algoritmo Support Vector Machine (SVM), se mostrou melhor comparado aos resultados do Random Forest (RF). A abordagem de segmentação com aprendizagem de máquina rasa mostrou ter potencial em mapear rios em imagens RGB. Porém, o estudo de caso considerou somente rios largos.

**Palavras-chave:** imagens RGB; aprendizagem de máquina; inteligência artificial.

### ABSTRACT

#### RIVER MAPPING IN HIGH SPATIAL RESOLUTION IMAGES USING MACHINE LEARNING ALGORITHMS.

The quality of water courses are often influenced by human actions, such as agricultural and socioeconomic activities around these resources. The mapping of these watercourses is an essential measure to develop environmental protection activities. This work aims to segment rivers in special high resolution RGB images with shallow machine learning algorithms (Machine Learning), at the 22nd Water Resources Management Unit of Pontal do Paranapanema - São Paulo. In this work, the performance of machine learning (ML) techniques was verified in mapping watercourses in multispectral aerial images with superposition of bands associated with RGB colors. These images of 01 meter of spatial resolution were collected by the Mapeia São Paulo project, in 2011. These images were labeled using the geographic information system environment of the river features, dividing them into training and test subsets. The results were evaluated using metrics such as Global Accuracy, F1 Measure (F1-score), Precision and Recall, which demonstrated that the Support Vector Machine (SVM) algorithm has greater ability to map rivers with high accuracy (average greater than 90%). compared to Random Forest (RF). From the quantitative results, it was noted that the average of the F1-Score, both for the training and test sets, was higher than 90% in the case of the Support Vector Machine (SVM) algorithm, it was better compared to the results of the Random Forest (RF). The segmentation approach with shallow machine learning has shown to have potential in mapping rivers in RGB images. However, the case study considered only wide rivers.

**Keywords:** RGB images; machine learning; artificial intelligence.

## INTRODUÇÃO

A água ou, de forma mais abrangente, os recursos hídricos constituem elemento central na temática das chamadas emergências ambientais para o século XXI. O consenso em relação à importância da temática é facilmente avaliado em documentos de natureza diversa, especialmente os que desenham cenários e estratégias para o futuro. Componente essencial para a vida humana em seus múltiplos usos, bem como para a dinâmica de todos os sistemas ambientais, a água, em seus diversos estados, determina as características zonais e tipologias dos ecossistemas, entendidos como conjuntos de biótopos e biocenoses em todas as escalas espaciais (TOMASONI, M. et al. 2009). A disponibilidade dos recursos hídricos no planeta é uma das questões mais desafiadoras nos tempos atuais, em virtude da elevada e alarmante escassez deste recurso natural essencial à manutenção da vida na Terra. Em 08 de janeiro de 1997, foram estabelecidas normas pela Lei nº 9.433, denominada de Política Nacional de Recursos Hídricos (BRASIL, 1997) ações que promovem o uso e preservação desses recursos hídricos.

No Brasil, existem muitos tipos de corpos d'água superficiais, incluindo lagos, rios e reservatórios que desempenham um papel importante na geração de energia na Terra, como fator principal o ciclo hidrológico e a troca de energia, e sua falta afeta profundamente as paisagens naturais e as atividades humanas (JIANG et al. 2018). Quantificar e monitorar as dinâmicas espaciais é fundamental para uma melhor compreensão de muitos dos processos da superfície terrestre. Para verificar essas alterações, as geotecnologias têm papel fundamental. Ao decorrer dos anos, diferentes métodos de classificação de imagens de sensoriamento remoto foram desenvolvidos para essa finalidade, uma vez que novos conjuntos de dados com atributos diferentes, vêm se tornando cada vez mais estudados.

Os métodos da Inteligência Artificial (IA), especialmente, os algoritmos rasos de aprendizagem de máquina (Machine Learning - ML) são uma das alternativas avançadas para se realizar a classificação de imagens de sensoriamento remoto, e que podem apoiar estudos de planejamento e monitoramento ambiental. Na literatura, pode-se encontrar vários trabalhos referentes ao uso de técnicas de Inteligência Artificial para o mapeamento da água de superfície através de dados de sensoriamento remoto. Nascimento et al. (2013) compararam o desempenho do classificador Support Vector Machine (SVM) contra o classificador estatístico

tradicional, o algoritmo de máxima verossimilhança, para classificar imagens CBERS-2 CCD em uma região de Reservatório Tropical no Brasil. Os autores mostram uma acurácia de 71% (e coeficiente Kappa de 0,64) para o classificador SVM, contra 49% (e coeficiente Kappa de 0,36) para o de máxima verossimilhança, na classificação da área do Reservatório Tropical.

