



VÍTOR AUGUSTO FERREIRA

**DELIMITAÇÃO DE ÁREA SUPERFICIAL E
MONITORAMENTO DA QUALIDADE VOLUMÉTRICA DA
ÁGUA COM SENSORIAMENTO REMOTO**

**LAVRAS – MG
2025**

VÍTOR AUGUSTO FERREIRA

**DELIMITAÇÃO DE ÁREA SUPERFICIAL E MONITORAMENTO DA QUALIDADE
VOLUMÉTRICA DA ÁGUA COM SENSORIAMENTO REMOTO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para a obtenção do título de Mestre.

Prof. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS – MG
2025**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Ferreira, Vítor Augusto

Delimitação de Área Superficial e Monitoramento da
Qualidade Volumétrica da Água com Sensoriamento Remoto /
Vítor Augusto Ferreira. – Lavras : UFLA, 2025.

144 p. : il.

Dissertação (Mestrado acadêmico)–Universidade Federal
de Lavras, 2025.

Orientador: Prof. Dr. Marcelo de Carvalho Alves.

Bibliografia.

1. Sensoriamento Remoto 2. Controle de qualidade 3.
Geocomputação 4. Imageamento por satélite I. Alves, Marcelo
de Carvalho. II. Título.

VÍTOR AUGUSTO FERREIRA

**DELIMITAÇÃO DE ÁREA SUPERFICIAL E MONITORAMENTO DA QUALIDADE
VOLUMÉTRICA DA ÁGUA COM SENSORIAMENTO REMOTO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para a obtenção do título de Mestre.

APROVADA em 19 de julho de 2025.

Prof. Dr. Marcelo de Carvalho Alves

DEA/EENG

Pesquisadora Dra. Margarete Marin Lordelo Volpato

EPAMIG

Profa. Dra. Marina Elisei Serra

DEA/EENG

Documento assinado digitalmente
 **MARCELO DE CARVALHO ALVES**
Data: 05/08/2025 15:47:43-0300
verifique em <https://validar.it.gov.br>

Prof. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS – MG
2025**

AGRADECIMENTOS

Agradeço a Deus em primeiro lugar, aos meus familiares e amigos que me apoiaram, ao orientador Prof^o. Dr. Marcelo de Carvalho Alves. A Universidade Federal de Lavras (UFLA), o Programa de Pós Graduação em Engenharia Agrícola (PPGEA). A secretária do PPGEA, a Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG), a Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG). O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG)

RESUMO

O monitoramento da área superficial da água é crucial para a gestão ambiental, especialmente em áreas estratégicas como a Represa do Funil, localizada em Minas Gerais, Brasil. A represa desempenha um papel significativo no abastecimento de água, geração de energia e lazer. Nesse contexto, avaliar a qualidade da água é essencial para diagnosticar o estado ambiental do reservatório, compreender as potencialidades de uso e identificar agentes poluidores que comprometem sua sustentabilidade. O sensoriamento remoto destaca-se como uma ferramenta eficiente e econômica para análise de corpos d'água, permitindo o mapeamento de características físico-químicas e o monitoramento contínuo desses ambientes. Essas técnicas possibilitam a detecção de mudanças ambientais e auxiliam na gestão integrada dos recursos hídricos. A utilização de metodologias de sensoriamento remoto viabiliza a criação de máscaras de água, delimitando automaticamente áreas hídricas em imagens de satélite e facilitando a identificação de variações na cobertura e na extensão desses recursos ao longo do tempo. Este trabalho propõe o uso de técnicas avançadas de sensoriamento remoto para a definição de máscaras de água e cálculo de índices espectrais relevantes à qualidade da água na Represa do Funil. Os resultados esperados incluem mapas detalhados da área da represa, a detecção de alterações temporais e a geração de dados que possam subsidiar ações voltadas à conservação e ao uso sustentável deste recurso hídrico estratégico.

Palavras-chave: índices espectrais; controle de qualidade; geocomputação; imageamento por satélite.

ABSTRACT

Water resource monitoring is crucial for environmental management, especially in strategic areas such as the Funil Reservoir, located in Minas Gerais, Brazil. The dam plays a significant role in water supply, power generation and leisure. In this context, assessing water quality is essential to diagnose the environmental status of the reservoir, understand its potential uses and identify pollutants that compromise its sustainability. Remote sensing stands out as an efficient and cost-effective tool for analyzing water bodies, allowing the mapping of physical and chemical characteristics and continuous monitoring of these environments. These techniques enable the detection of environmental changes and assist in the integrated management of water resources. The use of remote sensing methodologies makes it possible to create water masks, automatically delimiting water areas in satellite images and facilitating the identification of variations in the coverage and extent of these resources over time. This work proposes the use of advanced remote sensing techniques to define water masks and calculate spectral indices relevant to water quality in the Funil Reservoir. The expected results include detailed maps of the dam area, the detection of temporal changes and the generation of data that can support actions aimed at the conservation and sustainable use of this strategic water resource.

Keywords: spectral indices; quality control; geocomputing; satellite imaging.

IMPACTOS SOCIAIS, TECNOLÓGICOS, ECONÔMICOS E CULTURAIS

A pesquisa voltada para a delimitação de área superficial de água e a aplicação de índices de qualidade da água tem impactos diretos e significativos em diversas áreas. A utilização de ferramentas de monitoramento por meio de imagens de satélite, como o NDVI, NDWI e outros índices, permite uma análise detalhada e em tempo real da qualidade da água em diferentes corpos hídricos. Este avanço tecnológico pode transformar a gestão de recursos hídricos, permitindo a identificação precoce de problemas como poluição, eutrofização e assoreamento. A metodologia proposta, que envolve o uso de dados de satélites como o Sentinel-2 e o Landsat 8, proporciona uma alternativa eficaz aos métodos tradicionais de amostragem in situ, que muitas vezes são dispendiosos e demorados. Além disso, ela pode contribuir para uma gestão mais eficiente e sustentável dos recursos hídricos, melhorando a qualidade da água e a saúde dos ecossistemas aquáticos. No contexto social, essa metodologia favorece o aumento da conscientização ambiental e o engajamento da sociedade na preservação dos corpos d'água. O uso de imagens de satélite e índices de qualidade da água pode ainda fortalecer a implementação de políticas públicas voltadas à conservação da água. Esse modelo de monitoramento remoto se alinha com os Objetivos de Desenvolvimento Sustentável (ODS), como o ODS 6 (Água Potável e Saneamento), ao promover a gestão sustentável da água e a melhoria da qualidade hídrica. A aplicação dessa metodologia pode, assim, transformar não só o campo da pesquisa ambiental, mas também influenciar positivamente o desenvolvimento sustentável e a qualidade de vida das comunidades que dependem dos recursos hídricos para sua sobrevivência.

