



**UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
CURSO DE GEOGRAFIA - BACHARELADO**



ISABELLA FAVERO

**Classificação e estimativa de Estoque de Carbono nas Fitofisionomias do Pantanal: Análise da
Sub-região do Abobral**

CAMPO GRANDE – MS

2024

ISABELLA FAVERO

Classificação e estimativa de Estoque de Carbono nas Fitofisionomias do Pantanal: Análise da Sub-região do Abobral

Monografia apresentada ao curso de Geografia - Bacharelado da Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia da Universidade Federal de Mato Grosso do Sul, como parte dos requisitos para obtenção do título de Bacharel em Geografia.

Orientador: Prof. Dr. José Marcato Júnior

CAMPO GRANDE – MS

2024



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul



ATA DE DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO DO CURSO DE GRADUAÇÃO EM GEOGRAFIA - BACHARELADO

Às 09:00 horas do dia 4 de dezembro, reuniu-se a Banca Examinadora, sob Presidência do Professor Orientador, para avaliação do Trabalho de Conclusão de Curso do Curso de Graduação em Geografia - Bacharelado da Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia da Universidade Federal de Mato Grosso do Sul.

Acadêmica: Isabella Favero

RGA: 2021.2109.018-2

Titulo: CLASSIFICAÇÃO E ESTIMATIVA DE ESTOQUE DE CARBONO NAS FITOFISIONOMIAS DO PANTANAL : ANÁLISE DA SUB-REGIÃO DO ABOBRAL

A banca composta pelos examinadores abaixo relacionados emitiu os seguintes conceitos:

Examinadores:

Conceito:

José Marcato Junior - (Presidente)

Aprovado

Márcio Santos Araújo - (Membro)

Aprovado

Maxwell da Rosa Oliveira (Membro)

Aprovado

Allan Henrique de Almeida Souza - (Suplente)

Conceito Final: (X) Aprovado

()

Reprovado

Observação:

Este é o parecer.

Campo Grande, 4 de Dezembro de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por
**Jose Marcato Junior, Professor do
Magisterio Superior**, em 04/12/2024, às
10:23, conforme horário oficial de Mato
Grosso do Sul, com fundamento no § 3º do

art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Márcio Santos Araujo, Usuário Externo**, em 04/12/2024, às 10:36, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Maxwell da Rosa Oliveira, Usuário Externo**, em 04/12/2024, às 10:49, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5295679** e o código CRC **2688786F**.

COLEGIADO DE GRADUAÇÃO EM GEOGRAFIA (BACHARELADO)

Av Costa e Silva, s/nº - Cidade Universitária

Fone:

CEP 79070-900 - Campo Grande - MS

Referência: Processo nº 23104.018018/2024-81

SEI nº 5295679

AGRADECIMENTOS

A conclusão deste trabalho não seria possível sem o apoio, a orientação e a companhia de pessoas muito especiais, a quem dedico minha mais profunda gratidão.

Primeiramente, à minha família, minha base e maior suporte, meu agradecimento especial aos meus pais, Sônia Silva de Jesus e João Carlos Favero, que sempre acreditaram em mim e me ofereceram amor incondicional em todos os momentos. Aos meus irmãos, João Vitor e Rafaella, que estiveram ao meu lado, me apoiando e incentivando. Amo vocês profundamente e sou imensamente grata por tudo o que representam na minha vida.

Ao Prof. Dr. José Marcato Júnior, pela orientação dedicada, não apenas neste trabalho, mas também em outras pesquisas acadêmicas ao longo da minha trajetória. Sua paciência, conhecimento e apoio constante foram fundamentais para o meu crescimento como pesquisadora e autonomia para a realização deste trabalho de conclusão de curso.

Ao meu colega de laboratório e também geógrafo, Márcio Santos Araújo, meu agradecimento pelos conselhos valiosos que tanto contribuíram para minha caminhada acadêmica. Sua parceria e disposição para compartilhar experiências foram um grande incentivo para seguir em frente.

Por fim, não poderia deixar de mencionar minhas amigas, Isabelly Senna e Beatriz Talgatti, cuja amizade, companhia e apoio tornaram os anos de graduação mais leves e especiais. Vocês foram fundamentais para enfrentar os desafios e celebrar as conquistas ao longo dessa jornada.

A todos vocês, meu sincero e profundo agradecimento. Este trabalho é também resultado da influência positiva e do apoio de cada um de vocês.

RESUMO

O Pantanal, uma vasta planície alagável com rica diversidade de fitofisionomias, desempenha um papel crucial na captura e armazenamento de carbono, essencial para a mitigação das mudanças climáticas. Este estudo concentrou-se na sub-região do Abobral, utilizando algoritmos de aprendizado de máquina implementados na plataforma do Google Earth Engine (GEE), com ênfase em Suporte de Vetores de Máquina (SVM) e Florestas Aleatórias (FA), para classificar e estimar o estoque de carbono em três principais fitofisionomias: Formação Florestal, Formação Savânica e Formação Campestre. Os resultados indicaram que o SVM apresentou desempenho superior, com coeficiente kappa de 0,81 e acurácia das classes acima de 70%, destacando-se na classificação de formações mais complexas e heterogêneas. Em comparação, o classificador FA obteve coeficiente kappa de 0,72 e acurácia inferior na classificação da formação savânica ao comparar com o SVM. Apesar de ocupar uma menor área, a Formação Florestal revelou maior estoque médio de carbono por hectare devido à densidade de sua vegetação. Em contraste, a Formação Savânica, que abrange a maior área, possui o maior estoque total de carbono. A Formação Campestre apresentou a menor capacidade de armazenamento de carbono por hectare. Este estudo destaca a importância de análises sazonais para uma compreensão completa da dinâmica do carbono e sugere que o uso contínuo de tecnologias como o GEE pode aprimorar o monitoramento e a conservação do Pantanal.

Palavras-chave: google earth engine (gee), aprendizado de máquina, suporte de vetor de máquina (svm), florestas aleatórias (fa)

ABSTRACT

The Pantanal, a vast floodplain with a rich diversity of phytophysiognomies, plays a crucial role in carbon capture and storage, which is essential for climate change mitigation. This study focused on the Abobral sub-region, using machine learning algorithms implemented on the Google Earth Engine (GEE) platform, with emphasis on Machine Vector Support (SVM) and Random Forests (FA), to classify and estimate the carbon stock in three main phytophysiognomies: Forest Formation, Savannah Formation and Grassland Formation. The results indicated that the SVM presented superior performance, with a kappa coefficient of 0.81 and class accuracy above 70%, standing out in the classification of more complex and heterogeneous formations. In comparison, the FA classifier obtained a kappa coefficient of 0.72 and lower accuracy in the classification of the savannah

formation when compared to the SVM. Despite occupying a smaller area, the Forest Formation revealed a higher average carbon stock per hectare due to the density of its vegetation. In contrast, the Savanna Formation, which covers the largest area, has the largest total carbon stock. The Grassland Formation showed the lowest carbon storage capacity per hectare. This study highlights the importance of seasonal analyses for a thorough understanding of carbon dynamics and suggests that the continued use of technologies such as GHG can enhance the monitoring and conservation of the Pantanal.

Keywords: google earth engine (gee), machine learning, machine vector support (svm), random forests (fa)

LISTA DE FIGURAS

Figura 1- Mapa de Localização.....	9
Figura 2 – Imagem de Satélite: Sentinel-2.....	10
Figura 3 - Classes de interesse	12
Figura 4 - Classificação de Fitofisionomias na sub-região Abobral no pantanal sul-matogrossense	18
Figura 5 - Acurácia das classes	21
Figura 6 - Mapa temático de estoque de carbono de biomassa aérea em fitofisionomias na sub-região Abobral do Pantanal sul-matogrossense	24

LISTA DE TABELAS

Tabela 1- Bandas Sentinel-2 L2A	11
Tabela 2 - Valores de Índice Kappa	14
Tabela 3 - Estoque de carbono de biomassa aerea (4CN).....	15
Tabela 4 - Estoque de carbono de biomassa aérea (Barros, J.H.S et al. 2022)	16
Tabela 5 - Estoque de carbono de biomassa aérea em fitofisionomias no bioma Pantanal	17
Tabela 6 - Área em hectares.....	19
Tabela 7 - Índice Kappa	20
Tabela 8 - Erros de Omissão e Inclusão.....	22
Tabela 9 - Estoque de carbono da biomassa aérea em fitofisionomias no Abobral/ Pantanal.....	23

SUMÁRIO

1 INTRODUÇÃO.....	5
2 MATERIAL E MÉTODOS.....	7
2.1 ÁREA DE ESTUDO.....	8
2.1.1 Localização e caracterização da área de estudo.....	8
2.2 AQUISIÇÃO E PRÉ-PROCESSAMENTO DE DADOS.....	9
2.2.1 Dados de Sensoriamento Remoto.....	9
2.2.2 Classes de Interesse e Amostra de treinamento.....	11
2.3 TREINAMENTO SUPERVISIONADO.....	12
2.3.1 Suporte de Vetores de Máquinas.....	12
2.3.2 Florestas Aleatórias.....	13
2.3.3 Avaliação de precisão.....	13
2.4 DADOS DE ESTOQUE DE CARBONO.....	14
2.4.1 Valores primários e secundários.....	14
2.4.2 Estoque mínimo, médio e máximo de tC/ha.....	16
3 RESULTADO E DISCUSSÃO.....	17
3.1 CLASSIFICAÇÃO DAS FITOFISIONOMIAS.....	18
3.2 ÍNDICE KAPPA.....	20
3.3 ACURÁCIA.....	21
3.4 MATRIZ DE ERROS DOS ALGORITMOS.....	22
3.5 ESTIMATIVA DE ESTOQUE DE CARBONO DE BIOMASSA AÉREA COM DADOS PRIMÁRIO E SECUNDÁRIOS.....	24
4 CONCLUSÃO.....	27
5 REFERÊNCIAS.....	28

1 INTRODUÇÃO

Pantanal é um dos maiores biomas alagáveis do mundo, essa planície aluvial é caracterizada por uma grande diversidade de fitofisionomias, incluindo formações florestais, savânicas e campestres. O bioma é moldado por uma complexa interação entre fatores ambientais, como o regime de cheias e secas, que influenciam a diversidade de fitofisionomias presentes na região. A heterogeneidade da vegetação pantaneira resulta de um mosaico de ambientes que variam de áreas permanentemente alagadas a regiões mais secas (Adamoli, 1981; Damasceno et al. 1999; Pott et al. 2000).

As fitofisionomias desempenham um papel vital na captura e armazenamento de carbono, sendo a estimativa do estoque de carbono essencial para avaliar o papel do Pantanal na mitigação das mudanças climáticas. A relação entre a vegetação e o carbono armazenado é complexa e depende das características específicas de cada fitofisionomia, incluindo a densidade de biomassa e a composição florística. Portanto, a identificação e quantificação das fitofisionomias são fundamentais para a elaboração de estratégias de conservação e manejo sustentável desse ecossistema único (Queiroz et al. 2019; Silva et al. 2000).

