

Classificação de áreas úmidas usando modelos de Aprendizado de Máquina no Pantanal Brasileiro

Wetland Classification Using Machine Learning Models in the Brazilian Pantanal

Natalia Verónica Revollo*, Edinéia Aparecida dos Santos Galvanin**, Carlos Enrique Berger***, Verónica Gil****, Sandra Mara Alves da Silva Neves*****

* Departamento de Ingeniería Eléctrica y de Computadoras, Universidad Nacional del Sur, Argentina

** Departamento de Geografia e Planejamento/Ourinhos, Universidade Estadual Paulista, edineia.galvanin@unesp.br

*** Universidad Provincial del Sudoeste, Buenos Aires, carlos.berger@upso.edu.ar

**** Departamento de Geografía y Turismo, Universidad Nacional del Sur-CONICET, verogil@uns.edu.ar

***** Faculdade de Ciências Humanas/Geografia, Universidade do Estado de Mato Grosso, ssneves@unemat.br

<https://doi.org/10.5380/raega.v63i2.99547>

Resumo

O Pantanal é a maior área úmida tropical do mundo e abrange os países da Bolívia, Brasil e Paraguai. Existem regiões dentro do Pantanal que estão aderidas ao tratado da Convenção de áreas úmidas ou que são reconhecidas como Reserva da Biosfera e Patrimônio da Humanidade pela UNESCO. O objetivo deste trabalho é a classificação de corpos d'água superficiais em áreas úmidas por meio do uso de técnicas de aprendizado de máquina, em particular técnicas de agrupamento. Inicialmente, utilizou-se o índice Índice de Vegetação por Diferença Normalizada a partir de um mosaico de imagens que cobre a área de estudo provenientes do satélite Sentinel 2-A processadas na plataforma Google Earth Engine. A partir deste índice, estabeleceu-se um limiar de maneira empírica para segmentar os corpos d'água. Em seguida, aplicou-se a técnica de agrupamento às características morfológicas de cada objeto segmentado. Os resultados obtidos mostram que é possível a categorização de corpos d'água com técnicas de aprendizado não supervisionado.

Palavras-chave:

Sensoriamento remoto, Inteligência artificial, Processamento de imagens, Corpos d'água.

Abstract

The Pantanal is the largest tropical wetland in the world and covers the countries of Bolivia, Brazil, and Paraguay. Some regions within the Pantanal are part of the Convention on Wetlands or are recognized as Biosphere Reserves and World Heritage Sites by UNESCO. This work's objective is to classify surface water bodies into wetlands using machine learning techniques, through clustering techniques. Initially, the (Normalized Difference Vegetation Index) was used from a mosaic of images covering the study area from the Sentinel 2-A satellite processed on the Google Earth Engine platform. From this index, a threshold is established empirically, and the water bodies are segmented. The clustering technique is then applied to the morphological characteristics of each

segmented object. The results obtained show that it is possible to categorize water bodies with unsupervised learning techniques.

Keywords:

Remote sensing, Artificial intelligence, Image processing, Water bodies.

I. INTRODUÇÃO

As áreas úmidas da superfície terrestre que são inundadas de forma permanente ou intermitente representam aproximadamente 6% da superfície do planeta. São vitais para a sobrevivência humana e fonte de água e produtividade primária para várias espécies vegetais e animais. Apesar da sua importância global, estima-se que metade das áreas úmidas do planeta desapareceram. Atualmente, existe o tratado de Convenção sobre áreas úmidas para a conservação e o uso racional dessas áreas e dos seus recursos. Este tratado alcança 2.513 áreas de importância internacional que representam uma área de 257.254.185 ha (Ramsar, 2024). O Pantanal é a maior área úmida tropical da América Latina e do mundo e abrange os países da Bolívia, Brasil e Paraguai. Existem regiões dentro do Pantanal que estão aderidas ao tratado de Convenção sobre áreas úmidas ou que são reconhecidas como Reserva da Biosfera e Patrimônio da Humanidade pela UNESCO. Embora se reconheça a importância ambiental global, mais de 90% do Pantanal está sob propriedade privada e grande parte da terra é utilizada para a criação de gado.