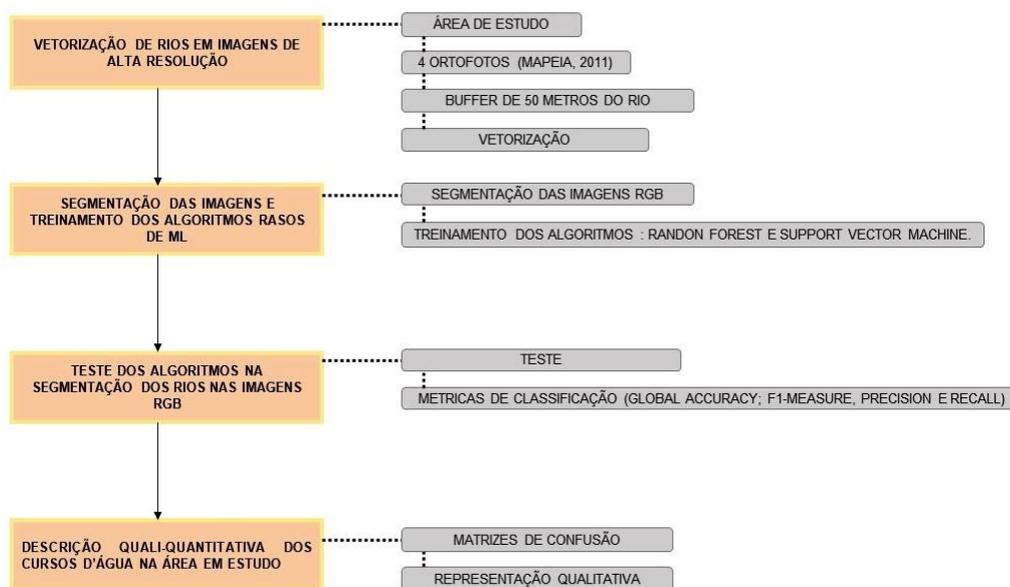
Martins et al. (2016) utilizaram, também, o algoritmo SVM para mapeamento de Uso e Cobertura do Solo (LULC) em uma área de reservatório hidrelétrico no estado do Rio de Janeiro, Brasil. Os autores testaram vários tipos de funções (linear, polinomial e função de base radial - RBF) e seus respectivos parâmetros para aplicarem o SVM em imagens TM/Landsat-5. Para a área em estudo, o SVM com a RBF foi a que apresentou melhor acurácia. Wei Jiang et al (2018) processaram imagens do Landsat 8 OLI com algoritmos de aprendizagem de máquina para a classificação de áreas de águas superficiais. Esse estudo mostrou uma acurácia global de 98,25% na discriminação de 06 tipos de massas de água, pelo processamento das imagens NDWI (Índice de Água por Diferença Normalizada) com o algoritmo SVM.

No que tange ao mapeamento de rios a partir de imagens de alta resolução espacial, até o presente momento, pouco se sabe sobre o desempenho dos algoritmos rasos de aprendizagem de máquina. Ademais, nenhum trabalho nessa temática foi identificado para a região do extremo oeste do estado de São Paulo, na qual a proteção das águas é um problema de interesse de diversos órgãos, como o Comitê de Bacias Hidrográficas do Pontal do Paranapanema (CBH-PP), Agência Nacional de Águas e Saneamento Básico (ANA), Ministério do Meio Ambiente (MMA), Conselho Nacional do Meio Ambiente (CONAMA) e Instituto Brasileiro do Meio Ambiente e dos Recursos Renováveis (IBAMA). O objetivo deste estudo é apresentar uma abordagem de mapeamento e segmentação de rios em imagens RGB de alta resolução espacial baseada em algoritmos rasos de aprendizagem de máquina (Machine Learning). Esse trabalho traz como contribuição científico-social a disponibilização de informações e dados que poderá auxiliar no desenvolvimento de estudos que visem a proteção das águas.

## MATERIAIS E MÉTODOS

O método foi dividido em quatro etapas (Figura 1): (1) vetorização de rios em imagens de alta resolução, no qual a partir da identificação de um pixel, ocorreria a geração do contorno ao agrupamento encontrado; (2) segmentação das imagens e treinamento dos algoritmos rasos de aprendizagem de máquina; (3) teste dos algoritmos na segmentação dos rios nas imagens RGB; e (4) descrição qualitativa da água superficial, que está relacionado a tendência e condição (estado atual) e também a variação de vazão temporal e espacial, e da descrição quantitativa da disponibilidade hídrica superficial dos cursos d'água na área em estudo.

Figura 1. Fluxo de trabalho descrevendo as principais etapas.



A classificação de imagens têm surgido nos últimos anos, visando otimizar o processo de extração e informação. Nessa perspectiva, os algoritmos rasos de machine learning disponíveis em softwares livres tem ganhado destaque. Há diversos algoritmos que realizam a classificação supervisionada de imagens, a destacar: Random Forests (RF) Classifier e Support Vector Machine (SVM).

Segundo Jake VanderPlas (2016) o algoritmo Random Forest (RF) é um exemplo de um método conjunto, ou seja, um método que se baseia na agregação dos resultados de um conjunto de estimadores mais simples. O Random Forest (RF) é um exemplo de conjunto construído em *decision tree* (DT) e apresenta flexibilidade e rapidez durante a execução. Breiman (2001) o algoritmo possui uma técnica de

aprendizagem em conjunto. O Random Forest (RF) gera muitas árvores de classificação que são agregadas para calcular uma classificação (BREIMAN et al. 1984). Hansen e Salamon (1990) indicou que uma condição necessária e suficiente para um conjunto de árvores de classificação para ser mais preciso do que qualquer um de seus membros, é que os membros do ensemble tenha um desempenho melhor do que aleatórios e diversos. O Random Forest aumenta a diversidade entre as árvores de classificação reamostrando os dados com substituição e alterando aleatoriamente os conjuntos de variáveis preditivas ao longo dos diferentes processos de indução da árvore. O número de árvores e o número da profundidade máxima de árvores são dois parâmetros definidos pelo usuário necessários para aumentar o valor de Random Forest.