O sensoriamento remoto tem se mostrado uma ferramenta essencial para o estudo e monitoramento de ecossistemas complexos, como o Pantanal. Diversos estudos demonstram a eficácia dessa técnica na avaliação da dinâmica de inundação, na análise das mudanças na vegetação e no monitoramento da variação da cobertura vegetal, conforme evidenciado por Pessi et al. (2023), Achucarro et al. (2023), Paranhos Filho et al. (2014), Hansen et al. (2013), Evans et al. (2014), Arieira et al. (2011) e Silva, (1991).

Nesse contexto, o aprendizado de máquina, um ramo da Inteligência Artificial, oferece um complemento valioso ao permitir a aquisição automática de conhecimento por meio de algoritmos que aprendem interativamente a partir dos dados recebidos (Schulz et al. 2018). Conforme Matyukira e Mhangara (2024), quando integrado ao sensoriamento remoto, especialmente no mapeamento de vegetação, o aprendizado de máquina proporciona resultados expressivos em termos de precisão, profundidade e escalabilidade das análises. Essa abordagem é fundamental para o monitoramento de mudanças ambientais, a conservação da biodiversidade e a melhoria das práticas de gestão territorial. Dentre os algoritmos de aprendizado de máquina, o Suporte de Vetores de Máquinas (SVM) e Florestas Aleatórias (FA) destacam-se por seu desempenho em estudos realizados por Braun et al.

(2010), Moreira et al. (2014), Tangthaikwan (2017), Camargo et al. (2020), Furuya et al. (2020), Duarte (2022), Praticó et al. (2021), Magalhães et al. (2022) e Gxokwe et al. (2022). Demonstraram resultados de forte a excelente concordância na análise do Índice Kappa ao utilizar o algoritmo SVM e/ ou RF para a classificação da cobertura do solo e vegetação com o emprego de diferentes imagens de satélite.

Estudos que utilizam o Sentinel-2 em conjunto com algoritmos de aprendizado de máquina, têm demonstrado notável eficiência na classificação de vegetação e análise do uso e cobertura da solo. Por exemplo, no estudo de Rodriguez et al. (2022), o SVM demonstrou maior precisão em regiões homogêneas ao classificar habitats mediterrâneos, evidenciando a capacidade do algoritmo de lidar com conjuntos de dados uniformes. Narvaes et al. (2024) utilizaram o SVM e FA para distinguir espécies florestais na arborização urbana. Além disso, Shang e Chisholm et al. (2014) empregaram o SVM e FA para mapear vegetação nativa australiana, nesse contexto o classificador Florestas Aleatórias alcançou melhor precisão, principalmente em regiões críticas.

O classificador FA é frequentemente destacado pela sua capacidade de manejar grandes volumes de dados e lidar com variáveis correlacionadas. Silva et al. (2022) demonstraram a alta eficiência do FA na diferenciação de fitofisionomias no Pantanal, com destaque para transições entre savanas e áreas alagadas. Essa abordagem também foi validada por Ahmed et al. (2023), que avaliaram o algoritmo na classificação de uso e cobertura do solo, evidenciando desempenho superior em vegetações naturais. Outro exemplo notável é o trabalho de Zhang et al. (2022), que utilizou o classificador em conjunto com dados LiDAR do ICESat-2 para estimar a altura do dossel florestal, destacando a versatilidade do Florestas Aleatórias na integração de diferentes fontes de dados.

A integração de dados espectrais e índices de vegetação, muitas vezes em plataformas como o Google Earth Engine (GEE), permite explorar a alta resolução espacial e temporal do Sentinel-2, otimizando a detecção e diferenciação de fitofisionomia e usos do solo. O GEE é uma plataforma de computação que permite o processamento e a análise de grandes volumes de dados geoespaciais, a capacidade de realizar análises em larga escala, aliada à sua arquitetura baseada em nuvem, reduz significativamente os custos e a necessidade de infraestrutura computacional (Gorlick et al. 2017).

A comparação de algoritmos em diferentes estudos evidencia a especificidade de cada classificador em determinadas aplicações. No estudo de Zhao et al. (2023), o SVM demonstrou maior precisão na distinção de padrões específicos, como a identificação do *Pinus tabulaeformis*, enquanto

Liu et al. (2022) evidenciou a robustez do FA em capturar múltiplas classes em uma classificação do Uso e Cobertura da Terra (LULC). Isso reforça a importância de selecionar o algoritmo com base nas características dos dados e nos objetivos da análise, ressaltando a flexibilidade do aprendizado de máquina para diversas aplicações no sensoriamento remoto.

Este estudo tem como objetivo investigar o uso de algoritmos de aprendizado de máquina na classificação das fitofisionomias da sub-região do Abobral, no pantanal, com foco na identificação das diferentes formações vegetais e suas respectivas áreas. A partir da classificação que apresentou o melhor desempenho nas análises estatísticas, foi realizada a estimativa do estoque de carbono dessas fitofisionomias, utilizando dados primários e secundários de biomassa aérea. Essa abordagem oferece uma análise detalhada e integrada, contribuindo para uma compreensão mais abrangente da distribuição das fitofisionomias e do potencial de estoque de carbono na região.

O artigo está organizado da seguinte forma: a seção de Materiais e Métodos apresenta a área de estudo, os procedimentos de aquisição e pré-processamento de dados, o treinamento supervisionado com algoritmos como Suporte de Vetores de Máquinas e Florestas Aleatórias, e a avaliação de precisão. Em Resultados e Discussão, são apresentados a classificação das fitofisionomias, o índice de acurácia e a matriz de erros para cada classe, além do coeficiente kappa das classificações e a análise de estoque de carbono de biomassa aérea. Por fim, a seção de Conclusões sintetiza os principais achados e contribuições do estudo.

2 MATERIAL E MÉTODOS

As seguintes etapas foram realizadas na plataforma Google Earth Engine (GEE): (1) Obtenção de imagens de satélite; (2) Determinar as classes de interesse; (3) Anotação das Amostras de Treinamento e Classificação Supervisionada; (4) Correlação entre a classificação e os dados de estoque de carbono.

2.1 ÁREA DE ESTUDO

2.1.1 Localização e caracterização da área de estudo

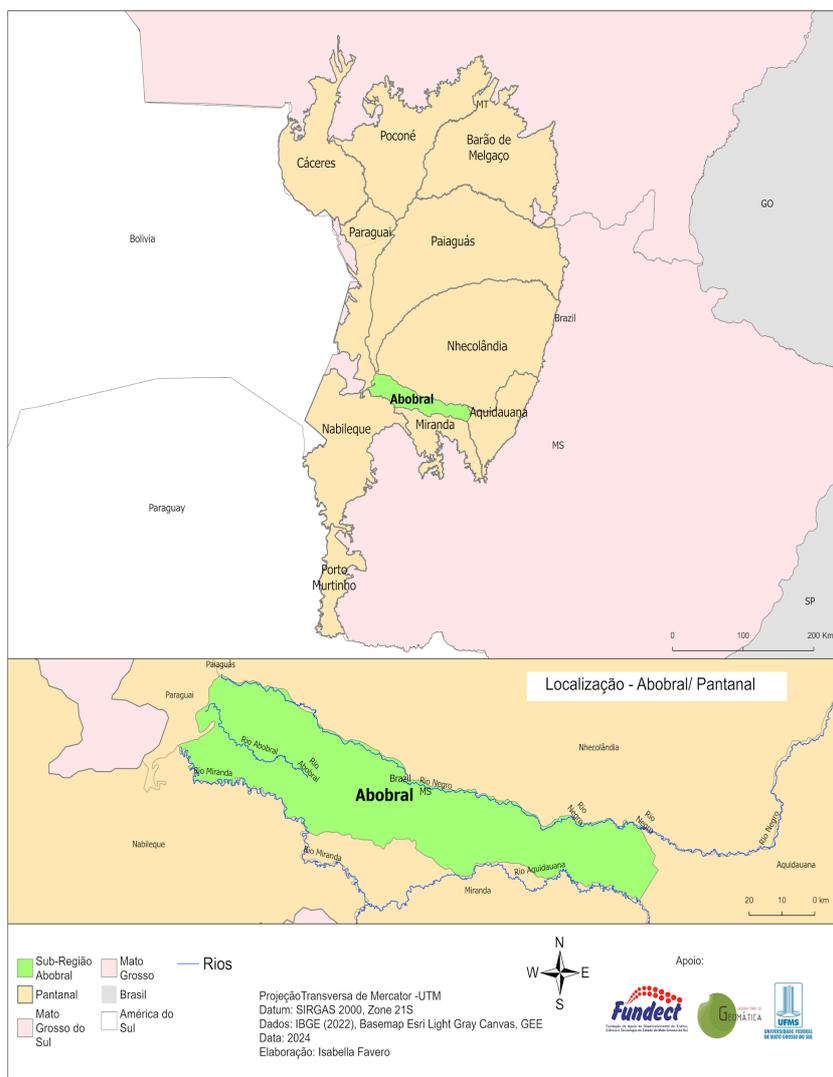
O Pantanal é uma área úmida de grande extensão geográfica, abrangendo 150.355 km², situada no centro da América do Sul e englobando partes da Bolívia, Paraguai e, predominantemente, da região Centro-Oeste do Brasil, especificamente nos estados de Mato Grosso do Sul e Mato Grosso,

figura 1. A temperatura média anual na região é de aproximadamente 25°C, enquanto a umidade relativa do ar mantém-se em torno de 82%. Segundo a classificação climática de Köppen, o Pantanal apresenta um clima tropical (Aw), caracterizado por duas estações bem definidas: um período seco durante o inverno e um período chuvoso no verão (Garcia, 1984). O período de seca ocorre entre os meses de abril e setembro, enquanto a cheia se dá de novembro a março.

O bioma do Pantanal é subdividido em 11 sub-regiões, de acordo com critérios que incluem o regime de inundação, o relevo, o tipo de solo e a vegetação predominante. As sub-regiões são: Barão do Melgaço, Cáceres e Poconé, localizadas no estado de Mato Grosso; e Abobral, Miranda, Aquidauana, Porto Murtinho, Nabileque, Paraguai, Paiaguás e Nhecolândia, situadas no estado de Mato Grosso do Sul (Silva e Abdon, 1998).

Para esta investigação, foi selecionada a sub-região Abobral, situada nas coordenadas 19°30'30.16"S 56°40'55.88"W, no sudoeste do bioma, no estado de Mato Grosso do Sul. O Abobral cobre uma área de 282.847 hectares (2.828.47 km²) e é caracterizada por uma planície baixa que, durante as cheias, transforma-se em uma planície de inundação alimentada pelos rios Abobral, Miranda e Negro (Cunha et al. 1985; Ravaglia et al. 2010).

Figura 1- Mapa de Localização



Fonte: autor, 2024

2.2 AQUISIÇÃO E PRÉ-PROCESSAMENTO DE DADOS

2.2.1 Dados de Sensoriamento Remoto

Segundo Drusch et al. (2012), o Sentinel-2 é uma ferramenta essencial para o monitoramento de mudanças em ecossistemas dinâmicos, como o Pantanal, devido à sua alta resolução espacial e temporal, além da capacidade de detectar variações nas coberturas de solo e vegetação. O uso deste sensor tem sido amplamente explorado em estudos relacionados, como os de Jiang et al. (2021), Zhao et al. (2024), Silva et al. (2022), Rodriguez et al. (2022), Zhang et al. (2023), Fernandes et al. (2022),

Srivastava et al. (2022), Liang et al. (2024), Ahmed et al. (2023) que demonstram sua eficácia na análise de ecossistemas complexos.