SOCIAL, TECHNOLOGICAL, ECONOMIC AND CULTURAL IMPACTS

Research focused on creating water masks and applying water quality indices has direct and significant impacts in several areas. The use of monitoring tools using satellite images, such as NDVI, NDWI and other indices, allows for detailed and real-time analysis of water quality in different water bodies. This technological advance can transform water resource management, allowing for the early identification of problems such as pollution, eutrophication and siltation. The proposed methodology, which involves the use of data from satellites such as Sentinel-2 and Landsat 8, provides an effective alternative to traditional in situ sampling methods, which are often costly and time-consuming. In addition, it can contribute to more efficient and sustainable management of water resources, improving water quality and the health of aquatic ecosystems. In the social context, this methodology favors increased environmental awareness and society's engagement in the preservation of water bodies. The use of satellite imagery and water quality indices can also strengthen the implementation of public policies aimed at water conservation. This remote monitoring model aligns with the Sustainable Development Goals (SDGs), such as SDG 6 (Clean Water and Sanitation), by promoting sustainable water management and improving water quality. The application of this methodology can thus transform not only the field of environmental research, but also positively influence sustainable development and the quality of life of communities that depend on water resources for their survival.

LISTA DE FIGURAS

Figura 1.1 – Mapa de Localização da Represa do Funil em Nível Nacional.	20
Figura 1.2 – Mapa de Localização da Represa do Funil em Nível Estadual.	21
Figura 1.3 – Mapa de Localização da Represa do Funil e Municípios Vizinhos.	22
Figura 2.1 – Região utilizada como base para o estudo. Fonte: Sentinel-2A.	56
Figura 2.2 – Mapa de localização da Represa do Funil em nível nacional.	57
Figura 2.3 – Mapa de localização da Represa do Funil em nível estadual.	58
Figura 2.4 – Mapa de localização da Represa do Funil e municípios vizinhos.	59
Figura 2.5 – Imagens Sentinel 2A e Landsat 8 selecionadas	63
Figura 2.6 – Índice Espectrais aplicados à região da Represa do Funil.	72
Figura 2.7 – Histograma dos índice aplicados a região da Represa do Funil.	73
Figura 2.8 – Limiar de água da região da Represa do Funil a partir do Landsat 8	73
Figura 2.9 – Índices NDDI, LSWI, albedo, water aplicados a região da Represa do Funil no Landsat 8	74
Figura 2.10 – Histograma dos índices WSI aplicados a região da Represa do Funil no Landsat 8	75
Figura 2.11 – Delimitação dos cursos d’água a partir dos Índices NDDI, LSWI, albedo, water no Landsat 8	75
Figura 2.12 – Índice espectrais aplicados à região da Represa do Funil Sentinel 2A.	77
Figura 2.13 – Histograma dos índice aplicados a região da Represa do Funil Sentinel 2A.	78
Figura 2.14 – Limiar de água da região da Represa do Funil Sentinel 2A.	78
Figura 2.15 – Índices aplicados a Represa do Funil Sentinel 2A	79
Figura 2.16 – Histograma dos Índices aplicados a Represa do Funil Sentinel 2A	80
Figura 2.17 – Índices aplicados a Represa do Funil, Sentinel 2A	80
Figura 2.18 – Classificação Não Supervisionada RStollBox, Landsat 8	82
Figura 2.19 – Limiar de água a partir da Classificação não Supervisionada RStollBox, Landsat 8	82
Figura 2.20 – Classificação Não Supervisionada RStollBox, Sentinel2 A	83
Figura 2.21 – Limiar de água a partir da Classificação Não Supervisionada RStollBox, Sentinel2 A	83
Figura 3.1 – Mapa de localização da Represa do Funil e municípios adjacentes.	94
Figura 3.2 – Dados de treinamento utilizados para a classificação supervisionada	95