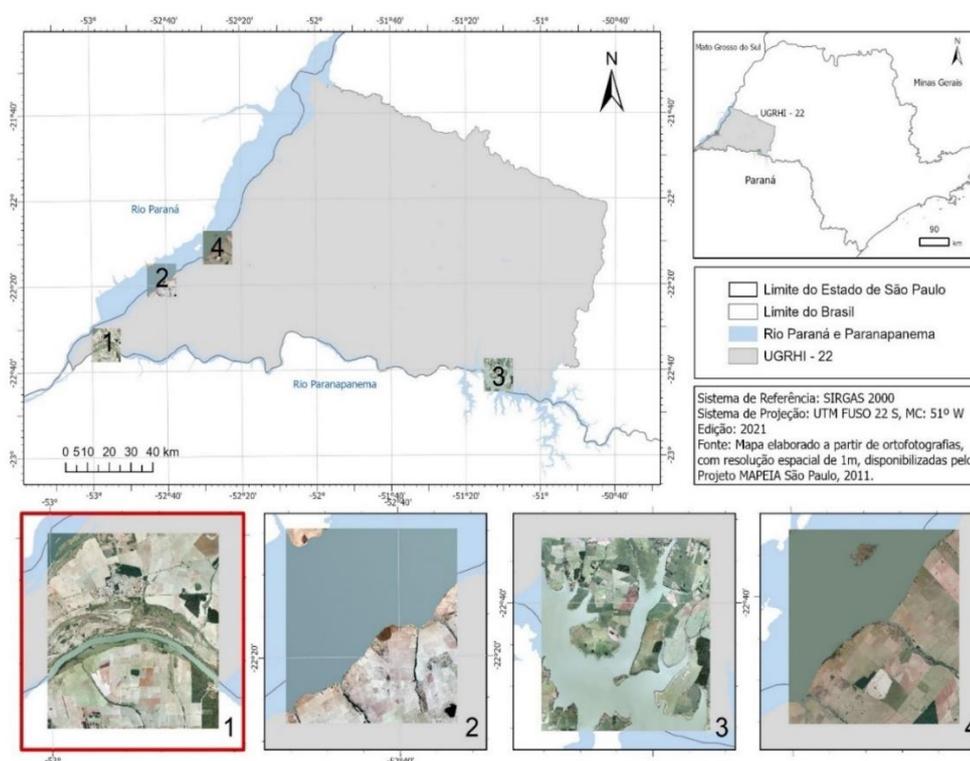
Outro algoritmo que será utilizado é o Support Vector Machine (SVM), segundo Mantero et al (2005) é adequado para o campo de sensoriamento remoto porque tem a capacidade de lidar com conjuntos de dados de treinamento pequenos, resultando em uma maior precisão de classificação em relação aos métodos tradicionais. Segundo Jake VanderPlas (2016) a utilização do algoritmo SVM é vantajoso devido a rapidez na fase de previsão por ser um modelo treinado, ao bom funcionamento com dados de alta dimensão e a capacidade de adaptação a diversos tipos de dados. Os SVMs são baseados no kernel, um método projetado para resolver os problemas de classificação binária e desenvolvido por Vapnik no início dos anos noventa. Os SVMs são baseados nos princípios de Minimização de Risco Estrutural (SRM) (BURGES, 1998), que tem se mostrado superior, ao princípio tradicional de Minimização de Risco Empírico (ERM), que é empregado por redes neurais convencionais (RICHARD et al, 1991) e as dimensões de Vapnik-Chervonenkis (VC) (BURGES, 1998). Estes podem ser considerados os classificadores discriminativos muito eficazes devido às suas várias características marcantes, tais como: a solução em requerer a margem máxima; sua capacidade de lidar com amostras de dimensionalidade muito maior; e sua convergência para o mínimo da função de custo associada é garantida. As principais características dos SVMs são o uso de kernels, a ausência de mínimos locais, a dispersão da solução e o controle de capacidade obtido pela otimização da margem. No SVM, o espaço de entrada original é mapeado em um espaço de recursos de dimensão mais alta no qual um hiperplano de separação ideal é construído com base no Minimização de Risco Estrutural (SRM) para maximizar a margem entre duas classes, ou seja, maximiza a capacidade de generalização do sistema.

## Área de Estudo

A área de estudo corresponde a uma região pertencente à 22ª Unidade de Gerenciamento de Recursos Hídricos do Pontal do Paranapanema (UGRHI-22), a qual é constituída por 07 grandes bacias hidrográficas. Os rios Paraná, Paranapanema, Santo Anastácio e Pirapozinho são os principais rios dessa unidade. Todavia, há uma vasta malha de cursos d'água na UGRHI-22, na qual estão inseridos 26 municípios do oeste do estado de São Paulo.

Antes de se definir quais seriam as áreas de estudo dentro da UGRHI-22, organizamos um banco de dados geográficos no SIG ESRI ArcGIS Pro 2.8, para o mapeamento das feições de rios que são imagens RGB de alta resolução espacial provenientes do projeto Mapeia-SP. Esse projeto registrou, no ano de 2011, fotografias aéreas de todo o estado de São Paulo. Essas fotografias foram registradas com um *Ground Sample Distance (GSD)* de 0,45 m, e liberadas ao público com uma resolução espacial de 1 m após o processo de ortorretificação. Na Figura 2 podemos observar as ortofotografias que foram selecionadas para realizar o treinamento (vermelho) e os testes (preto).