Nos últimos anos, a disponibilidade de imagens de satélite e plataformas de acesso e processamento de grandes volumes de informação tem tido um notável incremento. Isto tem impulsionado a investigação e a aplicação de tecnologias espaciais numa variedade de campos, desde o monitoramento ambiental até à gestão de recursos naturais e o planejamento urbano.

Dentro da Inteligência Artificial (IA), o Aprendizado de Máquina (Machine Learning - ML) tem se mostrado uma ferramenta poderosa para o monitoramento do meio ambiente (Avci, 2023; Costa et al., 2016; Immitzer et al., 2012; Hino et al., 2018; Milutinovic, 2024; Wurm, 2019; Zhang et al., 2021). O ML oferece ferramentas que contribuem para a conservação dos recursos naturais e a mitigação das mudanças climáticas, entre outros desafios ambientais globais. No caso das imagens de satélite, o ML permite uma exploração eficiente e automatizada de padrões espaciais, segmentação de imagens, detecção de anomalias e compressão de dados. Isso fornece informações geoespaciais para uma ampla gama de aplicações na gestão ambiental, na agricultura e no monitoramento dos recursos naturais, entre outros.

Existem situações em que a informação a ser analisada cobre grandes superfícies e não é possível a rotulação manual a priori por parte de especialistas. Nesses casos, o uso de modelos ou algoritmos de

aprendizado de máquina (ML) não supervisionados se torna uma ferramenta fundamental que pode explicar e ajudar a entender o comportamento da informação geoespacial a ser analisada. Esse enfoque pode ser essencial no estudo dos corpos d'água nas áreas úmidas do Pantanal, onde há uma grande quantidade de dados geoespaciais e a diversidade de características pode ser muito complexa. Em particular, o clustering permite identificar padrões espaciais e distribuições de características nas imagens de satélite sem necessidade de rotulação (Subbiah; Christopher, 2012; Usman, 2013; Abburo; Golla, 2015; Bezerra et al., 2022).

O objetivo deste trabalho é classificar corpos de água superficiais em áreas úmidas através do uso de técnicas de ML, em particular a técnica de clustering. Dessa forma, busca-se contribuir para a realização do Objetivo de Desenvolvimento Sustentável 6 "Água limpa e saneamento" (ODS 6), fornecendo informações e análises relevantes sobre áreas úmidas, com um enfoque específico no Pantanal Brasileiro. Ao fornecer informações sobre as mudanças ambientais e seus impactos nos recursos hídricos, esse enfoque pode apoiar políticas e práticas relacionadas à gestão da água e ao saneamento, promovendo a sustentabilidade desses recursos vitais.

II. MATERIAIS E MÉTODOS

O Pantanal é uma vasta planície de inundação localizada no centro-sul do Brasil e que se estende até o nordeste do Paraguai e o sudeste da Bolívia (Brasil, 2022) (Figura 1). A vegetação do Pantanal é heterogênea e influenciada principalmente pelo ecossistema Cerrado, mas também apresenta elementos da floresta amazônica, do Chaco e da mata atlântica. Essa característica, junto com os diferentes tipos de solo e os regimes de inundação, é responsável pela grande variedade de formações vegetais e pela heterogeneidade da paisagem, que abriga uma rica biota aquática e terrestre (Adámoli; Pott, 1999). O principal fator ecológico na determinação dos padrões e processos no Pantanal são os pulsos de inundação (Alho, 2008; Junk et al., 2013; Milien et al., 2023), com grandes amplitudes e uma duração de três a seis meses.




Figura 1 – Mapa da localização do Pantanal no Brasil, autoria: Galvanin (2025). Áreas do Pantanal no Brasil obtidas com drone (abaixo), fonte: LABGEO (2024).

O Programa de Monitoramento dos Biomas Brasileiros por Satélite (PMDBBS) destacou que a área úmida do Pantanal está enfrentando um processo de secagem devido à degradação do solo, com uma perda de 17%

da cobertura vegetal nativa nas últimas décadas. Além disso, a pressão para a instalação de projetos de infraestrutura tem aumentado, causando danos ambientais significativos.