Figura 3.3 – Importância das variáveis na Classificação Supervisionada, Landsat8	104
Figura 3.4 – Limiar de água na Classificação Supervisionada RF, Landsat8	105
Figura 3.5 – Importância das variáveis na Classificação Supervisionada, Sentinel 2A . .	105
Figura 3.6 – Limiar de água na Classificação Supervisionada RF, Sentinel 2A	106
Figura 3.7 – Limiar de água na Classificação Supervisionada RF, Landsat8	107
Figura 3.8 – Água e não Água, Limiar de água na Classificação Supervisionada MESMA no Landsat8	107
Figura 3.9 – Máscara de Água a partir da Classificação Supervisionada MESMA, Land- Sat 8	108
Figura 3.10 – Limiar de água na Classificação Supervisionada RF, Sentinel 2A	108
Figura 3.11 – Limiar de água na Classificação Supervisionada MESMA, Sentinel 2A . .	109
Figura 3.12 – Máscara de Água a partir da Classificação Supervisionada MESMA, Senti- nel 2A	110
Figura 3.13 – Probabilidade de Água MaxEnt, LandSat 8	111
Figura 3.14 – Máscara de Água MaxEnt, LandSat 8	112
Figura 3.15 – Probabilidade de Água MaxEnt, Sentinel 2A	112
Figura 3.16 – Máscara de Água MaxEnt, Sentinel 2A	113
Figura 4.1 – Região utilizada como base para a imagem matricial	123
Figura 4.2 – Principais cursos d’água que desembocam na região da Represa do Funil .	124
Figura 4.3 – Índice MN12NDCl, aplicado ao Sentinel 2A	128
Figura 4.4 – Índice MN12NDCl, aplicado ao Sentinel 2A	129
Figura 4.5 – Mapa com os índices de clorofila MM12NDCl, aplicado ao Sentinel 2A . .	130
Figura 4.6 – Índice Am092Bsub, aplicado ao Sentinel 2A	131
Figura 4.7 – Histograma do Índice Am092Bsub, aplicado ao Sentinel 2A	132
Figura 4.8 – Mapa com os índices de clorofila AM092BSUB, aplicado ao Sentinel 2A .	133
Figura 4.9 – Mapa com do índices de Turbidez TurbDox02NIRoverRed, aplicado ao Sentinel 2A	134
Figura 4.10 – Histograma do valores do índice TurbDox02NIRoverRed, aplicado ao Sen- tinel 2A	135
Figura 4.11 – Mapa das classes com valores do índice TurbDox02NIRoverRed, aplicado ao Sentinel 2A	136

Figura 4.12 – Mapa com do índices de Turbidez TurbBow06RedOverGreen, aplicado ao Sentinel 2A	137
Figura 4.13 – Histograma do valores do índice TurbBow06RedOverGreen, aplicado ao Sentinel 2A	138
Figura 4.14 – Mapa das classes com valores do Índice TurbDox02NIRoverGreen, apli- cado ao Sentinel 2A	139

LISTA DE TABELAS

Tabela 1.1 – Bandas espectrais do Satélite Landsat 8 com seus respectivos comprimentos de onda e resoluções espaciais.	33
Tabela 1.2 – Bandas espectrais do Satélite Sentinel-2A com seus respectivos comprimentos de onda e resoluções espaciais.	35
Tabela 2.1 – Imagens Landsat 8 disponíveis para a área de estudo em setembro de 2024	60
Tabela 2.2 – Imagens Sentinel-2A disponíveis para a área de estudo em setembro de 2024	60
Tabela 2.3 – Métodos empíricos aplicados aos sensores Landsat 8 e Sentinel-2A	68
Tabela 2.4 – Áreas de água detectadas por diferentes índices espectrais	74
Tabela 2.5 – Áreas de água detectadas por diferentes índices espectrais no Landsat 8 . .	76
Tabela 2.6 – Áreas de água detectadas por diferentes índices espectrais Sentinel 2A . . .	79
Tabela 2.7 – Resultados dos índices espectrais calculados (Sentinel-2)	81
Tabela 2.8 – Resultados da classificação de água em imagens Landsat 8 e Sentinel-2A .	84
Tabela 3.1 – Áreas de água detectadas por Random Forest com os diferentes sensores . .	106
Tabela 3.2 – Matriz de confusão da classificação MESMA com limiar 0,90 (Landsat 8) .	106
Tabela 3.3 – Matriz de confusão da classificação MESMA com limiar 0,90	108
Tabela 3.4 – Áreas de água detectadas pela classificação MESMA com limiar de 0,90 .	110
Tabela 3.5 – Matriz de confusão da classificação Maxnet com limiar 0,50	110
Tabela 3.6 – Métricas de desempenho do modelo de classificação	111
Tabela 3.7 – Matriz de confusão da classificação Maxnet (Sentinel-2A) com limiar 0,50	112
Tabela 3.8 – Métricas de desempenho do modelo de classificação para detecção de água (Sentinel-2A)	113
Tabela 3.9 – Comparação de áreas de água classificadas pelo MaxEnt	113
Tabela 3.10 – Desempenho dos métodos por sensor	115
Tabela 4.1 – Estatísticas descritivas do índice MM12NDCI	128
Tabela 4.2 – Intervalos de reclassificação do índice MM12NDCI para níveis de clorofila.	129
Tabela 4.3 – Resumo estatístico do índice Am092Bsub	131
Tabela 4.4 – Classes do índice Am092Bsub e seus intervalos de valores	132
Tabela 4.5 – Estatísticas descritivas dos valores do índice TurbDox02NIRoverRed calculado a partir da imagem Sentinel-2.	134
Tabela 4.6 – Classes do índice TurbDox02NIRoverRed e seus intervalos de valores . . .	135
Tabela 4.7 – Estatísticas descritivas do índice TurbBow06RedOverGreen	137

Tabela 4.8 – Classes do índice TurbBow06RedOverGreen e seus intervalos de valores . 138

SUMÁRIO

1	INTRODUÇÃO	17
1.1	JUSTIFICATIVA	18
1.2	HIPÓTESE	19
1.3	OBJETIVO GERAL	19
1.4	OBJETIVOS ESPECÍFICOS	19
1.5	REFERENCIAL TEÓRICO	20
1.5.1	DESCRIÇÃO DA ÁREA	20
1.5.2	IMPORTÂNCIA DA ÁGUA	22
1.5.3	MONITORAMENTO DA QUALIDADE DA ÁGUA	23
1.5.4	SENSORIAMENTO REMOTO DA ÁGUA	24
1.5.5	OS CAMINHOS DA LUZ NA ÁGUA	26
1.5.5.1	SENSORIAMENTO REMOTO APLICADO À QUALIDADE DA ÁGUA .	27
1.5.6	DETERMINAÇÃO AUTOMÁTICA DE ÁREA SUPERFICIAL DE ÁGUA	27
1.5.7	CLASSIFICAÇÃO DA ÁGUA POR SENSORIAMENTO REMOTO . . .	28
1.5.8	MODELOS DE DADOS EM GEOCOMPUTAÇÃO	29
1.5.9	SENSORES ORBITAIS PARA MONITORAMENTO DA ÁGUA	31
1.5.9.1	LANDSAT 8	32
1.5.9.2	SENTINEL-2A	33
1.5.10	PROCESSAMENTO DE IMAGENS	36
1.5.11	GEOCOMPUTAÇÃO AMBIENTAL COM R	36
1.5.12	PACOTES R	37
1.5.12.1	PACOTE WATERQUALITY	38
1.5.13	NORMALIZED DIFFERENCE WATER INDEX	39
1.5.14	ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA	40
1.5.15	TASSELED CAP	41
1.5.16	ALBEDO	42
1.5.17	CLASSIFICAÇÃO SUPERVISIONADA DA ÁGUA	42
1.5.17.1	MULTIPLE ENDMEMBER SPECTRAL MIXTURE ANALYSIS	43
1.5.17.2	MAXIMUM ENTROPY MODELING	44
	REFERÊNCIAS GERAIS	46