Figura 2. Localização das ortofotos na UGRHI 22 utilizadas no treinamento (borda em vermelho) e teste (bordas em preto) dos algoritmos de aprendizagem de máquina.



## Processamento dos dados por aprendizagem de máquina

Um total de 4 ortofotografias RGB de alta resolução espacial (1 m), com resolução radiométrica de 8 bits distribuídas dentro da articulação da UGRHI-22, foram utilizadas para treino e teste dos algoritmos de aprendizagem de máquina (Tabela 1). Uma para treinar e três dessas imagens para testar o desempenho dos algoritmos. Essas imagens foram projetadas para o Sistema de coordenadas Sirgas 2000, Universal Transversa de Mercator (UTM) zona 22 Sul. Todos os rios visíveis nas imagens RGB foram vetorizados no SIG ESRI ArcGIS Pro 2.8 usando a geometria de polígono. As áreas onde há a ocorrência de rios foram geocodificadas na tabela de atributos como “Classe 1 – rios”; as demais “Classe 2 – não rios”. Assim para evitar o desbalanceamento entre as classes, vetorizamos todos os rios que estavam localizados nas imagens, aplicamos um shapefile que se criou uma faixa de distância (um *buffer*) de 50 m para além de cada margem dos rios, e essa geometria resultante foi usada como máscara de recorte para as outras das ortofotografias, como exemplifica a Figura 3. Para realizar todos esses processamentos computacionais, utilizou-se um notebook Dell, com processador Core i7 – 7ª Geração e 8GB de Memória RAM, com placa de vídeo AMD R7 com 2GB.

Figura 3. Ortofoto (orto\_yavi1no) com aplicação do buffer de 50 metros.



Tabela 1. Informações referentes às 4 ortofotos utilizadas neste estudo para treino e teste dos algoritmos.

Algoritmo	Treino	Teste
Random Forest (RF)	orto_yavi1no	orto_bi1so
		orto_bvi2so
		yaiiii4no
Support Vector Machine (SVM)		orto_bi1so
		orto_bvi2so
		yaiiii4no

As ortofotos foram submetidas à uma classificação supervisionada orientada a objetos usando o Esri Arcgis Pro 2.8. Nesse tipo de classificação se agrupa os pixels vizinhos com base em quão semelhantes espectralmente eles são em um processo conhecido como segmentação da imagem. No presente trabalho, adotou-se o método de segmentação *MeanShift* por ser um método disponível no software em uso.

O método *MeanShift* tem por objetivo encontrar máximos e mínimos de uma função a partir das amostras dadas. No caso em estudo as amostras são os pixels de uma imagem, e a função levará em conta a posição e cor do pixel. Após várias tentativas, a melhor configuração adotada para esse método consistiu em detalhe espectral de 17, pois os valores válidos variam de 1,0 a 20,0, e esse valor é apropriado quando há recursos para ser classificado separadamente com características espectrais semelhantes; detalhe espacial de valor 10, o método de valores válidos são os mesmo, porém o nível de importância é dado às diferenças espectrais dos recursos nas imagens; e tamanho mínimo do segmento em pixel o valor de 150, onde mescla os segmentos menores com melhor ajuste e está relacionado à unidade mínima de mapeamento (Figura 4).

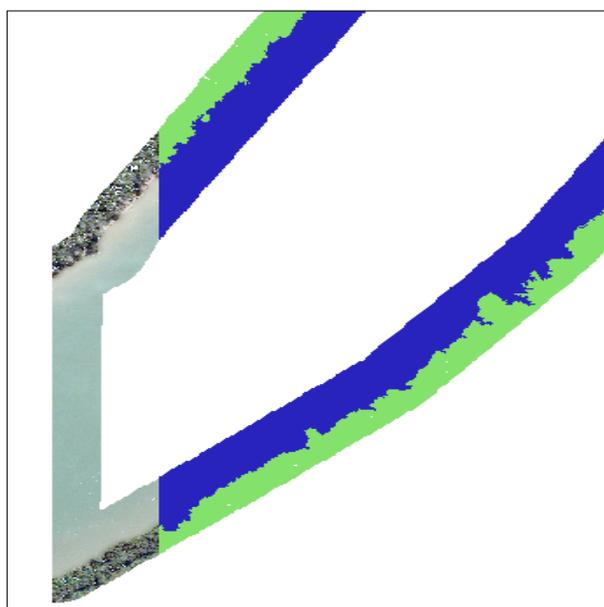
Figura 4. Segmentação da Ortofoto (orto\_yavi1no) pelo método MeanShift.



O presente trabalho utilizou o Random Forest (RF) e o Suport Vector Machine (SVM) para a segmentação das imagens RGB. As florestas aleatórias (ou Random Forest) constituem uma combinação de preditores baseados em árvores de decisão, na qual cada árvore depende de valores de um vetor aleatório gerado de forma independente e identicamente distribuídas em relação a todas as árvores da floresta (BREIMAN, 2001), os parâmetros utilizados no Random Forest (RF), a partir de teste empírico, que obteve melhor resultado quali-quantitativa foram: número máximo de árvores de 400, o número de árvores aumenta o tempo de processamento linear, com taxas de precisão mais altas; e profundidade máxima de arvores de 50, no qual o número de regras que cada árvore pode criar para chegar em uma decisão.