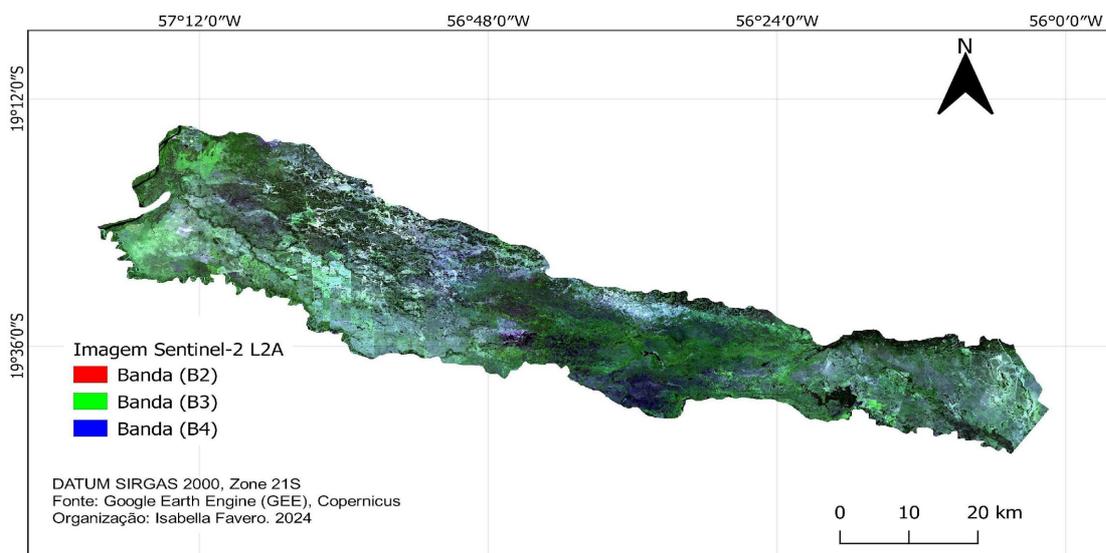
Essa ampla aplicação reforça a escolha do Sentinel-2 para a classificação de fitofisionomias, uma vez que suas características, como a alta resolução espectral e a frequência de aquisição de imagens, proporcionam dados precisos e atualizados, fundamentais para a identificação e monitoramento de diferentes tipos de vegetação em áreas de difícil acesso, como o Pantanal. A figura 2 apresenta o resultado da imagem gerada após as etapas descritas a seguir.

Para o estudo, foram utilizadas imagens de satélite do sensor *Harmonized Sentinel-2 MSI (MultiSpectral Instrument)*, no nível de processamento 2A. As bandas espectrais utilizadas incluem B2, B3, B4, B5, B6, B7, B8, B8A, B11 e B12, conforme descrito na tabela 1, com resolução espacial de 10 e 20 metros por pixel. A imagem selecionada corresponde ao mês de abril de 2022, caracterizado como um período de seca no bioma Pantanal.

O processamento e a análise dos dados foram realizados na plataforma de computação em nuvem GEE com linguagem de programação JavaScript. Nesse ambiente aplicaram-se diversas etapas de filtragem de dados por meio das funcionalidades da biblioteca da plataforma. Inicialmente, delimitou-se a área de interesse utilizando o método *filterBounds()*. Em seguida, definiu-se o intervalo temporal para selecionar as imagens correspondentes ao mês de abril por meio da função *filterDate()*.

Para assegurar a qualidade das imagens, foi aplicado um filtro baseado na cobertura de nuvens, restringindo a seleção às imagens com percentual de pixels nublados menor ou igual a 5% (*filter(ee.Filter.lte())*). Por fim, calculou-se a média de todas as imagens que atenderam aos critérios estabelecidos, resultando em uma única imagem composta representativa da área e do período analisado, utilizando o método *mean()*. As bandas de interesse foram selecionadas na imagem resultante por meio do método *select()*, reduzindo a imagem para as bandas relevantes para a análise.

Figura 2 – Imagem de Satélite: Sentinel-2



Fonte: autor, 2024

Tabela 1- Bandas Sentinel-2 L2A

	Banda	Tamanho do Pixel	Comprimento de Onda	Descrição
Sentinel-2 L2A	B2	10 metros	496,6 nm (S2A) / 492,1 nm (S2B)	Azul
	B3	10 metros	560 nm (S2A) / 559 nm (S2B)	Verde
	B4	10 metros	664,5 nm (S2A) / 665 nm (S2B)	vermelho
	B5	20 metros	703,9 nm (S2A) / 703,8 nm (S2B)	Borda Vermelha 1
	B6	20 metros	740,2 nm (S2A) / 739,1 nm (S2B)	Borda Vermelha 2
	B7	20 metros	782,5 nm (S2A) / 779,7 nm (S2B)	Borda Vermelha 3
	B8	10 metros	835,1 nm (S2A) / 833 nm (S2B)	NIR
	B8A	20 metros	864,8 nm (S2A) / 864 nm (S2B)	Borda Vermelha 4
	B11	20 metros	1613,7 nm (S2A) / 1610,4 nm (S2B)	SWIR 1
	B12	20 metros	2202,4 nm (S2A) / 2185,7 nm (S2B)	SWIR 2

Fonte: Catálogo de dados Earth Engine – organizado pelo autor, 2024

2.2.2 Classes de Interesse e Amostra de treinamento

As classes foram definidas com base nas fitofisionomias do bioma Pantanal, considerando que o objetivo deste estudo é testar o potencial dos métodos de aprendizado de máquina, sem a utilização de dados de campo, optou-se por generalizar as classes de vegetação em suas formações mais amplas que são: Formação Florestal, Formação Savânica e Formação Campestre. A classificação foi realizada com base no Manual Técnico da Vegetação do IBGE de 2020. Na Formação Florestal, destacam-se árvores altas e arbustos no estrato inferior, abrangendo variedades como Floresta Estacional Decidual e Semidecidual, Savana Florestada, Savana-Estépica Florestada e Formações Pioneiras com influência fluvial e/ou lacustre.

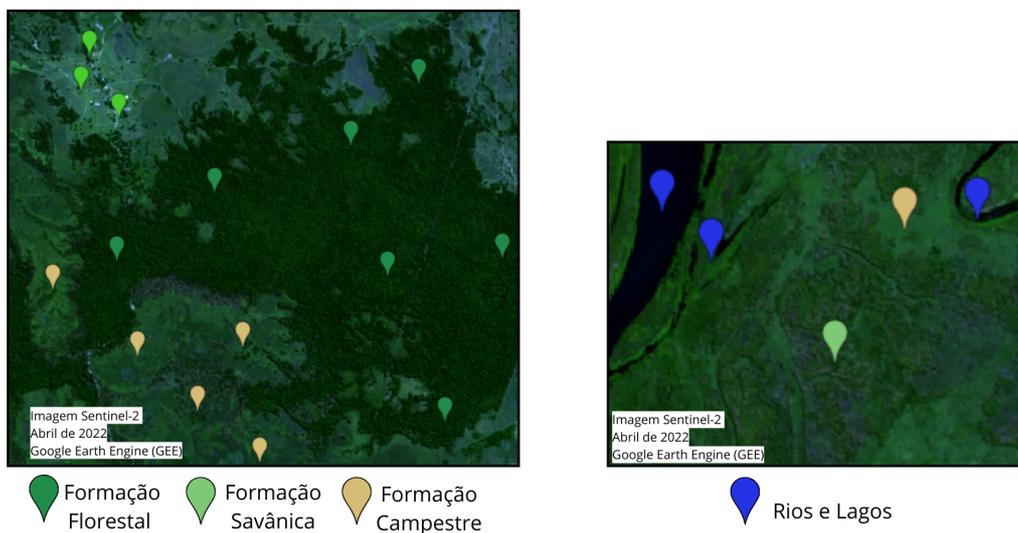
Já na Formação Savânica, predominam espécies arbóreas de pequeno porte, distribuídas de forma esparsa e inseridas na vegetação contínua de porte arbustivo e herbáceo. Aqui, a vegetação herbácea mescla-se com arbustos eretos ou decumbentes.

Por sua vez, a Formação Campestre caracteriza-se pelo domínio de um estrato herbáceo graminóide, com a presença ocasional de arbustos isolados e lenhosos raquíticos. A composição botânica é influenciada pelos gradientes edáficos e topográficos, bem como pelo manejo pastoril

(pecuária). Ademais, podem ser identificadas manchas de vegetação exótica invasora ou destinadas ao uso forrageiro, formando mosaicos com vegetação nativa.

Na etapa de anotação das amostras de treinamento, foram registradas 100 pontos representativos para cada classe de interesse. A figura 3 apresenta um exemplo de área, demonstrando o processo de anotação das classes no Google Earth Engine (GEE). Para cada ponto marcado, foram extraídas as características espectrais da imagem de satélite, as quais serviram como base para o treinamento do modelo.

Figura 3 - Classes de interesse



fonte: autor, 2024

2.3 TREINAMENTO SUPERVISIONADO

2.3.1 Suporte de Vetores de Máquinas

O Suporte de Vetores de Máquina (SVM) é um algoritmo de aprendizado supervisionado que é um dos mais populares classificadores do tipo linear. Sua abordagem consiste na separação máxima das classes através da construção de um hiperplano ideal, também denominado de superfície de decisão (Huang et al. 2002). Na plataforma do GEE, o treinamento do classificador é realizado por meio de uma variável que inclui os parâmetros *features*, *classProperty* e *inputProperties*. Essa variável é fornecida como argumento à função `ee.Classifier.libsvm().train()`, que utiliza as amostras de treinamento e as características especificadas para treinar o modelo SVM.

2.3.2 Florestas Aleatórias

Proposto pela primeira vez por Breiman (2001), algoritmo Florestas Aleatórias, são conjuntos de preditores baseada em múltiplas árvores de decisão em que cada uma é construída usando um vetor aleatório amostrado de forma independente e distribuídos uniformemente, para construir cada árvore no conjunto (Han et al. 2014). De forma similar ao SVM, para treinar o classificador FA no GEE, utilizamos os mesmos parâmetros, sendo a variável passada a função *ee.Classifier.smileRandomForest().train*.

2.3.3 Avaliação de precisão

Para avaliar o desempenho dos algoritmos na classificação das fitofisionomias, utilizou-se a análise da matriz de confusão, considerando os erros de omissão e de comissão. O erro de omissão ocorre quando pixels pertencentes à classe de interesse são classificados erroneamente em outra classe, enquanto o erro de comissão ocorre quando pixels de outras classes são atribuídos indevidamente à classe de interesse (Nascimento et al. 2009).

Além disso, foram analisados o índice Kappa e os valores de acurácia para cada classe. O índice Kappa permite uma avaliação detalhada do classificador com base na matriz de confusão, fornecendo uma métrica confiável para identificar a acurácia da classificação e caracterizar os erros. Essa abordagem contribui de forma significativa para o aprimoramento e a maior assertividade das imagens classificadas (Figueiredo; Vieira, 2007).