2	DELIMITAÇÃO DE ÁREA SUPERFICIAL DE ÁGUA DA REPRESA DO FUNIL A PARTIR DE SENSORIAMENTO REMOTO	53
2.1	INTRODUÇÃO	55
2.1.1	OBJETIVOS	55
2.2	MATERIAL E MÉTODOS	56
2.2.1	DESCRIÇÃO DA ÁREA	57
2.2.2	DEFINIÇÃO DA ÁREA	59
2.2.3	MÉTODOS EMPIRICOS	63
2.2.4	ALGORITMO K-MEANS	69
2.2.5	CÁLCULO DE ÁREA	70
2.3	RESULTADOS	72
2.3.1	MÉTODOS EMPIRICOS LANDSAT 8	72
2.3.2	MÉTODOS EMPIRICOS SENTINEL 2A	77
2.3.3	CLASSIFICAÇÃO NÃO SUPERVISIONADA RStoolbox	82
2.4	DISCUSSÃO DOS RESULTADOS	85
2.4.1	COMPARAÇÃO ENTRE LANDSAT-8 E SENTINEL-2A	86
2.4.2	LIMITAÇÕES E DESAFIOS	86
2.5	CONCLUSÃO	87
	REFERÊNCIAS	88
3	DELIMITAÇÃO DE ÁREA SUPERFICIAL DE ÁGUA DA REPRESA DO FUNIL A PARTIR DE SENSORIAMENTO REMOTO CLAASIFICAÇÃO SUPERVISIONADA	90
3.1	INTRODUÇÃO	92
3.1.1	OBJETIVOS	92
3.1.2	OBJETIVOS ESPECÍFICOS	92
3.2	DESCRIÇÃO DA ÁREA	93
3.3	DESCRIÇÃO DOS MÉTODOS	94
3.3.1	TREINAMENTO DOS DADOS	94
3.3.2	RANDOM FOREST	95
3.3.3	MESMA	99
3.3.4	MAXENT	101
3.4	RESULTADOS	104

3.4.1	RANDOM FOREST LANDSAT 8	104
3.4.2	RANDOM FOREST SENTINEL 2A	105
3.4.3	MESMA LANDSAT 8	106
3.4.4	MESMA SENTINEL 2A	108
3.4.5	MAXENT LANDSAT 8	110
3.4.6	MAXENT SENTINEL 2A	112
3.5	DISCUSSÃO DOS RESULTADOS	114
3.6	CONCLUSÃO	115
	REFERÊNCIAS	117
4	APLICAÇÃO DE ÍNDICES DE QUALIDADE DE ÁGUA NA REPRESA DO FUNIL VIA SENSORIAMENTO REMOTO	119
4.1	INTRODUÇÃO	121
4.2	MATERIAL E MÉTODOS	122
4.2.1	DESCRIÇÃO DA ÁREA	122
4.2.2	BACIA DO RIO GRANDE	123
4.2.3	GEOCOMPUTAÇÃO	124
4.2.4	ÍNDICES DE QUALIDADE DA ÁGUA	125
4.2.4.1	ÍNDICES PARA CLOROFILA-A	125
4.2.4.2	ÍNDICES PARA TURBIDEZ	126
4.2.4.3	CLASSES DE CLASSIFICAÇÃO	127
4.3	RESULTADOS	127
4.3.1	MM12NDCI	127
4.3.2	AM092BSUB	130
4.3.3	TurbDox02NIRoverRed	133
4.3.4	TurbBow06RedOverGreen	136
4.4	DISCUSSÃO DOS RESULTADOS	139
4.5	CONCLUSÃO	141
	REFERÊNCIAS	142

1 INTRODUÇÃO

A água é um recurso essencial para a vida humana e o desenvolvimento de diversas atividades. Sua importância se reflete em aspectos que vão desde a saúde individual até o funcionamento da sociedade como um todo. As atividades agrícolas, industriais e comerciais dependem diretamente da água para sua execução (Postel; Daily; Ehrlich, 1996). Os reservatórios, em particular, desempenham um papel crucial no abastecimento de água. No entanto, esses corpos d'água estão sujeitos a diversos impactos ambientais e climáticos, como mudanças no uso da terra, poluição e variações nos padrões de precipitação, que afetam diretamente tanto a quantidade quanto a qualidade da água disponível (Gao, 1996). A poluição da água, por exemplo, é uma das maiores ameaças aos ambientes aquáticos, ao recurso hídrico e à saúde humana (UNESCO, 2020). Para mitigar esses problemas, é urgente adotar medidas eficazes, sendo fundamental o monitoramento dinâmico e preciso da qualidade da água, especialmente em grande escala (Ouma; Tateishi, 2012). Nesse contexto, as tecnologias de sensoriamento remoto têm se destacado, pois permitem a coleta de dados sobre a qualidade da água de forma eficiente, considerando os benefícios temporais e espaciais dessas ferramentas (Dekker; Peters, 2001).