Nesse contexto, as Áreas Prioritárias para a Conservação, Utilização Sustentável e Repartição dos Benefícios da Biodiversidade são essenciais para o Pantanal. Essas áreas são fundamentais para a manutenção dos ecossistemas únicos e ameaçados do bioma, e sua conservação é crucial para garantir a biodiversidade e os serviços ecossistêmicos da região.

A metodologia proposta busca integrar-se com essas áreas prioritárias, utilizando tecnologias de sensoriamento remoto para monitorar e categorizar corpos de água. Isso pode auxiliar na tomada de decisões para a gestão e conservação desses ambientes críticos, contribuindo assim para a sustentabilidade ambiental e socioeconômica do Pantanal.

Processamento de Informação Geoespacial

A Região de Interesse (ROI) é delimitada através da combinação de Informação Geoespacial (IG) em formato vetorial do Pantanal na região do Brasil e IG em formato raster do satélite Sentinel 2-A. Sentinel-2 é uma missão de imagens multiespectrais de alta resolução e grande amplitude de varredura para o monitoramento da vegetação, do solo e da cobertura de água, assim como a observação de vias fluviais interiores e áreas costeiras. Estas imagens são obtidas da plataforma Google Earth Engine (GEE).

As imagens encontram-se ortorretificadas e os valores de reflectância da superfície estão corrigidos atmosféricamente. Além disso, as imagens são filtradas por uma nebulosidade menor que 5%. O ROI é representado por um mosaico que combina múltiplas imagens individuais em uma imagem média que representa o período chuvoso na região do Pantanal correspondente aos meses de outubro a maio. A partir desta imagem média, obtém-se o Índice de Água por Diferença Normalizado (NDWI) (Avezov et al., 2024; Gao, 1995; Li et al., 2022; McFeeters, 1996) que é amplamente utilizado para detectar e mapear corpos d'água em imagens de satélite. Para a avaliação deste índice, utiliza-se a combinação de comprimentos de onda do verde no visível e do infravermelho próximo. As primeiras maximizam a reflectância habitual da superfície da água. As segundas maximizam a alta reflectância da vegetação terrestre e das zonas de solo, enquanto minimizam a baixa reflectância das massas d'água. Os valores de NDWI são positivos para os elementos de água e negativos (ou zero) para o solo e a vegetação terrestre Equação 1.

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (1)$$

onde: GREEN e NIR são os valores de reflectância na banda do verde e reflectância na banda do infravermelho próximo, respectivamente.

Adicionalmente, selecionam-se três ROIs dentro das "Áreas Prioritárias para a Conservação, Uso Sustentável e Repartição de Benefícios da Biodiversidade brasileira". Essas áreas são estabelecidas como um instrumento de política pública, orientando o desenvolvimento de ações de pesquisa, inventário de biodiversidade, recuperação de áreas degradadas e espécies sobreexploradas ou em perigo de extinção, licenciamento ambiental, inspeção, identificação de áreas com potencial para a criação de unidades de conservação, corredores ecológicos, ações de fomento ao uso sustentável e ações de regularização ambiental (Brasil, 2022).

São áreas definidas geograficamente com base em informações espaciais sobre a ocorrência de objetos de conservação (espécies ameaçadas de extinção, raras ou endêmicas, ecossistemas terrestres e aquáticos e serviços ecossistêmicos relevantes para a conservação da biodiversidade existente nelas), informações especializadas sobre atividades antropogênicas (represas, estradas, áreas sem cobertura vegetal, mineração etc.), assim como atividades que favoreçam a conservação e uso sustentável da biodiversidade (projetos ambientais, ecoturismo, entre outros). As zonas consideradas para avaliar corpos d'água são zonas extremamente altas, muito altas e altas.

Para cada região, segmenta-se a imagem do NDWI com o objetivo de separar os corpos d'água. A segmentação é realizada utilizando um limiar estabelecido empiricamente com base em avaliações visuais de especialistas. Este limiar de NDWI permite diferenciar água e outros tipos de coberturas, resultando em uma representação binária da imagem. Uma vez identificados os corpos d'água, eles são convertidos em polígonos em formato vetorial.