O índice kappa pode ser calculado através da equação:

$$K = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (X_{i+} * X_{+i})}{N^2 - \sum_{i=1}^r (X_{i+} * X_{+i})}$$

Em que:

N = número total de amostras;

$\sum_{i=1}^r X_{ii}$ = som do número das amostras corretas nas linhas e colunas;

X_{i+} = soma linear; X_{+i} soma colinear.

Tabela 2 - Valores de Índice Kappa

Índice Kappa	Concordância
<0	Sem concordância
0.00 - 0.19	Pobre
0.20 – 0.39	Fraca
0.40 – 0.59	Moderada
0.60 – 0.79	Forte
0.80 a 1.00	Excelente

Fonte: Landis e Koch, 1977

O Erro de Omissão pode ser calculado através da equação:

$$Eo = \frac{X_{i+} - X_{ii}}{X_{i+}}$$

Em que:

Eo = erros de omissão;

X_{i+} = marginal da linha;

X_{ii} = diagonal daquela linha.

O Erro de Inclusão pode ser calculado através da equação:

$$Ei = \frac{X_{+i} - X_{ii}}{X_{+i}}$$

Em que:

Ei = erros de inclusão;

X_{+i} = marginal da coluna;

X_{ii} = diagonal daquela coluna.

2.4 DADOS DE ESTOQUE DE CARBONO

2.4.1 Valores primários e secundários

Os dados primários são referentes à Formação Campestre e estão apresentados na tabela 5. Os dados secundários de estoque de carbono aéreo utilizados neste estudo foram extraídos do documento técnico da Quarta Comunicação Nacional (4CN, 2020), relatório bienal do Brasil submetido à Convenção-Quadro das Nações Unidas sobre mudança do clima, apresentado na tabela 3. Para essa

investigação, não foram utilizados todos os valores apresentados no referido relatório. Após criteriosa análise das informações, foram selecionados os dados correspondentes às categorias Fa/ Floresta Estacional Semidecidual – Aluvial e Sd/ Savana – florestada, os quais compuseram o valor final atribuído à fitofisionomia Formação Florestal.

Tabela 3 - Estoque de carbono de biomassa aérea (4CN)

Sigla/Nome da fitofisionomia	% no bioma	Categoria	Local de Estudo	(tC/ha)	Estoque carbono aéreo Metodologia/referência para cálculo biomassa/estoque
Cs/Floresta Estacional Decidual – Submontana	0,8	F	Pantanal	84,38	Equação de Brown (1997, equação 3.2.1) a partir dos valores médios de área basal e densidade de indivíduos apresentados por Lima et al. (2009)
Fa/Floresta Estacional Semidecidual – Aluvial	6,06	F	Pantanal	121,92	Utilizado o valor de biomassa aérea em floresta ripária sazonalmente inundada no Pantanal (WITTMANN et al. 2008)
TN/Contato Savana- Estépica/ Floresta Estacional	0,06	F	Pantanal	121,92	Idem Floresta Estacional Semidecidual Aluvial (Fa)
Sd/Savana – florestada	10,62	F	Pantanal	69,2	Biomassa acima do solo (EMBRAPA/PROBIO, 2002)
ST/Contato Savana/Savana - Estépica	1,11	F	Pantanal	59,82	Média dos quatro estágios sucessionais de Cambarazal no Pantanal (SCHÖNGART et al., 2011)
Td/Savana- Estépica – florestada	2,43	F	Pantanal	66,43	Média dos três valores de biomassa aérea encontrados em Padilha (2011)
Sg/Savana – Gramíneo- Lenhosa	14,93	G	Cerrado	4,17	Idem Savana – Gramíneo- Lenhosa (Sg) do Cerrado
Tg/Savana Estépica – Gramíneo - Lenhosa	6,03	G	Amazônia	3,93	Idem Savana Estépica Gramíneo Lenhosa (Tg) da Amazônia
Sp/Savana – parque	26,66	OFL	Cerrado	7,4	Idem Savana Parque (Sp) do Cerrado
Tp/Savana- Estépica – parque	3,36	OFL	Amazônia	5,95	Idem Savana Estépica (Tp) da Amazônia

Fonte: 4 CN, 2020

No que se refere à fitofisionomia Formação Savânica, observou-se que os dados apresentados no relatório utilizaram valores de referência provenientes de outros biomas. Diante disso, optou-se por adotar valores descritos no estudo de Barros et al. (2022), destacado na tabela 4, os quais também foram empregados para complementar os dados da Formação Florestal, dispostos na tabela 5.

Tabela 4 - Estoque de carbono de biomassa aérea (Barros, J.H.S et al. 2022)

Sigla/Nome da fitofisionomia	DAP (cm)	H (m)	AD (plantas ha ⁻¹)	CS ± DP (Mg ha ⁻¹) e (classificações médias)	
Ps/ cerrado parque	6.77	5.87	2855	52,3	Formação Savânica
gws/ cerrado gramíneo-lenhoso	7.65	3.55	1367	26,6	Formação Savânica
ssf/ florestal estacional semidecídua	10.49	8.00	1374	103,9	Formação Florestal
ssc/ cerrado stricto sensu	45483	7.86	1338	108,4	Formação Savânica
ws/ cerrado arborizado	10.94	7.62	2375	131,4	Formação Florestal
rf/ mata ciliar	12.53	7.76	1700	184,1	Formação Florestal

Fonte: Barros, J.H.S et al. 2022

2.4.2 Estoque mínimo, médio e máximo de tC/ha

A tabela 5 apresenta os valores mínimos, médios e máximos do estoque de carbono, expresso em toneladas por hectare, para cada fitofisionomia analisada. Esses resultados decorrem da análise detalhada no tópico 3.4, evidenciando as variações do estoque de carbono nas diferentes formações vegetais, fornecendo informações cruciais para a compreensão das dinâmicas de armazenamento de carbono na região estudada.

Tabela 5 - Estoque de carbono de biomassa aérea em fitofisionomias no bioma Pantanal

Nome da fitofisionomia	Referência	Mínimo tC/ha	Médio tC/ha	Máximo tC/ha
Formação Florestal	Barros, J.H.S et al. + 4CN	69.2	122.104	184.1
Formação Savânica	Barros, J.H.S et al,	26.6	62.43	108.4
Formação Campestre	Dados de Campo	2.344	5.82	14.248

Fonte: organizado pelo autor, 2024

3 RESULTADO E DISCUSSÃO

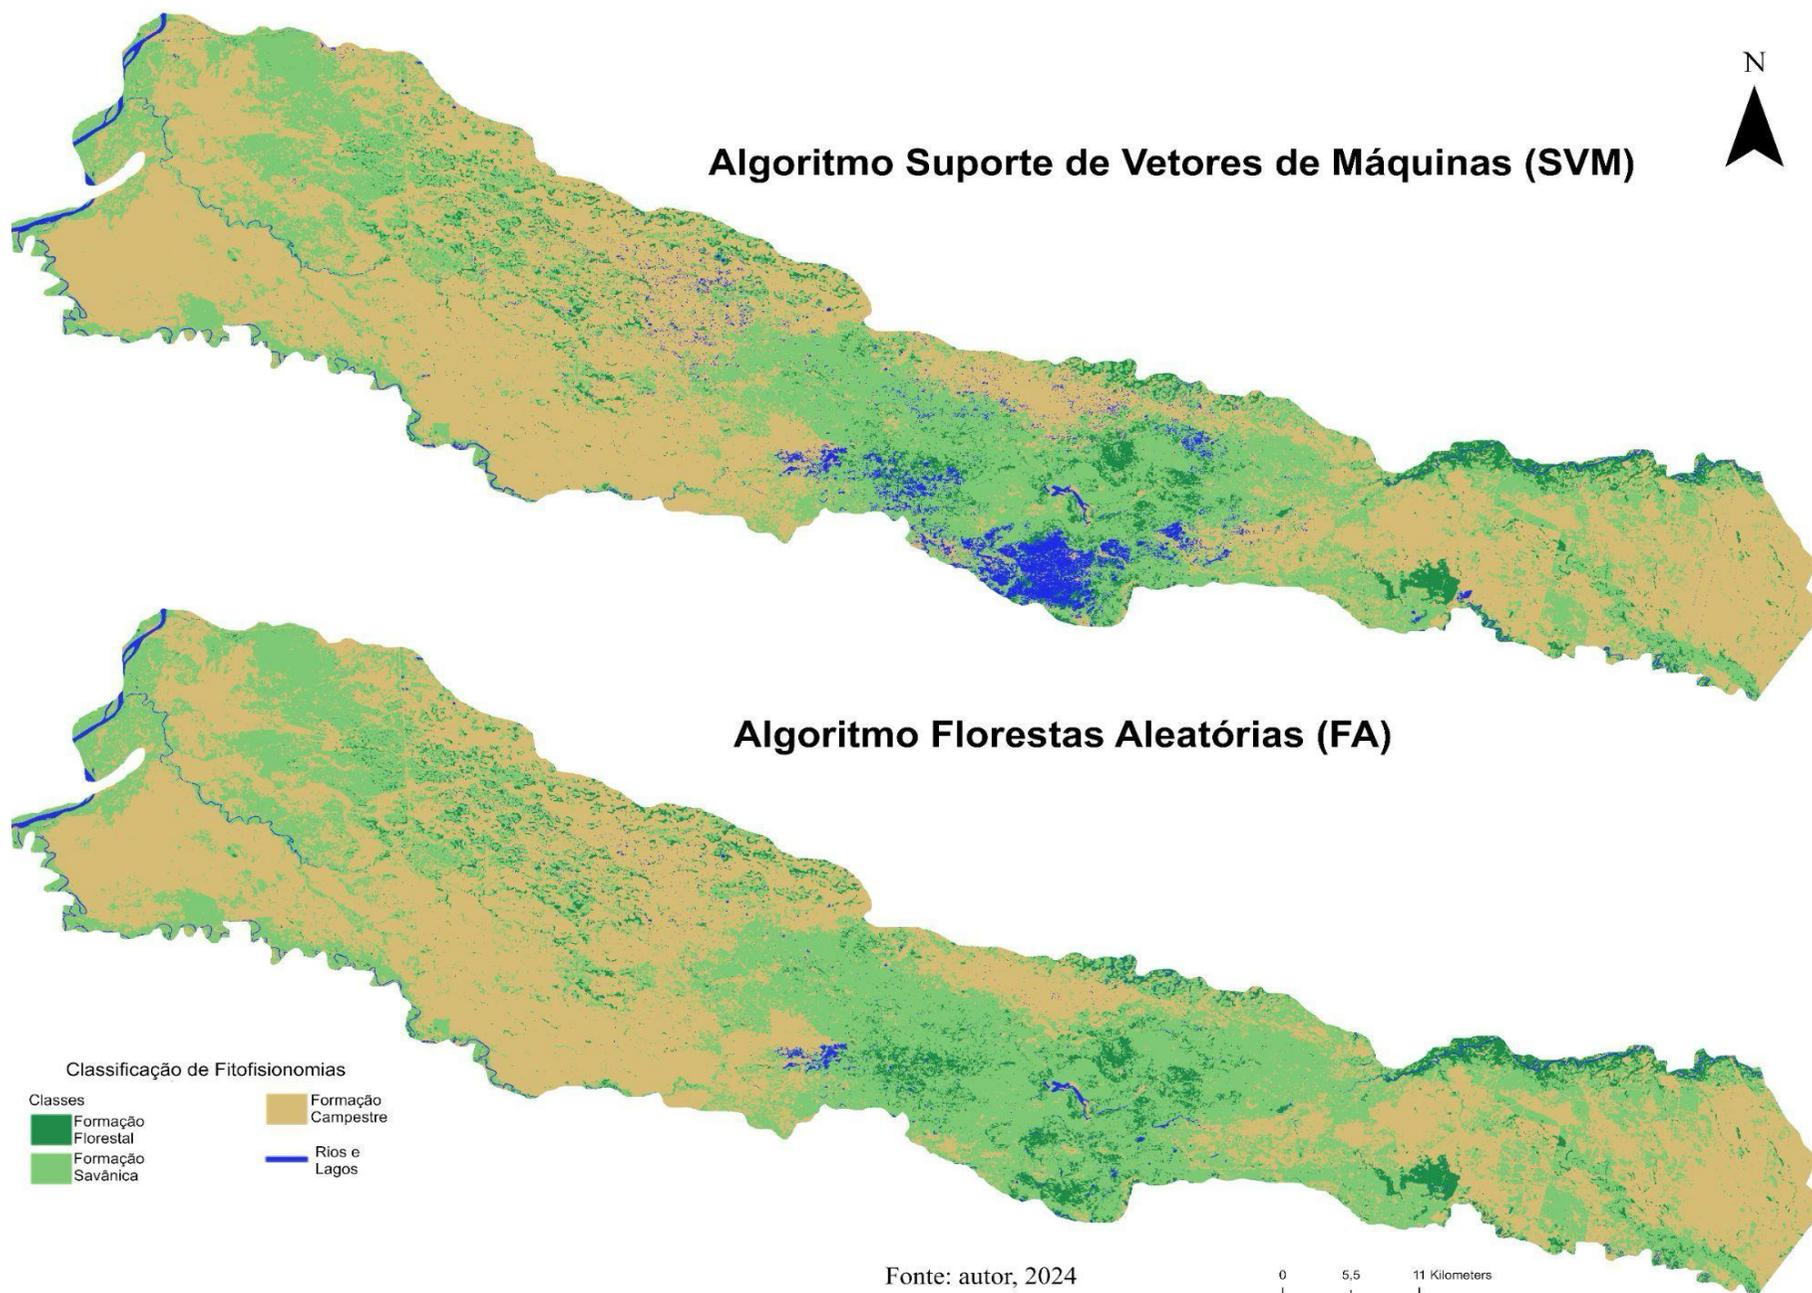
Os resultados da classificação das fitofisionomias da sub-região do Abobral são apresentados por meio de mapas temáticos, conforme ilustrado na Figura 3. A análise comparativa entre os algoritmos Florestas Aleatórias (FA) e Suporte de Vetores de Máquinas (SVM), fundamentada na matriz de confusão, nos índices de acurácia (figura 4), concordância do coeficiente kappa (tabela 7) e nos erros de classificação (tabela 8), proporciona uma visão detalhada sobre o desempenho de cada modelo na identificação das diferentes fitofisionomias, que incluem as classes Florestal, Savânica, Campestre, bem como a classe Rios e Lagos.