A análise espacial utilizando imagens de satélite é um método eficaz para entender os efeitos da ocupação e do uso do solo, especialmente no que diz respeito à sua interação com a qualidade da água (Wu; Lane; Liu, 2019). Imagens de satélite oferecem diversas possibilidades para avaliar a qualidade da água de reservatórios, sendo uma ferramenta essencial, especialmente quando complementada com infraestrutura de monitoramento em campo e laboratórios equipados para realizar análises detalhadas. O monitoramento de reservatórios por meio de sensoriamento remoto é uma abordagem eficiente, pois permite cobrir grandes áreas e ser realizado de forma remota, sem a necessidade de presença constante no local (Pereira; Allen, 2019).

Atualmente, o monitoramento da qualidade da água é crucial, e os dados de sensoriamento remoto têm grande potencial para otimizar esse processo. O Sensoriamento Remoto permite monitorar em escalas espaciais e temporais diversas, facilitando a identificação da qualidade da água e possibilitando a análise das respostas a perturbações causadas pela atividade humana (Gholizadeh; Melesse; Reddi, 2016). Isso ajuda a prever os impactos dessas ações sobre a sustentabilidade dos recursos hídricos no médio e longo prazo. O sensoriamento remoto oferece a vantagem de gerar dados em larga escala e com intervalos regulares, proporcionando uma visão abrangente e contínua das condições dos reservatórios (Vanhellemont; Rud-

dick, 2015). Tecnologias como imagens de satélite, incluindo aquelas dos satélites Landsat e Sentinel, são capazes de monitorar parâmetros importantes, como a área da superfície da água, turbidez, temperatura e a presença de matéria orgânica, de forma precisa e eficiente (Li; Li; Gong, 2017). Esses dados são fundamentais para detectar mudanças ao longo do tempo, identificar problemas emergentes e embasar decisões para a preservação e gestão sustentável desses ecossistemas.

1.1 JUSTIFICATIVA

A água é um recurso natural de valor inestimável, essencial para o desenvolvimento socioeconômico, a manutenção da vida e a preservação de ecossistemas aquáticos (Postel; Daily; Ehrlich, 1996; UNESCO, 2020). No entanto, os corpos d'água, especialmente os reservatórios, estão cada vez mais ameaçados por fatores como poluição, mudanças no uso e cobertura da terra, e alterações climáticas, que comprometem tanto sua quantidade quanto sua qualidade (Wu; Lane; Liu, 2019). A degradação desses ecossistemas tem impactos diretos na saúde pública, no abastecimento de água potável e em atividades como a agricultura e a geração de energia (Gao, 1996).

Os reservatórios artificiais, especialmente vulneráveis por sua natureza topográfica, sofrem impactos cumulativos provenientes de múltiplas fontes de contaminação por efluentes urbanos, agrícolas e industriais, carreamento de sedimentos, e os efeitos crescentes das mudanças climáticas sobre o regime hídrico. Esses fatores concorrem para um cenário de degradação progressiva que compromete tanto a disponibilidade quanto a qualidade da água, com reflexos diretos nos sistemas de abastecimento público, na irrigação agrícola e na geração de energia hidrelétrica.

Portanto, este trabalho se justifica pela necessidade de desenvolver e aplicar metodologias eficientes para monitorar a qualidade da água em reservatórios, utilizando o potencial do sensoriamento remoto. Os resultados podem contribuir para a identificação de impactos ambientais, o planejamento de ações mitigadoras e a promoção de políticas voltadas à sustentabilidade dos recursos hídricos, em um cenário global onde a água se torna cada vez mais escassa e vulnerável.

1.2 HIPÓTESE

O uso da ciência Sensoriamento Remoto, a partir de imagens de satélite Landsat e Sentinel, proporciona um método eficiente e robusto para delimitação automática de cursos d'água, reservatórios. E monitoramento da qualidade da água nos reservatórios e cursos d'água. Por meio da análise de parâmetros hídricos críticos, como turbidez, temperatura da superfície da água e concentração de matéria orgânica, é possível detectar variações espaciais e temporais significativas. Tais informações permitem identificar impactos ambientais decorrentes das atividades humanas e mudanças climáticas, além de fornecer subsídios fundamentais para a gestão sustentável e a preservação dos recursos hídricos.

O monitoramento regular e eficaz da qualidade da água é fundamental para a identificação precoce de problemas ambientais, a formulação de políticas públicas e a tomada de decisões para a gestão sustentável dos recursos hídricos. Contudo, métodos tradicionais de monitoramento, que envolvem coletas *in situ* e análises laboratoriais, são frequentemente custosos, demorados e limitados em escalas espaciais e temporais (Pereira; Allen, 2019).

Neste cenário, as tecnologias de sensoriamento remoto emergem como uma alternativa inovadora e eficaz, oferecendo informações contínuas, precisas e em larga escala sobre parâmetros críticos da qualidade da água (Dekker; Peters, 2001). Satélites como Landsat e Sentinel fornecem dados espectrais que permitem monitorar variáveis como turbidez, temperatura da superfície, presença de matéria orgânica e variações na cobertura hídrica com alta resolução espacial e temporal (Gholizadeh; Melesse; Reddi, 2016; Vanhellemont; Ruddick, 2015).

1.3 OBJETIVO GERAL

O objetivo deste trabalho é desenvolver uma metodologia para determinar automaticamente, por meio de sensoriamento remoto e processamento de imagens digitais, a área superficial e a qualidade volumétrica da água do reservatório do Funil. Busca-se avaliar a eficiência do sensoriamento remoto como ferramenta para a definição de metodologias de classificação de reservatórios de água e para a delimitação da dimensão do reservatório.