Machine Learning na classificação supervisionada de IG

Nesta etapa, calculam-se os descritores morfológicos de cada objeto segmentado. Existe uma variedade de descritores baseados em contornos ou no conjunto total de pixels que compõem o objeto segmentado (Bober et al., 2002; Zhang; Lu, 2004; Heilbronner, 2014; Neal; Russ, 2012) e são frequentemente utilizados no reconhecimento e identificação de objetos. Desta forma, consegue-se caracterizar os corpos d'água a partir de um vetor de características de forma (Tabela 1).

Para o processo de classificação de objetos, aplica-se a técnica de Análise de Componentes Principais (ACP) e, em seguida, o algoritmo de Agrupamento. A técnica de ACP é utilizada para reduzir a dimensionalidade do conjunto de dados, com a qual se obtém um novo conjunto de variáveis em um nível de confiança de 95%.

Em algoritmos não supervisionados, é fundamental determinar o número ideal de clusters nos quais os dados podem ser agrupados. Para isso, usou-se o método do cotovelo, o qual calcula o valor de uma métrica de avaliação chamada inércia. Os valores de inércia são obtidos através da Equação 2 ao aplicar o algoritmo de agrupamento para diferentes números de clusters (k), e gera-se um gráfico desses valores. Finalmente, procuram-se os pontos onde a curva começa a suavizar.

Tabela 1 – Descritores Morfológicos.

Descritor de Forma	Descrição	Equação
Area	Superfície do corpo d'água	A
Perímetro	Longitude do perímetro do corpo d'água	P
Compacidade	Como um corpo de água se assemelha a uma figura compacta	$C = \frac{A}{p^2}$
Relação de aspecto	Relação entre a largura e o comprimento de um corpo d'água	$RA = \frac{Largura}{Máxima}$
Circularidade	Medida em que um corpo d'água se assemelha a um círculo	$Circ = \frac{4\pi A}{P^2}$
Fator de forma	Medida da relação entre a área do objeto e a área do círculo mínimo que o contém	$FF = \frac{A}{A_c}$
Máxima longitude	O comprimento máximo medido em qualquer direção dentro do corpo d'água	ML
Largura Máxima	A largura máxima medida em qualquer direção dentro do corpo d'água	MA
Amplitude	Medida que indica quão estirado ou alongado o corpo d'água é em comparação com sua largura	$E = \frac{Longitude\ do\ objeto}{Largura\ do\ objeto}$
Envolvente convexa	Polígono convexo menor que contém todos os pontos do corpo d'água	EC

Autoria própria.

$$Inercia(k) = \sum_{i=1}^k ||x - \mu_i||^2 \quad (2)$$

onde:

k é o número de clúster.

μ_i é o centroide do i -ésimo clúster

$||x - \mu_i||^2$ representa a distância ao quadrado entre um ponto x e o centróide μ_i do cluster a que pertence.

Para a classificação dos corpos d'água, utiliza-se a técnica K-Means (MacKay, 2003) aos descritores morfológicos de cada polígono gerado. Esta técnica particiona o conjunto de n observações em k clusters baseado em uma distância euclidiana média. Apresenta a vantagem de ser simples e rápida de processar, embora tenha a limitação de que se deve conhecer a priori o número de classes ($x_1, x_2, \dots, x_n$) onde cada x_i é um vetor real de d dimensões, a partir do qual se constrói uma partição das observações em k conjuntos ($k \leq n$) a fim de minimizar a soma dos quadrados dentro de cada grupo.

$$\arg \min S \sum_{x_j \in S_i} \|x_j - \mu_i\|^2 \quad (3)$$

onde μ_i é a média de pontos S_i .