A matriz de erros, por sua vez, destaca dois tipos principais de falhas na classificação: o erro de omissão (Eo), que ocorre quando uma classe não é identificada corretamente, e o erro de inclusão (Io), que se refere à atribuição equivocada de uma área em uma classe distinta daquela que realmente representa. Tais falhas são cruciais para a avaliação de aprimoramento dos modelos de classificação, uma vez que indicam as limitações na capacidade dos algoritmos de discriminar adequadamente entre as diferentes classes de uso do solo.

3.1 CLASSIFICAÇÃO DAS FITOFISIONOMIAS

A Figura 3 ilustra a classificação resultante da aplicação dos classificadores de aprendizado de máquina em um processo de classificação supervisionada.

Figura 4 - Classificação de Fitofisionomias na sub-região Abobral no pantanal sul-matogrossense



A Tabela 6 apresenta as áreas em hectares das fitofisionomias analisadas no estudo, que serviram como fundamento para a elaboração do mapa temático de estoque de carbono da biomassa aérea, conforme exposto na Figura 5. A comparação das áreas de fitofisionomias estimadas pelos algoritmos revela diferenças significativas nas categorias analisadas, na Formação Florestal, o SVM estima uma área 5.061 ha maior do que as Florestas Aleatórias, indicando uma possível tendência de superestimação dessa categoria. Por outro lado, na Formação Savânica, as Florestas Aleatórias apresentam uma área 17.495 ha superior, o que pode refletir maior sensibilidade desse algoritmo às características dessa fitofisionomia. Na Formação Campestre, o SVM volta a estimar uma área maior, com uma diferença de 7.374 ha. Apesar dessas variações, a diferença total entre os dois algoritmos é relativamente pequena, sendo as Florestas Aleatórias 5.060 ha superiores ao SVM, o que corresponde a cerca de 1,84% do total. Esses resultados sugerem que, enquanto os algoritmos diferem nas estimativas específicas, suas somas totais são próximas, refletindo abordagens distintas na classificação dos dados.

Tabela 6 - Área em hectares

Algoritmos	Suporte de Vetor de Máquina	Florestas Aleatórias
	Área (ha)	Área (ha)
Formação Florestal	55.856	50.795
Formação Savânica	116.036	133.531
Formação Campestre	103.399	96.025
Total	275.291	280.351

fonte: o autor (2024)

3.2 ÍNDICE KAPPA

Na análise do índice kappa, o classificador Suporte de Vetores de Máquinas apresentou uma excelente concordância, com um valor de 0,81, superando o classificador Florestas Aleatórias, que registrou 0,72, indicando uma concordância forte. Esses resultados indicam

que, no contexto deste estudo, o SVM apresentou desempenho superior ao FA na classificação de fitofisionomias corroborando sua eficácia em contextos similares.

Tabela 7 - Índice Kappa

Classificador	Índice Kappa	Concordância
Suporte de Vetor de Máquina	0,81	Excelente
Florestas Aleatórias	0,72	Forte

fonte: o autor (2024)

3.3 ACURÁCIA

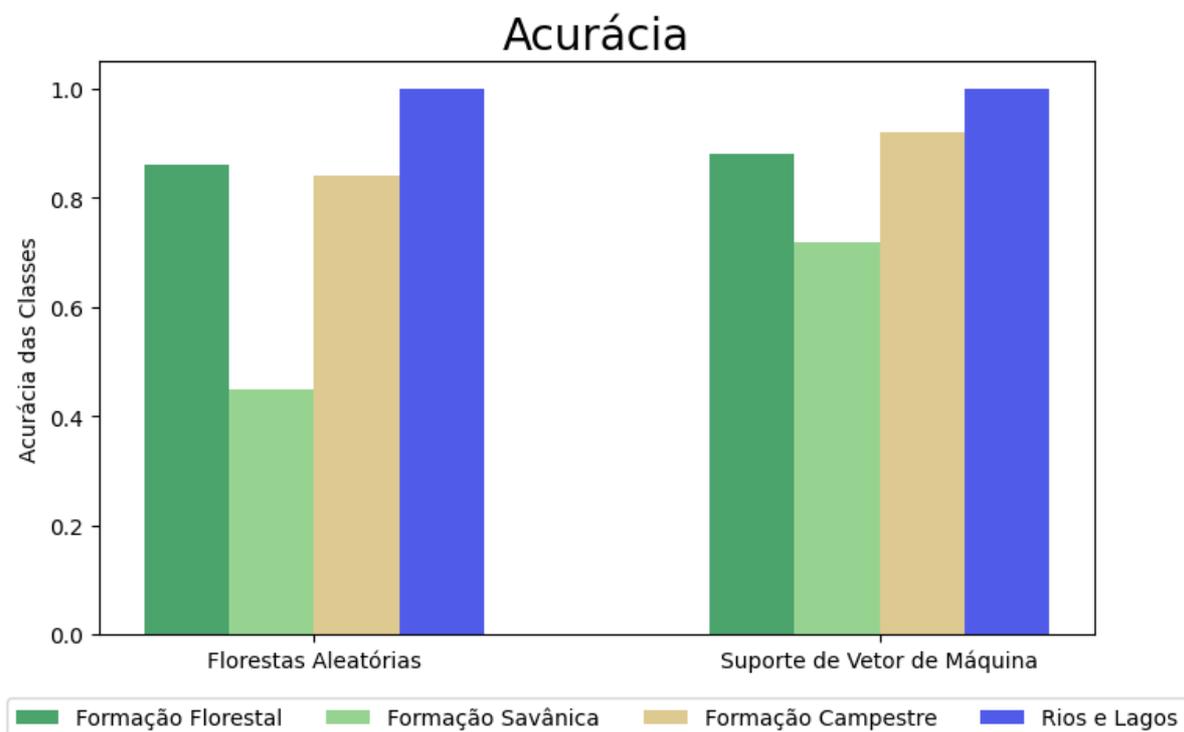
A figura 5 mostra a acurácia das classes nos dois métodos de classificação empregados, a análise dos resultados revelou diferenças significativas no desempenho dos métodos, assim como variações no reconhecimento das diferentes classes.

No caso do classificador FA, a classe "Rios e Lagos" apresentou a maior acurácia, próxima de 1.0, demonstrando que este método é eficiente em identificar essa classe no contexto analisado. As classes Formação Florestal e Formação Campestre também apresentam bom desempenho, com acurácia superior a 0.8. Contudo, a classe Formação Savânica apresentou a menor acurácia, em torno de 0.5, o que sugere limitações na distinção desta categoria, possivelmente devido à sua alta heterogeneidade ou sobreposição de características com outras classes, dificultando sua separação.

Por outro lado, o algoritmo SVM apresentou desempenho geral superior, com as classes Rios e Lagos e Formação Campestre alcançando acurácia próxima de 1.0, enquanto, as classes Formação Savânica e Florestal obtiveram 0,72 e 0,88, respectivamente. Este desempenho superior pode ser atribuído à capacidade do SVM de maximizar as margens de separação entre as classes, sendo mais eficiente na discriminação de classes com características semelhantes. Esses resultados destacam a robustez e a eficácia do SVM no mapeamento de áreas com características complexas e heterogêneas, como as investigadas na sub-região abobral no bioma Pantanal. A melhora observada na acurácia da classe Formação Savânica, em comparação ao

desempenho do classificador FA, reforça a adequação do SVM para aplicações em ambientes de alta complexidade.

Figura 5 - Acurácia das classes



fonte: o autor, 2024

3.4 MATRIZ DE ERROS DOS ALGORITMOS

O modelo de Florestas Aleatórias apresentou um desempenho geral satisfatório na classificação das formações Florestal e Campestre, com taxas de erro de omissão de 29,78% e 4,46%, respectivamente. Esses valores indicam que o modelo foi eficiente na identificação da classe Campestre, mas teve maior dificuldade em identificar as áreas da classe Florestal. Para a classe Rios e Lagos, o desempenho também foi bom, com um erro de omissão de 15%, sugerindo uma boa capacidade de classificação dessa categoria. No entanto, o maior desafio do classificador foi na classificação da Formação Savânica, que apresentou o maior erro de omissão (38,46%), evidenciando a dificuldade do modelo em reconhecer áreas desta classe.