A Figura 5 ilustra um resultado do treinamento do Random Forest, no qual a classe rio é representada na cor azul, e a classe não rio na cor verde.

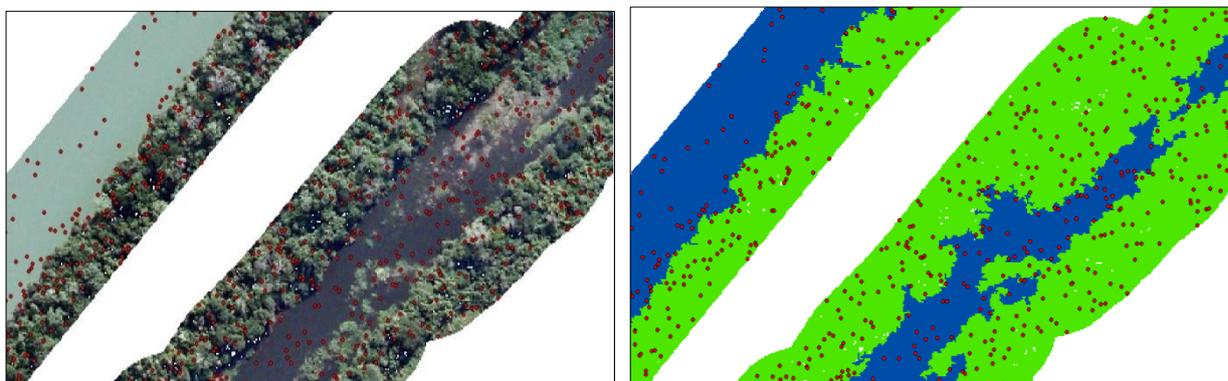
Figura 5. Resultado qualitativo do Random Forest nos dados de treino.



Outro classificador avaliado sobre as imagens RGB segmentadas pelo *método MeanShift* foi o Support Vector Machine (SVM), este algoritmo segundo Mantero et al (2005) é adequado para o campo de sensoriamento remoto porque tem a capacidade de lidar com conjuntos de dados de treinamento pequenos, resultando em uma maior precisão de classificação em relação aos métodos tradicionais. Fez-se o treinamento dos algoritmos (RF e SVM) por 5 vezes em cada ortofoto para, então, obter-se uma média de desempenho nos dados de treinamento por meio da avaliação da matriz de confusão. Tanto para avaliar a performance dos modelos nos dados de treino quanto

de teste (outras duas ortofotos), fez a construção da matriz de confusão usando um total de 10.000 pontos distribuídos usando a amostragem equalizada por tamanho de classe (classe 1 e classe 2) (Figura 6).

Figura 6. Distribuição dos pontos para classificação nos dados de teste.



Pela matriz de confusão (Figura 7) pode-se determinar tanto os erros de inclusão quanto os erros de omissão. Os erros de inclusão (ou comissão) são denominados erros do consumidor e são definidos como os pixels que são erroneamente incluídos em uma dada classe quando na verdade deveriam ser associados à outra classe. Os erros de omissão (ou exclusão), são denominados erros do produtor e são os pixels omitidos de sua correta classe e associados à outra classe (CONGALTON e GREEN, 1999). A matriz de erro permite, também, calcular outras medidas de exatidão, como a exatidão total ou acurácia global (STORY e CONGALTON, 1986). Portanto, pela matriz de confusão é possível analisar índices tanto de exatidão total, como a Exatidão Global e Coeficiente de Concordância Kappa, quanto de coeficiente de concordância por classe, a Exatidão do Usuário e do Produtor (STORY e CONGALTON, 1986).

Figura 7. Matriz de Confusão

		Detectada	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

**Verdadeiros Positivos (VP):** classificação correta da classe Positivo; **Falsos Negativos (FN)** (Erro Tipo II): erro em que o modelo anterior a classe Negativo quando o valor real era classe Positivo; **Falsos Positivos (FP)** (Erro Tipo I): erro em que o modelo anterior a classe Positivo quando o valor real era classe Negativo; **Verdadeiros Negativos (VN):** classificação correta da classe Negativo.

Além da matriz de confusão, adotou-se as seguintes métricas para avaliar o desempenho dos classificadores: a acurácia (ou taxa de reconhecimento), a sensibilidade do modelo (ou recall ou taxa de verdadeiro-positivo), a precisão, e a medida  $F_1$  – score (média harmônica entre o recall e a precisão).

A acurácia (accuracy ou ACC) é uma métrica clássica e muito utilizada na literatura, e para descobrir ela, basta calcular o número de acertos dividido pelo número total (número de acertos mais número de erros), onde essas informações são retiradas da matriz de confusão (BRITO, 2020).

$$acurácia = \frac{VP + VN}{VP + FN + VN + FP}$$

A sensibilidade do modelo (revocação, recall, taxa de verdadeiro-positivo ou REC) é calculado pelo número dos resultados corretos (verdadeiro positivo) dividido pelo número de resultados que deveriam ser apresentados (verdadeiro positivo mais falso negativo). Ou seja, caso seu classificador não cometa nenhum erro, a precisão do mesmo é igual a sua revocação e ambos possuem valor 1.