Validação

A validação da segmentação de objetos é realizada utilizando o Coeficiente de Similaridade de Dice (DSC) (Dice, 1945) Equação 4. Esta é uma métrica comumente usada em imagens médicas, embora sua aplicação tenha sido ampliada para outras áreas. Para isso, são selecionados aleatoriamente objetos segmentados com a metodologia proposta em uma camada de informação vetorial. Em seguida, esses objetos, a partir das imagens de satélite, são digitalizados manualmente por especialistas utilizando a plataforma QGIS (QGIS, 2024). Dessa forma, obtêm-se dois conjuntos de dados para aplicar o DSC.

$$DSC = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (4)$$

onde $|A \cap B|$ representa o tamanho da área de intersecção entre os conjuntos A e B , $|A|$ e $|B|$ representa o tamanho dos conjuntos A e B .

Categorização de Corpos d'água

Uma vez agrupados os objetos em classes, realiza-se uma categorização descritiva de cada corpo d'água classificado. Essa categorização é feita com especialistas que trabalham na área, com o objetivo de identificar grupos de objetos com formas ou estruturas morfológicas similares. Para isso, avaliam-se visualmente os arquivos em formato vetorial selecionados e definem-se categorias, além de adicionar um campo descritivo dentro da informação alfanumérica associada a cada corpo d'água. O fluxograma da metodologia proposta é apresentado na **Figura 2**.




Figura 2 – Metodologia proposta para a classificação de corpos d'água em áreas úmidas. Autoria própria.

III. RESULTADOS E DISCUSSÃO

Foi obtido um mosaico de imagens do satélite Sentinel-2 pseudocor em RGB com as bandas espectrais do vermelho, azul, verde e infravermelho próximo, com um tamanho de 12.143 GB. Um ROI deste mosaico pode ser observado na **Figura 3a**. Estas estão inseridas nas zonas alta, muito alta e extremamente alta definidas como Áreas Prioritárias para a Biodiversidade Brasileira e compreendem uma área total de 100.000 km². A partir das bandas espectrais, calculou-se o índice NDWI, onde é possível visualizar os corpos d'água (**Figura 3b**).

A partir de um limiar empírico estabelecido em consenso com três especialistas que estudam este tipo de áreas úmidas, se selecionam os grupos de pixels cujo valor de NDWI supera este limiar, obtendo-se a imagem segmentada (**Figura 3c**). É possível notar que existem corpos d'água que não são detectados pelo método proposto ou que são detectados como vários objetos; isso, em alguns casos, se deve ao fato de estarem secos ou cobertos parcial ou totalmente por algum tipo de vegetação. Também existem casos em que os rios ou riachos apresentam descontinuidades devido ao aparecimento de vegetação ou à falta de água nos mesmos. Logo, para cada objeto segmentado, foram calculados os contornos em um formato vetorial, obtendo polígonos para os conjuntos de pixels detectados como água (**Figura 3d**).




Figura 3 – Resultados do algoritmo de segmentação aplicando um limiar empírico determinado de maneira subjetiva por um especialista a partir de uma imagem de NDWI. a) Imagem pseudocor em cor natural. b) Imagem NDWI pseudocor. c) Imagem segmentada. d) Imagem de contornos em formato vetorial. e) Superposição de corpos d'água detectados sobre a imagem em cor natural. Autoria própria.

A vantagem do formato vetorial é a possibilidade de acesso mais rápido à informação, pois ocupa menos capacidade computacional do que o formato raster; é possível incorporar informações alfanuméricas descritivas a cada objeto detectado e é possível unir objetos que são detectados separadamente por meio de operações geoespaciais. A combinação da imagem em cor natural e os contornos em formato vetorial permite uma interpretação visual dos resultados (**Figura 3e**).

A validação da segmentação foi realizada através do cálculo do Coeficiente de Similaridade de Dice (DSC), utilizando segmentações manuais de corpos d'água no QGIS para comparação com os resultados da segmentação automática (**Figura 4**). O valor de DSC obtido foi de 0,91, indicando uma alta sobreposição e concordância entre as duas segmentações, com cerca de 90% dos objetos segmentados que coincidem entre si.




Figura 4 – Comparação entre a segmentação manual (cyan) e a segmentação aplicando a metodologia (azul). Autoria própria.