Além disso, a Formação Savânica também registrou o maior erro de inclusão (54,71%), o que revela que o algoritmo frequentemente classifica as áreas de outras classes como pertencentes à Savânica. Esse padrão reflete uma confusão significativa do modelo na discriminação dessa formação específica, possivelmente devido à sua complexidade ou semelhança com outras classes. Por outro lado, para as demais classes, o modelo apresentou taxas de erro de inclusão relativamente baixas, sugerindo um desempenho mais equilibrado.

Por sua vez, o modelo de SVM demonstrou um desempenho superior em algumas classes. Na Formação Florestal e Formação Campestre, o SVM registrou erros de omissão de 10,92% e 7,08%, respectivamente, valores consideravelmente menores em comparação ao classificador Florestas Aleatórias. Além disso, o erro de inclusão da Formação Florestal foi de apenas 11,66%, reforçando a capacidade do modelo em diferenciar essa classe de outras. Na classificação da Formação Savânica, o SVM também superou o algoritmo FA, com um erro de omissão de 24,44%, embora ainda significativo. Isso sugere que, embora o SVM enfrente desafios na identificação dessa formação, ele apresenta maior precisão relativa.

Uma das principais forças do SVM foi observada na classificação de Rios e Lagos, onde o modelo obteve um erro de inclusão de 10%, indicando uma excelente capacidade de evitar classificações incorretas dessa classe. Contudo, o erro de omissão para Rios e Lagos foi relativamente elevado (30%), destacando dificuldades em identificar todas as áreas desta classe.

Tabela 8 - Erros de Omissão e Inclusão

Algoritmos	Formação Florestal		Formação Savânica		Formação Campestre		Rios e Lagos	
	Eo (%)	Io(%)	Eo (%)	Io(%)	Eo (%)	Io(%)	Eo (%)	Io(%)
Florestas Aleatórias	29,78	13,15	38,46	54,71	4,46	15,07	10	15
Suporte de Vetor de Máquinas	10,92	11,66	24,44	27,65	7,08	7,08	30	10

fonte: o autor (2024)

Eo – Erro de Omissão; Io – Erro de Inclusão

3.5 ESTIMATIVA DE ESTOQUE DE CARBONO DE BIOMASSA AÉREA COM DADOS PRIMÁRIO E SECUNDÁRIOS

Na figura 6, é apresentado o mapa temático de estoque mínimo, médio e máximo de carbono de biomassa aérea das fitofisionomias do bioma Pantanal, na sub-região do Abobral.

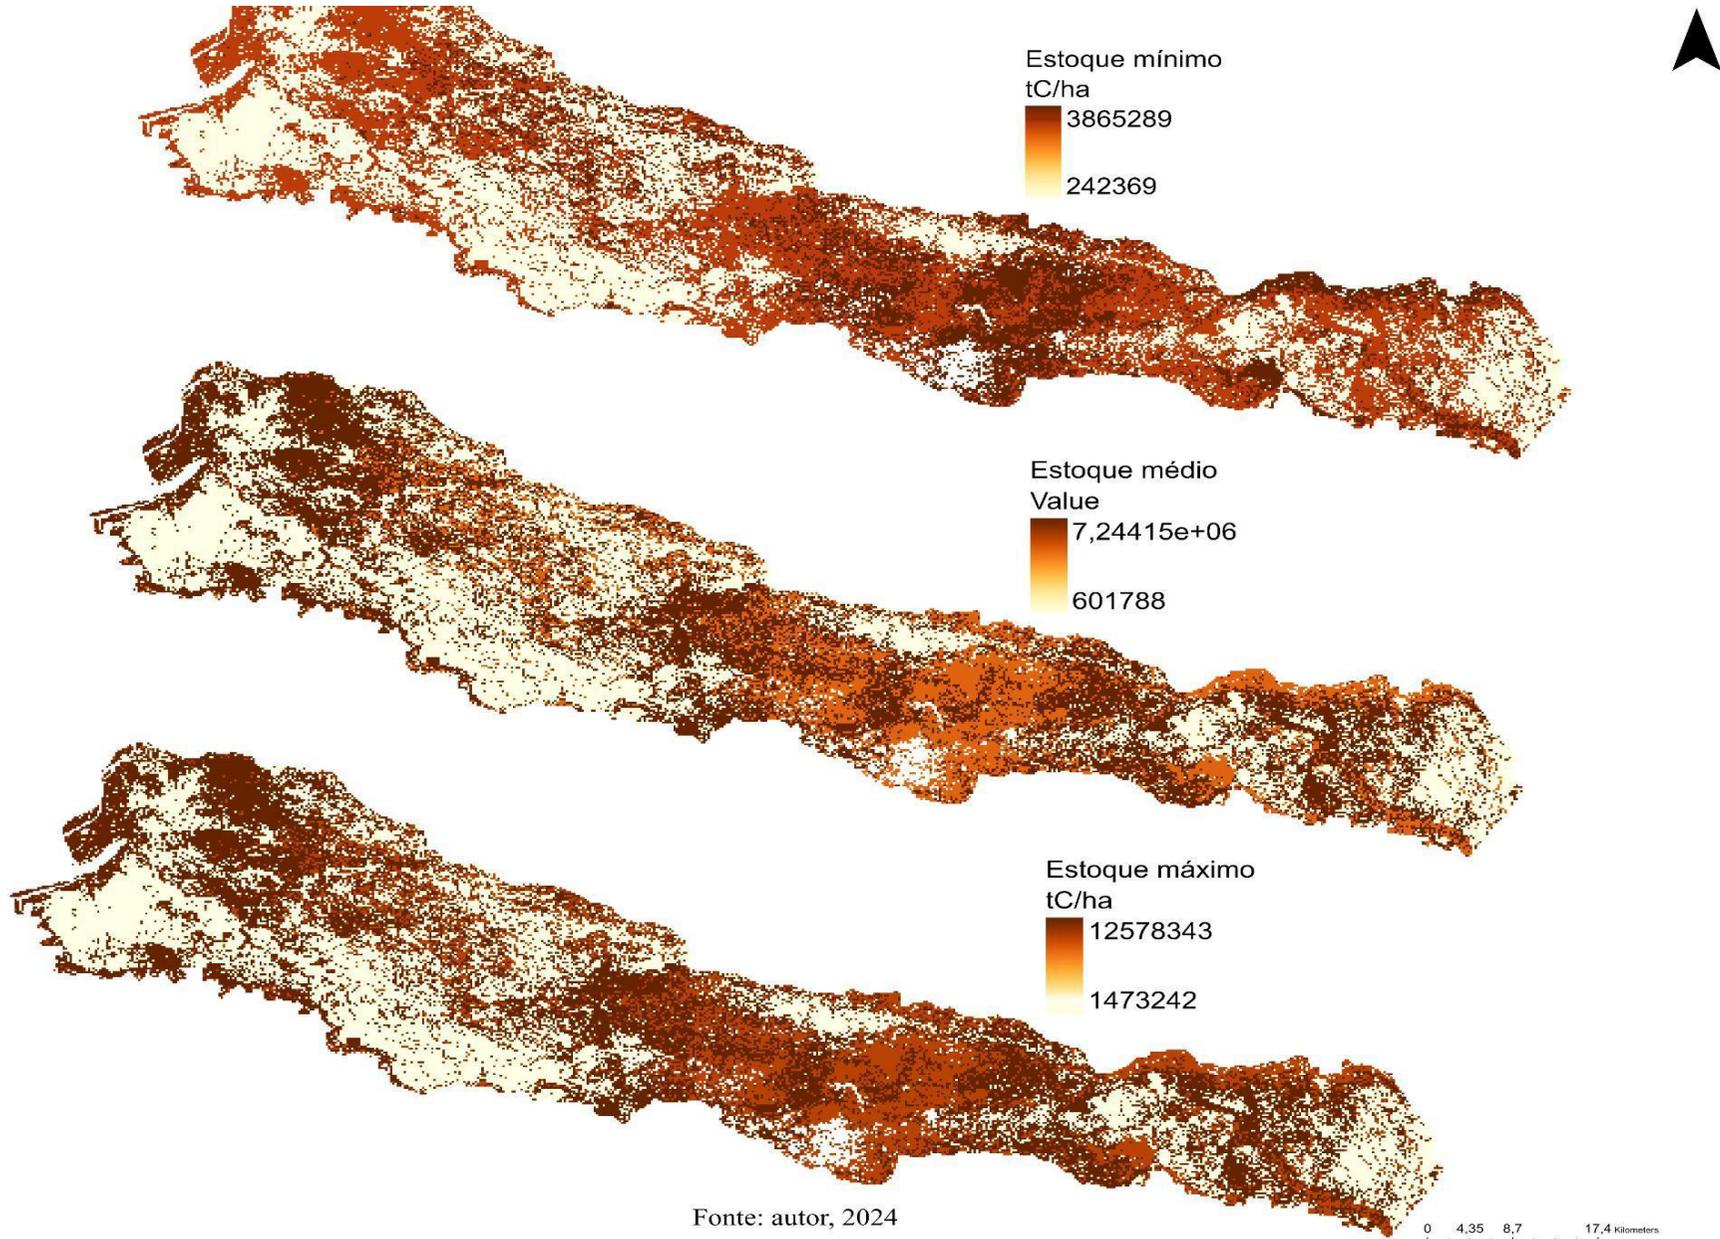
Na tabela 9, são apresentados os valores estimados para cada fitofisionomia analisada, para cada classe, foram registrados os valores mínimos, médios e máximos do estoque calculado, permitindo a obtenção do total correspondente às fitofisionomias analisadas.

Tabela 9 - Estoque de carbono da biomassa aérea em fitofisionomias no Abobral/ Pantanal

Nome da fitofisionomia	Área (ha)	Mínimo tC/ha	Médio tC/ha	Máximo tC/ha
Formação Florestal	55.856	3.8652 10 ⁸	682.03 10 ⁸	102.83 10 ⁸
Formação Savânica	116.036	3.0865 10 ⁸	72441 10 ⁸	12578 10 ⁸
Formação Campestre	103.399	0.0024236 10 ⁸	60.176 10 ⁸	1.4732 10 ⁸
Total	219.490	6.9531236 10⁸	73183.206 10⁸	12782.3032 10⁸

Fonte: autor, 2024

Figura 6 - Mapa temático de estoque de carbono de biomassa aérea em fitofisionomias na sub-região Abobral do Pantanal sul-matogrossense



Fonte: autor, 2024

Ao analisar os valores de estoque de carbono, verifica-se que a formação florestal exibe uma variação que vai de um mínimo de 3.8652×10^8 tC/ha, passando por uma média 682.03×10^8 tC/ha, até um máximo de 102.83×10^8 tC/ha. Essa fitofisionomia apresenta um estoque médio de carbono notavelmente elevado, o que indica a eficácia dessa formação em capturar e reter carbono na biomassa acima do solo. Apesar de cobrir a menor área entre as três fitofisionomias, a capacidade da vegetação arbórea de armazenar grandes quantidades de carbono é evidenciada pelos valores mínimos e máximos observados. Esta capacidade pode ser atribuída à sua estrutura de vegetação densa e à presença de árvores de grande porte, que são altamente eficientes no armazenamento de carbono.