$$sensibilidade = \frac{VP}{VP + FN}$$

A precisão (precision ou PRE) é uma métrica que avalia a quantidade de verdadeiros positivos sobre a soma de todos os valores positivos:

$$precisão = \frac{VP}{VP + FP}$$

A medida  $F_1$  ( $F_1$ -Score ou  $F_1S$ ) é a combinação da precisão com a revocação trazendo um número único que indique a qualidade geral do seu modelo, trabalhando bem até com um conjunto de dados que possuem classes desproporcionais (BRITO, 2020). O cálculo da medida  $F_1$  é:

$$f1 = 2 * \frac{precisão * sensibilidade}{precisão + sensibilidade}$$

## RESULTADOS E DISCUSSÃO

A Tabela 2 mostra o desempenho dos algoritmos de aprendizagem de máquina nos dados de treino (5 iterações), enquanto a Tabela 3 descreve os resultados nos dados de teste.

Tabela 2. Performance dos modelos nos dados de treino.

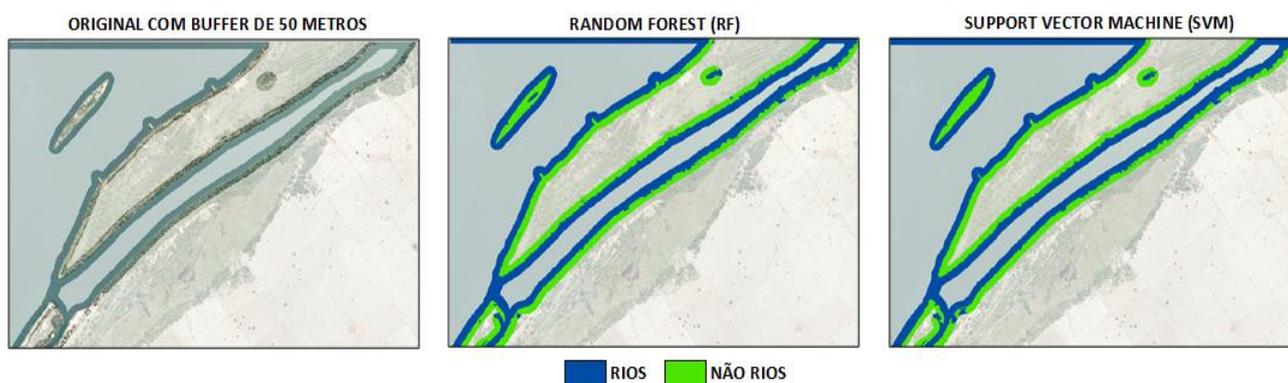
Método	Treino	Iterações	Acurácia	FScore	Precision	Recall
Random Forest (RF)	orto_yavi1no	1º	0,9018	0,9100	0,8398	0,9930
		2º	0,9018	0,9100	0,8398	0,9930
		3º	0,9019	0,9101	0,8400	0,9930
		4º	0,8982	0,9070	0,8348	0,9929
		5º	0,9037	0,9116	0,8428	0,9926
		<b>Média</b>	<b>0,901</b>	<b>0,910</b>	<b>0,8390</b>	<b>0,9930</b>
Support Vector Machine (SVM)	orto_yavi1no	1º	0,9011	0,9083	0,8464	0,9800
		2º	0,9095	0,9164	0,8519	0,9914
		3º	0,9095	0,9164	0,8519	0,9914
		4º	0,9095	0,9164	0,8519	0,9914
		5º	0,9095	0,9164	0,8519	0,9914
		<b>Média</b>	<b>0,908</b>	<b>0,915</b>	<b>0,851</b>	<b>0,989</b>

Tabela 3. Performance dos modelos nos dados de testes.

Método	Treino	Teste	Acurácia	FScore	Precision	Recall
Random Forest (RF)	orto_yavi1no	orto_bi1so	0,7915	0,8264	0,7079	0,9924
		orto_bvi2so	0,8453	0,8664	0,7670	0,9954
		yaiiii4no	0,7909	0,8260	0,7077	0,9918
		<b>Média</b>	<b>0,809</b>	<b>0,840</b>	<b>0,728</b>	<b>0,9930</b>
Support Vector Machine (SVM)	orto_yavi1no	orto_bi1so	0,8785	0,8886	0,8203	0,9694
		orto_bvi2so	0,9196	0,9246	0,8767	0,9780
		yaiiii4no	0,8775	0,8897	0,8155	0,9788
		<b>Média</b>	<b>0,892</b>	<b>0,901</b>	<b>0,838</b>	<b>0,975</b>

Para ilustrar o desempenho dos algoritmos, na Figura 8, apresenta os resultados qualitativos obtidos com cada algoritmo de aprendizagem de máquina, treinado utilizando a ortofoto 'orto\_yavi1no'.