A partir de informações geográficas que representam a camada de corpos d'água, foram estimados dez descritores morfológicos para cada objeto geográfico. Dessa forma, tem-se um vetor de características para cada objeto. Em seguida, aplicou-se a técnica de ACP para determinar a quantidade de variáveis que representam 95% da variância, o que foi alcançado com dois componentes. Inicialmente, para aplicar o método de agrupamento k-means, estimou-se o número ótimo de clusters utilizando o método do cotovelo, resultando em um valor de $k = 4$ grupos. Portanto, os resultados obtidos classificam os objetos geográficos em quatro classes. A partir dessa imagem, cada grupo foi categorizado manualmente com a interpretação visual de acordo com o feedback dos especialistas.

Após o agrupamento dos objetos geográficos em 4 classes, foram definidas as seguintes classes: classe 1: Lagoa regular, classe 2: lagoa irregular ou lagoa irregular parcialmente coberta por vegetação ou outro, classe 3: lagoa seca, lagoa coberta, represa ou reservatório de água e classe 4: rio ou meandro. Na **Figura 5a** é possível observar uma lagoa irregular que está coberta por vegetação em seus arredores. A **Figura 5b** mostra uma lagoa mais regular nas bordas.

Os objetos categorizados em riachos, rios ou meandros podem ser separados após a aplicação do algoritmo de agrupamento (**Figura 5c**). Finalmente, na **Figura 5d**, visualiza-se um exemplo de reservatório de água. Dado que o k-means é um algoritmo não supervisionado, a validação das categorias propostas pelo modelo foi realizada com especialistas em corpos d'água. Esse processo foi realizado de forma qualitativa, observando se os clusters resultantes eram coerentes com as classes conhecidas de corpos d'água. Embora a amostra tenha sido pequena e aleatória, a validação permitiu verificar a correspondência entre os agrupamentos gerados pelo k-means e as categorias informadas pelos especialistas.




Figura 5 – Resultados da classificação: imagem de alta resolução (primeira coluna), imagem Sentinel 2-A (segunda coluna) e classificação superposta (terceira coluna). a) Corpo d'água irregular, b) Corpo d'água regular, c) Meandro e d) reservatório d'água criado artificialmente. Autoria própria.

O modelo proposto permitiu a segmentação de mais de 100.000 objetos nas áreas prioritárias do Pantanal Brasileiro. Na Figura 6, à direita, são mostrados os resultados da classificação e categorização para as

áreas prioritárias. Na região de interesse (ROI) selecionada, é possível notar que existem cursos de água pertencentes a rios que o modelo os classifica como corpos d'água irregulares. Isso ocorre porque esses corpos d'água se encontram descontínuos devido às zonas ripárias. No entanto, é possível notar que em amarelo se categoriza a continuidade de um curso de água. Cada objeto categorizado é validado por três especialistas que, segundo seu critério, podem aceitar, rejeitar ou modificar a categoria indicada pelo modelo.




Figura 6 – Resultados da classificação para as áreas prioritárias Muito Alta correspondente a uma imagem Sentinel-2 para o período chuvoso de 2018 e 2019. Autoria própria.

Estudos sobre o Pantanal destacam a importância de equilibrar o desenvolvimento econômico com a conservação ambiental. A literatura sugere que a sustentabilidade cultural e ambiental é crucial para manter o equilíbrio da paisagem natural (Rossetto; Brasil Junior, 2003). O modelo de segmentação pode ser uma ferramenta útil para identificar áreas prioritárias para conservação, alinhando-se com esses objetivos de sustentabilidade.

O turismo rural e o ecoturismo são mencionados como formas de promover o desenvolvimento sustentável, valorizando a cultura local (Almeida, 2003). A segmentação e classificação de objetos podem

auxiliar na identificação de áreas adequadas para essas atividades, promovendo a conservação da biodiversidade.

O modelo de segmentação e classificação de objetos no Pantanal pode ser uma ferramenta importante para a conservação e o desenvolvimento sustentável da região, especialmente quando integrado a outras tecnologias e considerando a cultura e a socioeconomia local.