A formação savânica apresenta um estoque de carbono mínimo de 3.0865×10^8 tC, uma média de 72441×10^8 tC/ha, e um máximo de 12578×10^8 tC/ha. Esta formação abrange a maior área geográfica e, conseqüentemente, possui o maior estoque médio total de carbono, conferindo-lhe o maior potencial de armazenamento de carbono entre as três fitofisionomias analisadas. Embora os valores de estoque por hectare sejam comparáveis aos da formação florestal, a ampla extensão da área coberta pela formação savânica resulta em um total de carbono armazenado superior.

Em contraste, a formação campestre apresenta a menor capacidade de armazenamento de carbono por hectare, com variações de 0.0024236×10^8 tC/ha no mínimo, uma média de 60.176×10^8 tC/ha, e um máximo de 1.4732×10^8 tC/ha. Apesar de abranger uma área significativa de 103.399 hectares, o estoque total de carbono da formação campestre é inferior aos das formações florestal e savânica. Esse estoque relativamente baixo pode ser atribuído à vegetação rasteira e à menor densidade de biomassa.

Essa disparidade nos níveis de estoque de carbono entre as diferentes formações pode ser atribuída a uma variedade de fatores, incluindo a densidade da vegetação, a diversidade de espécies, às condições climáticas e os padrões de uso da terra. Por exemplo, a presença de árvores de grande porte na formação florestal pode contribuir significativamente para o armazenamento de carbono, enquanto a formação de campo, com sua vegetação mais rasteira pode ter uma capacidade de sequestro de carbono mais limitada.

4 CONCLUSÃO

O presente estudo analisou a classificação das fitofisionomias na sub-região do Abobral, no bioma Pantanal, utilizando os algoritmos Florestas Aleatórias (FA) e Suporte a Vetores de Máquinas (SVM), além de avaliar o estoque de carbono nas diferentes formações vegetais. Os resultados evidenciaram a superioridade do algoritmo SVM, que apresentou maior acurácia geral, especialmente na classificação de classes mais complexas e heterogêneas, como a Formação Savânica, superando o FA em termos de índice Kappa (0,81 contra 0,72). Embora ambos os métodos enfrentem desafios na discriminação de determinadas classes, o SVM demonstrou maior eficiência na redução dos erros de omissão e inclusão, consolidando-se como uma ferramenta mais eficaz para o mapeamento detalhado das fitofisionomias investigadas.

A análise do estoque de carbono revelou diferenças significativas entre as fitofisionomias. A formação florestal destacou-se pelo elevado estoque médio de carbono por hectare, evidenciando sua vegetação densa e presença de árvores de grande porte na captura e retenção de carbono. Por sua vez, a formação savânica, que abrange a maior área territorial, apresentou o maior estoque total de carbono, refletindo a influência da extensão geográfica na acumulação de biomassa, mesmo com valores médios por hectare similares aos da formação florestal. Em contraste, a formação campestre apresentou a menor capacidade de armazenamento de carbono por hectare, o que resultou em um estoque total inferior, apesar de sua ampla distribuição espacial.

Cabe destacar que a análise foi conduzida no mês de abril, período correspondente à estação de estiagem. Para uma compreensão mais abrangente do estoque de carbono, é crucial incluir avaliações durante a estação de cheia, quando as condições da vegetação e do solo podem alterar significativamente os níveis de carbono armazenado. Essa abordagem sazonal proporcionará uma visão mais completa da dinâmica de carbono e das variações ao longo do ano.

A utilização do Google Earth Engine (GEE) mostrou-se uma ferramenta eficiente para o processamento e análise de extensas áreas geográficas, permitindo um monitoramento contínuo e detalhado das fitofisionomias em diferentes períodos. Essa tecnologia não apenas facilita a obtenção de dados mais precisos e atualizados, mas também contribui para o avanço do conhecimento sobre a variação temporal do estoque de carbono.

Para futuros estudos, recomenda-se a integração de dados sazonais, abrangendo tanto a estação de seca quanto a de cheia, a fim de obter uma análise mais completa do potencial de armazenamento de carbono das diferentes fitofisionomias. A combinação de técnicas de sensoriamento remoto com análises temporais aprofundará a compreensão das flutuações sazonais e dos impactos climáticos sobre o armazenamento de carbono. Essa abordagem subsidiará estratégias de manejo e conservação mais eficazes, fundamentais para a gestão sustentável do bioma Pantanal.

5 REFERÊNCIAS

1. ACHUCARRO, Iris Carolina Valdez; ANDRIEU, Julien; BOUISSOU, Stéphane. Land cover dynamics in the Paraguayan Pantanal in the timeframe 1987–2020. *Regional Environmental Change*, v. 23, n. 1, p. 11, 2023. Disponível em: <<https://link.springer.com/10.1007/s10113-022-01990-4>>.
2. ADAMOLI, Jorge. O Pantanal e suas relações fitogeográficas com os cerrados. Discussão sobre o conceito de “Complexo do Pantanal”. In: Anais do XXXII Congresso Nacional de Botânica. Sociedade Botânica do Brasil, Teresina, PI. p.109-119, 1981.
3. ARIEIRA, Julia; KARSSENBERG, D.; DE JONG, Steven Michael; et al. Integrating field sampling, geostatistics and remote sensing to map wetland vegetation in the Pantanal, Brazil. *Biogeosciences*, v. 8, n. 3, p. 667–686, 2011. Disponível em: <<https://bg.copernicus.org/articles/8/667/2011/>>.
4. BARROS, João Henrique S.; AYRES, Fábio Martins; CHAMBÓ, Emerson Dechechi; et al. Aboveground carbon stock in phytophysiognomies of the Southeast Pantanal, Brazil. *Brazilian Journal of Botany*, v. 45, n. 2, p. 755–762, 2022. Disponível em: <<https://link.springer.com/10.1007/s40415-022-00808-1>>.
5. BRASIL. Ministério da Ciência, Tecnologia e Inovação. Quarta Comunicação Nacional (4CN) e Relatórios de Atualização Bienal do Brasil à Convenção-Quadro das Nações Unidas sobre Mudança do Clima. Versão de novembro. Brasília: MCTI, 2020.
6. BRAUN, Andreas Christian; WEIDNER, Uwe; HINZ, Stefan. Support Vector Machines for Vegetation Classification A Revision. *Photogrammetrie - Fernerkundung - Geoinformation*, v. 2010, n. 4, p. 273–281, 2010. Disponível em: <http://www.schweizerbart.de/papers/pfg/detail/2010/75235/Support_Vector_Machines_for_Vegetation_Classification?af=crossref>.
7. BREIMAN, Leo; CUTLER, Adele. An introduction to random forest for beginners. 1. ed. Califórnia, Estados Unidos: Salford Systems, 2014. 71p
8. CAMARGO, Flávio F.; SANO, Edson E.; ALMEIDA, Cláudia M.; et al. A Comparative Assessment of Machine-Learning Techniques for Land Use and Land Cover Classification of the Brazilian Tropical Savanna Using ALOS-2/PALSAR-2 Polarimetric Images. *Remote Sensing*, v. 11, n. 13, p. 1600, 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/13/1600>>.

9. CUNHA, Noel Gomes Da; POTT, Arnildo; GONÇALVES, Assis Rosa. Solos calcimórficos da sub-região do Abobral, Pantanal Mato-grossense. Corumbá: EMBRAPA - CPAP. 52p. 1985.
10. DAMASCENO-JUNIOR, Geraldo Alves; BEZERRA, Maria Angelica de Oliveira.; BORTOLOTTI, Ieda Maria; POTT, Arnildo. Aspectos florísticos e fitofisionômicos dos capões do Pantanal do Abobral. In: SIMPÓSIO SOBRE RECURSOS NATURAIS E SÓCIO-ECONÔMICOS DO PANTANAL, 2: MANEJO E CONSERVAÇÃO. Corumbá, 1996. Anais... Corumbá: Embrapa Pantanal, 1999 p. 203-214.
11. DUARTE, Priscila Gabriela da Silva. Métodos de Machine Learning Aplicados à Classificação do Uso e Ocupação do Solo Na Microbacia Do Lago Igapó Na Cidade De Londrina/Pr. 2022. 77 p. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Engenharia Ambiental, Universidade Tecnológica Federal do Paraná (UTFPR), Londrina, 2022.
12. DRUSCH, Matthias; DEL BELLO, Umberto; CARLIER, Simon; et al. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, v. 120, p. 25–36, 2012. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0034425712000636>>.
13. ESRI. Arcgis explorer website. ArcGIS PRO 3.0.0, 2022. <http://www.esri.com/software/arcgis/explorer/index.html>, 2022.
14. ESA. European Space Agency (ESA). Europe: Earth Engine Data Catalog, 2 imagens de satélite, color. Satélite Sentinel-2, instrumento MSI. Intervalo de tempo: 01/04/2024 a 30/04/2024.
15. EVANS, Teresa Lynne; COSTA, Maycira.; TOMAS, Walfrido Moraes; et al. Large-scale habitat mapping of the Brazilian Pantanal wetland: A synthetic aperture radar approach. *Remote Sensing of Environment*, v. 155, p. 89–108, 2014. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0034425714001576>>. FERNÁNDEZ, Darwin Gómez; López, Rolando Salas; BRICEÑO, Nilton B. Rojas; et al. Dynamics of the Burlan and Pomacochas Lakes Using SAR Data in GEE, Machine Learning Classifiers, and Regression Methods. *ISPRS International Journal of Geo-Information*, v. 11, n. 11, p. 534, 2022. Disponível em: <<https://www.mdpi.com/2220-9964/11/11/534>>.
16. FURUYA, Danielle Elis Garcia; AGUIAR, João Alex Floriano; ESTRABIS, Nayara V.; et al. A Machine Learning Approach for Mapping Forest Vegetation in Riparian Zones in an Atlantic Biome Environment Using Sentinel-2 Imagery. *Remote Sensing*, v. 12, n. 24, p. 4086, 2020. Disponível em: <<https://www.mdpi.com/2072-4292/12/24/4086>>.
17. GARCIA, Eduardo Alfonso Cadavid. O clima no Pantanal Mato-Grossense. *Circular Técnica*. Corumbá-MS. n. 14. p. 36 1984.
18. GOOGLE. Google Earth Engine, 2024. <https://earthengine.google.com/>
19. GORLICK, Noel; HANCHER, Matt; DIXON, Mike; et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18–27, 2017. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0034425717302900>>.
20. GXOKWE, Siyamthanda; DUBE, Timothy; MAZVIMAVI, Dominic. Leveraging Google Earth Engine platform to characterize and map small seasonal wetlands in the semi-arid environments of South Africa.