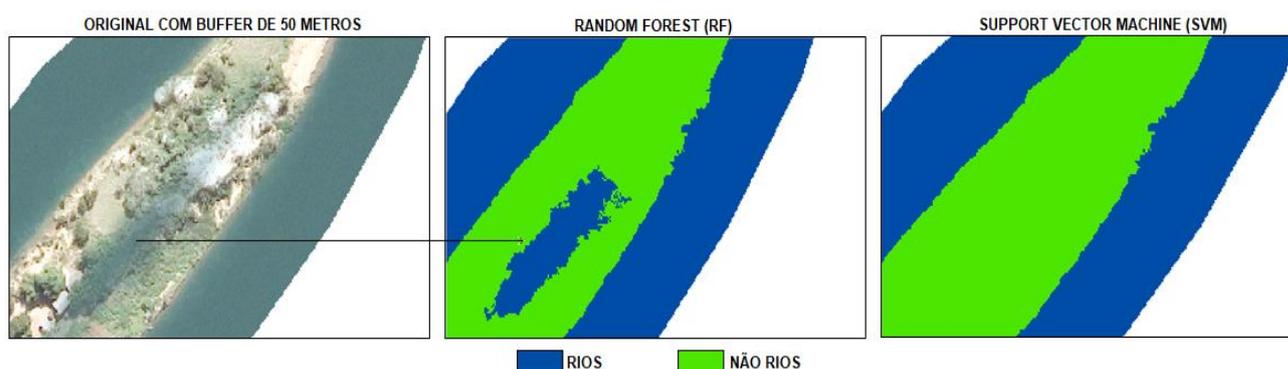
Figura 8. Resultado das Classificações das imagens de cada algoritmo.



Podemos observar nas duas imagens classificadas com os algoritmos rasos de aprendizagem que houve um desempenho semelhante entre elas, a análise quantitativa (Tabela 2) demonstrou que o melhor resultado em termos de valor em nosso estudo, que o algoritmo Support Vector Machine (SVM) foi mais estável entre os dados de treino e teste em comparação ao Random Forest (RF). Nota-se que a média do F1-Score, tanto para o conjunto de treino quanto de teste, foi superior a 90% no caso do algoritmo SVM, e isso se mostrou melhor comparado aos resultados do Random Forest (RF). O mesmo apresentou a média da Precision inferior ao SVM, isto é, a capacidade do RF em classificar regiões de rios foi menor que a do algoritmo SVM. Podemos destacar também que o Random Forest (RF) foi superior ao SVM quanto à média do Recall e isto indica que, o SVM teve dificuldade em reconhecer feições de rios nas imagens, gerando os falsos positivos na sua classificação.

Na análise qualitativa podemos observar alguns falsos positivos (Figura 9) (ou seja, rios classificados como não rios), que são mais prejudiciais que os falsos negativos.

Figura 9. Analise falsos positivos.



Os parâmetros do SVM treinado garantiram a parametrização ideal do algoritmo e permitiram mapear e segmentar as feições de rios das imagens. Os resultados quantitativos demonstraram que a precisão média de FScore para treino em SVM teve 91% o que apresentou bons resultados quando comparado ao Random Forest (RF). Os parâmetros de entrada do RF, também, foram testados e mostraram que o parâmetro de regularização mais alto obteve resultado de 90%.

As análises de detecção após a classificação dos algoritmos de aprendizagem de máquina demonstram que a parametrização da segmentação do SVM obtida permite uma grande diferenciação entre o treinamento e teste. Além da diferenciação entre rios e não rios, a parametrização obtida neste trabalho tornou o algoritmo capaz de diferenciar água e não água (agricultura, pastagem, silvicultura e entre outros). Apesar de ter alcançado uma ótima precisão o SVM, a inclusão de novos dados pode ajudar a melhorar ainda mais o desempenho dos modelos que apresentaram valores satisfatórios.

## **CONCLUSÃO**

A abordagem apresentada neste estudo avaliou o desempenho dos algoritmos de aprendizagem de máquina, Support Vector Machine (SVM) e o Random Forest (RF) para o mapeamento de cursos d'água em imagens RGB de alta resolução espacial. A estratégia de segmentação semântica das imagens para, então, realizar o processo de classificação das cenas se mostrou eficiente, visto que em ambos os algoritmos testados o desempenho foi alto. Isso mostra que a abordagem de segmentação de o algoritmo de aprendizagem rasa aqui apresentada tem o potencial de mapear os cursos hídricos em imagens RGB, ainda que exista alta similaridade espectral entre essas feições de interesse (ex. rios) e outros altos como solo exposto (ex. erosão), pois muitos dos rios na área em estudo apresentam problemas de assoreamento, porém o estudo de caso considerou somente rios largos. Futuros estudos deveriam tratar os casos de mapeamento de rios estreitos ou aqueles que tenham indícios de assoreamento. Outro fator contribuinte importante que devemos citar são as hidrelétricas (UHE Rosana, UHE Taquaruçu e UHE Capaivara) em nossa área de estudo da 22ª Unidade de Gerenciamento de Recursos Hídricos do Pontal do Paranapanema - São Paulo, que utilizam os recursos hídricos que além de ser uma fonte de energia renovável e mais barata do que as demais energias limpas (solar,

eólica e energia proveniente de marés), com esse estudo pode ser utilizado para monitoramento da gestão desses recursos hídricos, conservação da biodiversidade, mudanças climáticas e principalmente a gestão de desastres.

Com recomendações futuras tem-se a comparação dos resultados aqui obtidos com aqueles derivados de aprendizagem profunda de modo que se possa verificar o ganho, ou não, de desempenho na tarefa de interesse (mapear rios) ao se utilizar algoritmos rasos que trabalhem com maior número de características da cena, como textura, forma, dentre outros, como é o caso dos modelos de aprendizagem profunda.