1.4 OBJETIVOS ESPECÍFICOS

Os objetivos específicos deste trabalho são, delimitar a superfície de água utilizando métodos empíricos baseados em índices espectrais, que envolvem a aritmética de bandas. Deli-


mitar a superfície de água a partir de métodos de classificação supervisionada. Avaliar a qualidade da água na represa do Funil utilizando índices de qualidade de água a partir de dimensões pré-definidas nas imagens classificadas

1.5 REFERENCIAL TEÓRICO

1.5.1 DESCRIÇÃO DA ÁREA

A região da Barragem do Funil, localizada no Campo das Vertentes, próxima ao sul do estado de Minas Gerais, Brasil, abrange municípios limítrofes como Lavras, Ijaci, Perdões, Ribeirão Vermelho, Bom Sucesso, Itumirim e Ibituruna (Figura 2.4). Trata-se de uma área de importância estratégica, por abrigar um dos principais reservatórios da bacia do rio Grande, desempenhando funções essenciais no abastecimento público, irrigação agrícola, geração de energia hidrelétrica e controle de vazões ([Agência Nacional de Águas \(ANA\), 2023](#)).


Figura 1.1 – Mapa de Localização da Represa do Funil em Nível Nacional.



No que se refere ao clima, a região é classificada como Cwa, segundo o sistema de Köppen-Geiger, caracterizando-se por verões quentes e chuvosos, com temperaturas médias acima de 22°C e precipitação concentrada entre os meses de outubro e março, e por invernos


secos e amenos, com temperaturas médias entre 14°C e 18°C (Alvares *et al.*, 2013). A precipitação média anual situa-se entre 1.400 e 1.600 mm, com variações sazonais influenciadas por sistemas frontais e convectivos, características que impactam diretamente a dinâmica hídrica do reservatório (Instituto Nacional de Meteorologia (INMET), 2023).

Figura 1.2 – Mapa de Localização da Represa do Funil em Nível Estadual.



Do ponto de vista geomorfológico, a área insere-se no Planalto Atlântico, apresentando relevo que varia de suavemente ondulado a montanhoso, com altitudes entre 800 e 1.200 metros (Instituto Brasileiro de Geografia e Estatística (IBGE), 2019). A cobertura vegetal original consistia predominantemente de Mata Atlântica e cerrado; contudo, atualmente, a região apresenta extensas áreas de cultivo agrícola, especialmente de café, além de pastagens (MapBio-mas, 2022). Essa transição entre áreas naturais e antropizadas torna a região particularmente relevante para estudos agrícolas e ambientais, pois permite avaliar os impactos das atividades humanas sobre os recursos hídricos.

Figura 1.3 – Mapa de Localização da Represa do Funil e Municípios Vizinhos.



1.5.2 IMPORTÂNCIA DA ÁGUA

A água é uma molécula fundamental para a vida, possuindo propriedades físico-químicas únicas que a tornam indispensável em processos biológicos e ecológicos. A molécula de água H_2O apresenta uma estrutura angular, com um ângulo de aproximadamente 104,5 graus entre os átomos de hidrogênio e oxigênio. Essa geometria confere à água uma polaridade significativa, permitindo que forme ligações de hidrogênio tanto consigo mesma quanto com outras moléculas polares (Lehninger; Nelson; Cox, 2017).

Uma das propriedades mais notáveis da água é sua alta capacidade calorífica específica, que permite a absorção e liberação de grandes quantidades de calor com variações mínimas de temperatura. Isso é crucial para a manutenção da temperatura corporal em organismos vivos e para a regulação térmica de ambientes aquáticos (Lehninger; Nelson; Cox, 2017).

A água é um recurso essencial para a sobrevivência humana e o desenvolvimento socioeconômico, desempenhando um papel fundamental em diversas atividades, como abastecimento doméstico, agricultura, indústria e geração de energia. No entanto, a crescente pressão exercida sobre os recursos hídricos devido à poluição, mudanças climáticas e exploração excessiva tem

acentuado a necessidade de um monitoramento eficaz da qualidade da água para garantir sua sustentabilidade.

O monitoramento da qualidade da água é essencial para detectar, prevenir e mitigar impactos ambientais e de saúde pública decorrentes da contaminação de corpos d'água. O monitoramento permite identificar poluentes, avaliar tendências temporais, diagnosticar problemas ambientais e embasar políticas públicas voltadas à gestão sustentável dos recursos hídricos. Além disso, oferece informações valiosas para a modelagem preditiva de cenários futuros, essenciais para a mitigação de impactos relacionados a mudanças climáticas e urbanização (Chapra; B., 1997).

Com o avanço das tecnologias, ferramentas como o sensoriamento remoto têm se destacado no monitoramento da qualidade da água. Essas tecnologias permitem a análise em larga escala e em alta frequência de parâmetros como turbidez, concentração de clorofila e presença de matéria orgânica, reduzindo custos e tempo em relação aos métodos tradicionais (Liang; Fang; Chen, 2012). A utilização de imagens de satélite possibilita avaliar a distribuição espacial e temporal dos parâmetros de qualidade da água em grandes reservatórios e rios, o que é essencial para o planejamento e a gestão integrada dos recursos hídricos (Schaepman-Strub *et al.*, 2006).

A degradação da qualidade da água tem implicações diretas na saúde pública, pois muitos poluentes podem causar doenças graves quando consumidos por humanos ou animais. Cerca de 80% das doenças em países em desenvolvimento estão relacionadas ao consumo de água contaminada. Por isso, monitorar e assegurar padrões adequados de qualidade da água são passos fundamentais para promover a saúde e o bem-estar das populações (Saúde, 2017).

1.5.3 MONITORAMENTO DA QUALIDADE DA ÁGUA

O monitoramento da qualidade da água é uma prática essencial para garantir a saúde pública e a preservação dos ecossistemas aquáticos. Tradicionalmente, esse monitoramento é realizado por meio de amostras *in situ*, onde amostras de água são coletadas diretamente nos corpos d'água e analisadas em laboratório. Esses métodos oferecem informações detalhadas sobre os parâmetros da água, como pH, turbidez, concentração de sólidos dissolvidos, nutrientes e presença de poluentes (Barros; Ferreira; Silva, 2005; Brasil, 2005).