- Science of The Total Environment, v. 803, p. 150139, 2022. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0048969721052141>>..
21. HAN, Jiawei; KAMBER, Micheline; PEI, Jian. Data mining: concepts and techniques. 3. ed. Estados Unidos: Morgan Kaufmann and Elsevier, 2012. 673p. Disponível em: <<https://www.sciencedirect.com/book/9780123814791/data-mining-concepts-and-techniques?via=ihub=>>>.
 22. HÄNSCH, Ronny; SCHULZ, Karsten; SÖRGEL, Uwe. Machine learning methods for remote sensing applications: an overview. In: MICHEL, Ulrich; SCHULZ, Karsten (Orgs.). Earth Resources and Environmental Remote Sensing/GIS Applications IX. Berlin, Germany: SPIE, 2018, p. 1. Disponível em: <<https://www.spiedigitallibrary.org/conference-proceedings-of-spie/10790/2503653/Machine-learning-methods-for-remote-sensing-applications-an-overview/10.1117/12.2503653.full>>.
 23. HANSEN, Matthew. C; POTAPOV, Peter; MOORE, Rebecca; et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. Science, v. 342, n. 6160, p. 850–853, 2013. Disponível em: <<https://www.science.org/doi/10.1126/science.1244693>>.
 24. HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. International Journal of Remote Sensing, v. 23, n. 4, p. 725–749, 2002. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/01431160110040323>>. Acesso em: 29 nov. 2024.
 25. IBGE. Instituto Brasileiro de Geografia e Estatísticas. Manual Técnico da Vegetação Brasileira. 2. ed. rev. ampl. Rio de Janeiro: IBGE, 2012. ISBN 978-85-240-4272-0 (meio impresso). ISSN 0103-9598.
 26. JIANG, Fugen; ZHAO, Feng; MA, Kaisen; et al. Mapping the Forest Canopy Height in Northern China by Synergizing ICESat-2 with Sentinel-2 Using a Stacking Algorithm. Remote Sensing, v. 13, n. 8, p. 1535, 2021. Disponível em: <<https://www.mdpi.com/2072-4292/13/8/1535>>.
 27. LANDIS, JR; Koch GG. The measurement of observer agreement for categorical data. Biometrics. 1977 Mar;33(1):159-74. PMID: 843571.
 28. LIANG, Jiaxi; SAWUT, Mamat; CUI, Jintao; et al. Object-oriented multi-scale segmentation and multi-feature fusion-based method for identifying typical fruit trees in arid regions using Sentinel-1/2 satellite images. Scientific Reports, v. 14, n. 1, p. 18230, 2024. Disponível em: <<https://www.nature.com/articles/s41598-024-68991-7>>. Acesso em: nov. 2024.
 29. LIU, Lizhi; GUO, Ying; LI, Yu; et al. Comparison of Machine Learning Methods Applied on Multi-Source Medium-Resolution Satellite Images for Chinese Pine (*Pinus tabulaeformis*) Extraction on Google Earth Engine. Forests, v. 13, n. 5, p. 677, 2022. Disponível em: <<https://www.mdpi.com/1999-4907/13/5/677>>.
 30. M, ARPITHA; AHMED, S A; N, HARISHNAIKA. Land use and land cover classification using machine learning algorithms in google earth engine. Earth Science Informatics, v. 16, n. 4, p. 3057–3073, 2023. Disponível em: <<https://link.springer.com/10.1007/s12145-023-01073-w>>.
 31. MAGALHÃES, Ivo Augusto Lopes; DE CARVALHO JÚNIOR, Osmar Abílio; DE CARVALHO, Osmar Luiz Ferreira; et al. Comparing Machine and Deep Learning Methods for the Phenology-Based Classification of Land Cover Types in the Amazon Biome Using Sentinel-1 Time Series. Remote Sensing, v. 14, n. 19, p. 4858, 2022. Disponível em: <<https://www.mdpi.com/2072-4292/14/19/4858>>.

32. MATYUKIRA, Charles; MHANGARA, Paidamwoyo. Advances in vegetation mapping through remote sensing and machine learning techniques: a scientometric review. *European Journal of Remote Sensing*, v. 57, n. 1, p. 2422330, 2024. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/22797254.2024.2422330>>.
33. MOREIRA, Adriana Aparecida; ALMEIDA, Rodrigo Praes De; FERNANDES, Fernando Hiago Souza; et al. O Algoritmo Support Vector Machine Aplicado ao Mapeamento do Uso e Ocupação do Solo (The Support Vector Machine Algorithm Applied to Mapping and Land Use). *Revista Brasileira de Geografia Física*, v. 7, n. 2, p. 291–303, 2014. Disponível em: <<https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/233041>>.
34. NASCIMENTO, R. F. F; ALCÂNTARA, E. H; KAMPEL, M; STECH, J. L; NOVO, E. M. L. M; Support Vector Machines (SVM): Avaliação da separação ótima de classes em imagens CCD-CBERS-2. *Anais XIV SBSR*, Natal, Brasil, 2009, INPE, p. 2079-2086. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/10.20.10.59/doc/2079-2086.pdf>.
35. NARVAES, Igor Da Silva; SCHUH, Mateus Sabadi; SOUZA, Pábulo Diogo; et al. Espectrorradiometria na distinção de espécies florestais utilizando Random Forest (RF), Support Vector Machine (SVM) e Artificial Neural Network (ANN). *Revista Brasileira de Geografia Física*, v. 17, n. 4, p. 2582–2605, 2024. Disponível em: <<https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/258364>>.
36. PARANHOS FILHO, Antonio Conceição; MOREIRA, Erika Silva; OLIVEIRA, Ademir Kleber Morbeck De; et al. Análise da variação da cobertura do solo no Pantanal de 2003 a 2010 através de sensoriamento remoto. *Engenharia Sanitaria e Ambiental*, v. 19, n. spe, p. 69–76, 2014. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-41522014000500069&lng=pt&tlng=pt>.
37. PATKI, P. S.; KELKAR, V. V. Support Vector Machine and various methods of Multi-Spectral satellite image classification. In: 2013 International Conference on Advances in Technology and Engineering (ICATE). Mumbai: IEEE, 2013, p. 1–5. Disponível em: <<http://ieeexplore.ieee.org/document/6524740/>>.
38. PESSI, Dhonatan Diego; SILVA, Normandes Matos Da ; MIOTO, Camila Leonardo.; BARBOSA, Domingos Sávio.; MOREIRA, Rodrigo Martins.; GOMES, Mateus Antonio Gums.; GRIGIO, Alfredo. Marcelo.; RIBEIRO, Vinicius. de Oliveira.; DIODATO, Marco. Antonio.; PARANHOS FILHO, Antonio Conceição. C. Aplicação de Sensoriamento Remoto na análise das mudanças da vegetação de campos de altitude no Pantanal usando dados multitemporais Landsat. *Terr@ Plural*, [S. l.], v. 17, p. e2321497, 2023.
39. POTT, Arnildo. Dinâmica da vegetação do Pantanal. In: Cavalcanti. T.C. & Walter, B.M.T. (org.) *Tópicos atuais em Botânica*. Brasília: Embrapa Recursos Genéticos e Biotecnologia/Sociedade Botânica do Brasil, p. 172-182, 2000.
40. PRATICÒ, Salvatore; SOLANO, Francesco; DI FAZIO, Salvatore; et al. Machine Learning Classification of Mediterranean Forest Habitats in Google Earth Engine Based on Seasonal Sentinel-2 Time-Series and Input Image Composition Optimisation. *Remote Sensing*, v. 13, n. 4, p. 586, 2021. Disponível em: <<https://www.mdpi.com/2072-4292/13/4/586>>.

41. QUEIROZ, Roberta Franco Pereira De; CORRÊA, Guilherme Resende; GRADELLA, Frederico Dos Santos; et al. Gradiente Edáfico Define as Fitofisionomias do Pantanal do Abobral, Brasil. *Oecologia Australis*, v. 23, n. 04, p. 730–743, 2019. Disponível em: <<https://revistas.ufjf.br/index.php/oa/article/view/20329>>.
42. RAVAGLIA, Adriana Gamarra.; SANTOS, Sandra Aparecida.; PELLEGRIN, Luiz Alberto.; RODELA, Luciana. Graci.; SILVA, Leilane Cristini Freitas Da. Classificação preliminar das paisagens da sub-região do Abobral, Pantanal, usando imagens de satélite. Corumbá: Embrapa Pantanal, 1-4. Comunicado Técnico, 82. 2010.
43. RODRÍGUEZ, Raquel Pérez; BAJORATH, Jürgen. Evolution of Support Vector Machine and Regression Modeling in Chemoinformatics and Drug Discovery. *Journal of Computer-Aided Molecular Design*, v. 36, n. 5, p. 355–362, 2022. Disponível em: <<https://link.springer.com/10.1007/s10822-022-00442-9>>.
44. SILVA, João dos Santos Villa Da. Aplicações de técnicas de sensoriamento remoto e sistema de informações geográficas na avaliação da dinâmica de inundação no Pantanal. 139 f. Dissertação (Mestrado em Administração) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1991.
45. SILVA, João dos Santos Villa Da; ABDON, Myrian de Moura. Delimitação do Pantanal brasileiro e suas sub-regiões. *Pesquisa Agropecuária Brasileira*, Brasília, v. 33, p. 1703-1711, out., 1998. Número Especial.
46. SILVA, Marta Pereira Da; MAURO, Rodiney; MOURÃO, Guilherme; et al. Distribuição e quantificação de classes de vegetação do Pantanal através de levantamento aéreo. *Revista Brasileira de Botânica*, v. 23, n. 2, 2000. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-84042000000200004&lng=pt&nrm=iso&tlng=pt>.
47. SHANG, Xiao; CHISHOLM, Laurie A. Classification of Australian Native Forest Species Using Hyperspectral Remote Sensing and Machine-Learning Classification Algorithms. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 6, p. 2481–2489, 2014. Disponível em: <<https://ieeexplore.ieee.org/document/6626350/>>.
48. SRIVASTAVA, Anubhava; BHARADWAJ, Shruti; DUBEY, Rakesh; SHARMA, Vinamra Brushan; BISWAS, Susham. Mapping Vegetation and Measuring the Performance of Machine Learning Algorithm in Lulc Classification in the Large Area Using Sentinel-2 And Landsat-8 Datasets of Dehradun as a Test Case. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. XLIII-B3-2022, p. 529–535, 2022. Disponível em: <<https://isprs-archives.copernicus.org/articles/XLIII-B3-2022/529/2022/>>.
49. ZHANG, Daiwei; YING, Chunyang; WU, Lei; et al. Using Time Series Sentinel Images for Object-Oriented Crop Extraction of Planting Structure in the Google Earth Engine. *Agronomy*, v. 13, n. 9, p. 2350, 2023. Disponível em: <<https://www.mdpi.com/2073-4395/13/9/2350>>.
50. ZHAO, Zhewen; ISLAM, Fakhrul; WASEEM, Liaqat Ali; et al. Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification. *Rangeland Ecology & Management*, v. 92, p. 129–137, 2024. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1550742423001227>>.

51. TANGTHAIKWAN, Kanita; KEERATIPRANON, Narongdech; AGSORNINTARA, Adshariya. Multiclass Support Vector Machine for Classification Spatial Data from Satellite Image. IEEE. 9th International Conference on Knowledge and Smart Technology (KST), Chonburi, Thailand, p. 1-5, 2017.
52. WITTMANN, Florian; ZORZI, Bianca Thaís; TIZIANEL, Fernando Augusto Tambelini; et al. Tree Species Composition, Structure, and Aboveground Wood Biomass of a Riparian Forest of the Lower Miranda River, Southern Pantanal, Brazil. *Folia Geobotanica*, v. 43, n. 4, p. 397–411, 2008. Disponível em: <<http://link.springer.com/10.1007/s12224-008-9022-9>>.