IV. CONCLUSÕES

A metodologia proposta permite a segmentação, classificação e, posteriormente, categorização de cada corpo de água que compõe o Pantanal Brasileiro. O uso do aprendizado de máquina não supervisionado k-means permitiu categorizar os objetos geográficos em quatro grupos. Este algoritmo oferece uma valiosa ferramenta para a análise e a compreensão das características morfológicas do terreno. O uso de bandas espectrais, como o infravermelho próximo, em combinação com bandas do espectro visível, resulta em um método simples para a segmentação de corpos de água.

Ao segmentar os dados em clusters, o k-means permite identificar padrões que destacam as diferentes regiões de acordo com sua morfologia. Diferentemente de técnicas supervisionadas, onde é necessário o etiquetado de informações para poder classificar objetos, esta metodologia não requer dados etiquetados previamente. No caso do Pantanal, dada a grande quantidade de objetos geográficos que o compõem, isso resultaria em uma tarefa que consumiria elevados recursos de processamento e humanos.

Os resultados não apenas proporcionam uma compreensão mais profunda dos corpos de água do Pantanal, mas também podem servir para a tomada de decisões ambientais, sociais ou econômicas. A quantidade de informações avaliadas foi realizada através da plataforma Google Earth Engine e da missão Sentinel-2. Essas plataformas fornecem informações e ferramentas a investigadores e profissionais que permitem o estudo de características da Terra.

Com a capacidade de processar e analisar enormes quantidades de dados de maneira eficiente, essas plataformas estão revolucionando a forma como se estuda e se compreende nosso planeta, permitindo a realização de investigações em grande escala e a tomada de decisões informadas em áreas que vão desde a gestão ambiental até a agricultura de precisão.

Como trabalho futuro, propõe-se a elaboração de um catálogo de tipos de corpos de água dentro do Pantanal que possa ser usado para o estudo espaço-temporal de áreas úmidas. Além disso, sugere-se analisar a conectividade da paisagem, integrando os dados obtidos com modelos de conectividade ecológica. Isso

permitirá identificar áreas-chave para a conservação e restauração da conectividade, contribuindo assim para a sustentabilidade ambiental e socioeconômica da região do Pantanal. Além disso, considerando os recentes incêndios no pantanal, é importante investigar quais lagos desapareceram, se novos lagos se formaram, bem como outras questões relacionadas à presença ou ausência de água.

V. REFERÊNCIAS

- ABBURO, S.; GOLLA, S. B. Satellite image classification methods and techniques: A review. *International Journal of Computer Applications*, v. 119, n. 8, 2015.
- ADÁMOLI, J.; POTT, A. Las fuentes de diversidad en el Pantanal. In: MATTEUCCI, S.; SOLBRIG, O.; MORELLO, J.; HALFFTER, G. (ed.). *Biodiversidad y uso de la tierra: conceptos y ejemplos en Latinoamérica*. Buenos Aires: UNESCO y Universidad de Buenos Aires, 1999. p. 317-360.
- ALHO, C. J. R. Biodiversity of the Pantanal: response to seasonal flooding regime and to environmental degradation. *Brazilian Journal of Biology*, v. 68, n. 4, p. 957-966, 2008.
- ALOTAIBI, E.; NASSIF, N. Artificial intelligence in environmental monitoring: in-depth analysis. *Discover Artificial Intelligence*, v. 4, n. 1, p. 84, 2024.
- AVCI, C. et al. Comparison between random forest and support vector machine algorithms for LULC classification. *International Journal of Engineering and Geosciences*, v. 8, n. 1, p. 1-10, 2023.
- AVEZOV, S. et al. Quantifying Water Bodies with Sentinel-2 Imagery and NDWI: A Remote Sensing Approach. In: *E3S Web of Conferences*. Les Ulis: EDP Sciences, 2024. p. 2007.
- BEZERRA, F. G. S. et al. Spatio-temporal analysis of dynamics and future scenarios of anthropic pressure on biomes in Brazil. *Ecological Indicators*, v. 137, p. 108749, 2022.
- BOBER, M.; PRETEUX, F.; KIM, W. Y. Shape descriptors. In: MANJUNATH, B. S.; SALAMBHOY, P. (ed.). *Introduction to MPEG-7: Multimedia content description interface*. New York: Wiley, 2002. p. 231.
- BRASIL. Ministério do Meio Ambiente. Relatório Probio-Pantanal. Brasília: MMA, 2022. Disponível em: <https://www.gov.br/mma/pt-br/assuntos/biodiversidade-e-ecossistemas/ecossistemas/biomas/pantanal>. Acesso em: 11 jan. 2025.
- COSTA, P. H.; OLIVEIRA PEREIRA, E.; MAILLARD, P. An original processing method of satellite altimetry for estimating water levels and volume fluctuations in a series of small lakes of the Pantanal wetland complex in Brazil. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 41, p. 327-334, 2016.
- DICE, L. R. Measures of the amount of ecologic association between species. *Ecology*, v. 26, n. 3, p. 297-302, 1945.
- GAO, B. Normalized difference water index for remote sensing of vegetation liquid water from space. In: *SPIE. Imaging Spectrometry*, 1995. p. 225-236.
- HEILBRONNER, R.; BARRETT, S. Shape descriptors. In: *Image analysis in Earth sciences: microstructures and textures of Earth materials*. Heidelberg: Springer, 2014. p. 323-347.