O uso de amostras *in situ* é considerado um método preciso para a avaliação da qualidade da água, já que permite a análise direta dos parâmetros em tempo real. No entanto, esse método

apresenta limitações, como o alto custo operacional, a necessidade de equipamentos e pessoal especializado, e a dificuldade em cobrir grandes áreas ou áreas de difícil acesso, como regiões remotas ou de difícil navegação (Cunha; Rodrigues; Barbosa, 2007). A coleta de amostras também depende de frequências periódicas, o que pode limitar a quantidade de dados disponíveis para monitoramento contínuo.

Entre as técnicas *in situ* mais comuns estão os sensores de qualidade da água e a coleta de amostras para análises laboratoriais. Os sensores, frequentemente acoplados a bóias ou plataformas flutuantes, podem medir uma variedade de parâmetros, incluindo pH, oxigênio dissolvido, turbidez e condutividade elétrica. Esses sensores fornecem dados em tempo real, permitindo o monitoramento contínuo e, portanto, uma resposta rápida a variações na qualidade da água (Kibler; Adim; Al., 2011).

A coleta de amostras de água e sua análise em laboratório continua sendo um método essencial, particularmente para a medição de compostos específicos, como metais pesados, pesticidas ou substâncias orgânicas. Embora mais precisa, essa abordagem é mais demorada e custosa, além de não permitir o monitoramento contínuo (Allan *et al.*, 2009).

Além disso, a combinação dessas abordagens tradicionais com novas tecnologias, como os dados de sensoriamento remoto, tem se mostrado promissora. A integração dos dados *in situ* com imagens de satélite, por exemplo, pode proporcionar uma visão mais abrangente e detalhada da qualidade da água em grandes áreas, permitindo a análise temporal e espacial da variação da qualidade da água e a identificação de tendências de poluição (Vanhellemont; Ruddick, 2015). Essa combinação de métodos complementares pode melhorar a precisão e a eficiência do monitoramento da qualidade da água, além de otimizar os recursos para a gestão hídrica.

1.5.4 SENSORIAMENTO REMOTO DA ÁGUA

O sensoriamento remoto é uma ciência que permite a obtenção de informações sobre objetos ou áreas da superfície terrestre sem a necessidade de contato direto, utilizando sensores que capturam a radiação eletromagnética refletida ou emitida pelos alvos de interesse. Essa abordagem baseia-se na interação entre a radiação eletromagnética e os componentes da Terra, incluindo solo, vegetação e corpos d'água (Jensen, 2007).

Os sensores remotos podem ser montados em plataformas orbitais, como satélites, ou suborbitais, como aeronaves, e são projetados para operar em diferentes regiões do espectro

eletromagnético, como o visível, infravermelho e micro-ondas. Cada faixa espectral oferece informações específicas sobre as propriedades físicas e químicas dos alvos, o que permite uma ampla gama de aplicações, desde o monitoramento ambiental até o planejamento urbano (Lillesand; Kiefer; Chipman, 2015).

Os produtos de sensoriamento remoto têm se mostrado valiosos em várias áreas. Na agricultura, permitem a identificação do vigor vegetativo das culturas e o monitoramento da saúde das plantas. No gerenciamento de recursos hídricos, são utilizados para mapear corpos d'água e monitorar a qualidade da água. No planejamento urbano, ajudam a avaliar mudanças no uso do solo e no crescimento das cidades. Além disso, são ferramentas cruciais para o monitoramento de desastres naturais, como deslizamentos de terra e inundações, devido à sua capacidade de fornecer dados em grande escala e em tempo quase real (Richards; Jia, 2013).

A refletância da água no contexto do sensoriamento remoto é caracterizada por propriedades únicas que a diferenciam de outros alvos, como solo e vegetação. A água pura possui uma baixa refletância em grande parte do espectro eletromagnético, especialmente nas regiões do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR), onde a absorção é extremamente alta. No espectro visível, a água apresenta sua maior refletância na faixa do azul, diminuindo gradativamente em direção ao vermelho, o que explica sua aparência azulada em imagens de satélite (Jensen, 2007).

Os corpos d'água apresentam baixa refletância no espectro visível, exceto na faixa do azul (400-500 nm), onde a água pura reflete mais devido à sua capacidade de absorção reduzida nessa região. No infravermelho próximo (NIR) e no infravermelho de ondas curtas (SWIR), a água absorve fortemente a radiação, resultando em valores de refletância próximos a zero. Essas propriedades tornam possível distinguir corpos d'água de outros alvos terrestres, como vegetação e solo, em imagens de satélite.

A capacidade de obter informações detalhadas e consistentes em escalas globais faz do sensoriamento remoto uma tecnologia indispensável para o estudo e o gerenciamento sustentável do meio ambiente. Com o avanço das plataformas e sensores, como os satélites Landsat e Sentinel, as possibilidades de aplicação continuam a se expandir, ampliando o alcance e a precisão dos dados disponíveis.

1.5.5 OS CAMINHOS DA LUZ NA ÁGUA

No sensoriamento remoto de corpos d'água, a interação da luz solar com a água, juntamente com os constituintes ali presentes como fitoplâncton, sedimentos e material orgânico dissolvido, determina a assinatura espectral captada pelos sensores. De acordo com (Jensen, 2007), que aborda esses processos em detalhe, destacando a importância da absorção, espalhamento e reflexão da luz na coluna d'água para aplicações como monitoramento de qualidade da água, batimetria e estudos ecológicos.

Quando a luz solar atinge a superfície da água, parte dela é refletida, enquanto outra fração penetra na coluna d'água. A reflexão depende do ângulo de incidência e da rugosidade da superfície, que pode variar em algumas situações como ondulações e presença de espuma (Jensen, 2007).

A luz que penetra na água sofre absorção e espalhamento, processos descritos pela Lei de Beer-Lambert (Jensen, 2007):

$$I_z = I_0 \cdot e^{-K_d \cdot z} \quad (1.1)$$

onde I_z representa a intensidade da luz na profundidade z , I_0 é a intensidade na superfície e K_d é o coeficiente de atenuação difusa.