Pelo estudo de caso, demonstra-se que o SVM é o algoritmo de aprendizagem rasa indicado para o mapeamento de rios largos, e não assoreados, em imagens RGB segmentadas. A contribuição desse trabalho, até o momento, é a disponibilização de uma abordagem eficaz e eficiente capaz de realizar a classificação supervisionada de imagens RGB para mapear feições de interesse ambiental.

## REFERÊNCIAS

BRASIL. **Lei nº 9.433, de 8 de janeiro, de 1997**. Institui a Política Nacional de Recursos Hídricos, cria o Sistema Nacional de Gerenciamento de Recursos Hídricos, regulamenta o inciso XIX do art. 21 da Constituição Federal, e altera o art. 1º da Lei nº 8.001, de 13 de março de 1990, que modificou a Lei nº 7.990, de 28 de dezembro de 1989.

BREIMAN L, FRIEDMAN JH, OLSHEN RA, Stone CJ (1984) Classification and regression trees. Chapman & Hall, New York.

BREIMAN, LEO. Random forests. Machine Learning, v. 45, n. 1, p. 5-32, 2001. doi:10.1023/A:1010933404324.

BRITO, EIKE NATAN SOUSA. Análise de desempenho de modelos de classificação de elementos arquitetônicos em modelos BIM. São Cristóvão, SE, 2020. Monografia (graduação em Ciência da Computação) - Departamento de Computação, Centro de Ciências Exatas e Tecnologia, Universidade Federal de Sergipe, São Cristóvão, SE. 2020.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers. 137 p. 1999.

C. J. C. BURGESS, "A tutorial on Support Vector Machines for Pattern Recognition", Kluwer Academic Publications, 1998.

HANSEN L, SALAMON P. Neural network ensembles. IEEE Trans Pattern Anal Mach Intell 12:993–1001. 1990.

MANTERO P, MOSER G, SERPICO SB (2005) Partially supervised classification of remote sensing images through SVM-based probability density estimation. **IEEE Trans Geosci Remote Sens** 43:559–570.

MARTINS, S., BERNARDO, N., OGASHAWARA, I. et al. Support Vector Machine algorithm optimal parameterization for change detection mapping in Funil Hydroelectric Reservoir (Rio de Janeiro State, Brazil). *Model. Earth Syst. Environ.* 2, 138 (2016).

M. D. RICHARD AND R. P. LIPPMANN, “Neural network classifiers estimate Bayesian a posteriori probabilities,” *Neural Comput.*, vol. 3, pp. 461–483, 1991.

NASCIMENTO, R. et al. An assessment of the Support Vector Machine for a CBERS-2 CCD image classification: a case study of a tropical reservoir in Brazil. **Revista Brasileira de Cartografia** (2013) N0 65/3: 431-439.

SIRIKULVIRIYA, N. and Sinthupinyo, S. (2011). Integration of rules from a random forest, 2011 International Conference on Information and Electronics Engineering, Vol. 6, pp. 194–198.

SONKAMBLE, B. A., & DOYE, D. D. An overview of speech recognition system based on the support vector machines. 2008 International Conference on Computer and Communication Engineering. doi:10.1109/iccce.2008.4580709.

STORY, M.; CONGALTON, R.G. Accuracy assessment: a user’s perspective. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 3, p. 397-399, 1986.

TOMASONI, M.; PINTO, J.; SILVA, H. A questão dos recursos hídricos e as perspectivas para o Brasil. **GeoTextos**, Salvador, v. 5, n. 2, p. 107-127, dez. 2009.

VANDERPLAS, J., 2016. **Python Data Science Handbook**. O’Reilly and Associates.

WEI JIANG, GUOJIN HE, TENGFEI LONG, YUAN NI, HUICHAN LIU, YAN PENG, KENAN LV, GUIZHOU WANG: **Multilayer Perceptron Neural Network for Surface Water Extraction in Landsat 8 OLI Satellite Images**. *Remote Sensing* 10(5): 755 (2018).

### 3 CONSIDERAÇÕES FINAIS

Em vista dos argumentos apresentados o presente trabalho verificou o desempenho de algoritmos rasos de machine learning (ML) em mapear, segmentar e classificar os rios e não rios com base em imagens RGB de alta resolução espacial. As técnicas de programação estão sendo cada vez mais utilizadas para aplicações nestas ciências. Nos testes realizados, evidencia-se que é possível obter uma segmentação dos rios em imagens RGB com alta acurácia. As análises em corpos d'água se mostraram de grande eficiência, dado ao controle de qualidade realizado se comparado a uma vetorização manual. Mesmo com um intervalo de uso de 5 iterações a porcentagem de erros não superou os 10%, considerando o resultado extremamente satisfatório do estudo, com 91%.

Entre os muitos aspectos que são destacados como ferramentas neste estudo, podemos definir que o desenvolvimento de bancos de dados (baseados em sistemas de informação geográfica) que foram mostrados, para mapeamento, segmentação e classificação com as métricas de avaliação, é possível realizar o monitoramento, obter um diagnóstico, criar métodos de planejamento e métodos de manejo de recursos hídricos.

Desta forma pode-se considerar que os métodos utilizados servem para fins acadêmicos, profissionais, de gestão e até mesmo de planejamento, podendo esta informação ser repassada para os órgãos públicos que necessitem de informações semelhantes, para prefeituras visto o grande caso de assoreamento por conta do intemperismo e outros fatores, bem como serviria para alunos tanto de áreas afins como de áreas distintas para servir de base ou mesmo de fonte de informação para outros estudos.