- HINO, M.; BENAMI, E.; BROOKS, N. Machine learning for environmental monitoring. *Nature Sustainability*, v. 1, n. 10, p. 583-588, 2018.
- IMMITZER, M.; ATZBERGER, C.; KOUKAL, T. Tree species classification with random forest using very high spatial resolution 8-band WorldView-2 satellite data. *Remote Sensing*, v. 4, n. 9, p. 2661-2693, 2012.
- JEAN MILIEN, E. et al. Hydrological dynamics of the Pantanal, a large tropical floodplain in Brazil, revealed by analysis of Sentinel-2 satellite imagery. *Water*, v. 15, n. 12, p. 2180, 2023.
- JUNK, W. J. (ed.). *The central Amazon floodplain: ecology of a pulsing system*. Dordrecht: Springer Science & Business Media, v. 126, 2013.
- LI, J. et al. Satellite detection of surface water extent: A review of methodology. *Water*, v. 14, n. 7, p. 1148, 2022.
- MACKAY, D. J. *Information theory, inference and learning algorithms*. Cambridge: Cambridge University Press, 2003.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, v. 17, n. 7, p. 1425-1432, 1996.
- MILUTINOVIĆ, M. Machine learning in environmental monitoring. *Facta Universitatis, Series: Working and Living Environmental Protection*, p. 155-160, 2024.
- NAÇÕES UNIDAS. *The Agenda 2030*. Disponível em: <https://www.un.org/sustainabledevelopment/es/development-agenda/>. Acesso em: 10 jan. 2025.
- NEAL, F. B.; RUSS, J. C. *Measuring shape*. Boca Raton: CRC Press, 2012.
- QGIS.ORG. QGIS Geographic Information System. QGIS Association, 2024. Disponível em: <http://www.qgis.org>. Acesso em: 20 jan. 2025.
- RAMSAR. Ramsar Homepage. Disponível em: <https://www.ramsar.org/>. Acesso em: 12 dez. 2024.
- SUBBIAH, B.; CHRISTOPHER, S. C. Image classification through integrated K-Means algorithm. *International Journal of Computer Science Issues (IJCSI)*, v. 9, n. 2, p. 518, 2012.
- USMAN, B. Satellite imagery land cover classification using k-means clustering algorithm computer vision for environmental information extraction. *Elixir International Journal of Computer Science and Engineering*, n. 63, p. 18671-18675, 2013.
- WURM, M. et al. Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 150, p. 59-69, 2019.
- ZHANG, D.; LU, G. Review of shape representation and description techniques. *Pattern Recognition*, v. 37, n. 1, p. 1-19, 2004.
- ZHANG, T. et al. Sentinel-2 satellite imagery for urban land cover classification by optimized random forest classifier. *Applied Sciences*, v. 11, n. 2, p. 543, 2021.