Em relação à absorção e espalhamento na água, a água pura absorve fortemente no infravermelho próximo (NIR) e infravermelho médio (MIR), permitindo maior penetração do azul e verde em águas claras (Jensen, 2007). Os fitoplânctons (clorofila) absorvem no azul e vermelho, refletindo no verde. Os sedimentos em suspensão aumentam a reflectância no vermelho e NIR. O material orgânico dissolvido (CDOM) absorve fortemente no azul, deslocando a reflectância para o verde-amarelo (Jensen, 2007).

O espalhamento ocorre devido ao espalhamento molecular (Rayleigh), dominante em águas claras, e ao espalhamento por partículas (Mie), importante em águas turvas com sedimentos e plâncton (Jensen, 2007). A zona de penetração efetiva varia conforme o tipo de água, em águas claras (oligotróficas) a luz azul atinge maiores profundidades, enquanto em águas eutróficas ou turvas a penetração é reduzida, dominada por reflexão superficial e partículas suspensas (Jensen, 2007).

1.5.5.1 SENSORIAMENTO REMOTO APLICADO À QUALIDADE DA ÁGUA

O sensoriamento remoto tem contribuído para o monitoramento de corpos hídricos ao fornecer dados contínuos e abrangentes sobre parâmetros críticos de qualidade da água, como turbidez, clorofila-a e temperatura superficial. Essas variáveis são essenciais para avaliar a saúde dos ecossistemas aquáticos, identificar fontes de poluição e monitorar mudanças sazonais ou antrópicas.

Satélites de média e alta resolução, como o Sentinel-2 e o Landsat 8 e 9, destacam-se pela capacidade de capturar informações espectrais em múltiplas bandas, permitindo a detecção de alterações sutis na qualidade da água. O Sentinel-2, por exemplo, com sua resolução espacial de 10 a 60 metros e revisita de 5 dias, é particularmente eficaz para monitorar reservatórios com alta variabilidade sazonal (Pahlevan; Schott, 2020). Já o Landsat, com uma série histórica de décadas, possibilita análises temporais de longo prazo, essenciais para estudos de tendências e impactos cumulativos (Toming; Kutser; Uiboupin, 2016).

No contexto brasileiro, pesquisas recentes no reservatório de Itupararanga (SP) têm demonstrado o potencial do sensoriamento remoto para monitorar padrões espaciais e sazonais na qualidade da água. O estudo de (Rudorff; Bernardo; Watanabe, 2022) revelou a complexa heterogeneidade das variáveis limnológicas neste reservatório, mostrando como fatores como o uso do solo na bacia hidrográfica e a sazonalidade climática influenciam significativamente a distribuição espacial de parâmetros de qualidade da água. A pesquisa destacou a eficácia de técnicas de sensoriamento remoto para identificar gradientes espaciais e variações temporais nos padrões de turbidez e material particulado, oferecendo subsídios valiosos para a gestão sustentável de recursos hídricos em sistemas lacustres.

1.5.6 DETERMINAÇÃO AUTOMÁTICA DE ÁREA SUPERFICIAL DE ÁGUA

Para identificação do alvo de estudo - os cursos d'água e reservatórios - é necessário o desenvolvimento de máscaras de água. As máscaras de água em imagens matriciais são representações binárias que distinguem pixels correspondentes a corpos d'água daqueles pertencentes a outras classes da paisagem, como vegetação, solo exposto ou áreas urbanas. No contexto do sensoriamento remoto, essas máscaras são ferramentas essenciais para a delimitação de áreas hídricas, sendo amplamente utilizadas em estudos ambientais, monitoramento de recursos hídricos e planejamento territorial. Em uma imagem matricial, cada pixel possui um valor numérico que reflete características espectrais de diferentes bandas, capturadas por sensores remotos. Es-

ses valores podem ser utilizados para identificar a presença de corpos d'água, atribuindo um valor específico para os pixels que representam água e outro para os demais elementos da paisagem. Assim, as máscaras de água transformam uma imagem multibanda complexa em uma representação simplificada, focada exclusivamente nos corpos hídricos. O sensoriamento remoto oferece um meio eficiente e econômico de monitorar mudanças ambientais, incluindo a identificação de corpos d'água e o acompanhamento de suas alterações espaciais e temporais (Jensen, 2007).

A aplicação de máscaras de água é de grande relevância em estudos ambientais, pois possibilita a delimitação precisa de corpos hídricos, minimizando interferências de elementos não relacionados (Pekel *et al.*, 2016). Essa técnica é especialmente valiosa para a gestão de recursos hídricos, permitindo o acompanhamento temporal da extensão e distribuição de superfícies aquáticas (McFeeters, 1996), (Xu, 2006).

Do ponto de vista metodológico, as máscaras de água em imagens matriciais representam uma solução eficiente para lidar com a complexidade inerente aos dados de sensoriamento remoto, conferindo maior objetividade e padronização às análises espaciais (Fisher; Flood; Danaher, 2016). Além disso, a geração de produtos geoespaciais confiáveis e exclusivamente direcionados a recursos hídricos reforça sua utilidade em monitoramento ambiental e gestão sustentável da água (Feyisa *et al.*, 2014), (Li; Du *et al.*, 2013).

1.5.7 CLASSIFICAÇÃO DA ÁGUA POR SENSORIAMENTO REMOTO

Os métodos empíricos constituem uma abordagem para a identificação e mapeamento de corpos d'água através de imagens de satélite, utilizando técnicas que se baseiam na aplicação de índices de água pré-estabelecidos, que permitem diferenciar automaticamente pixels correspondentes a água daqueles de outras coberturas que não sejam água. Os índices espectrais representam uma importante ferramenta empírica. O Índice de Diferença Normalizada da Água (NDWI), proposto por (McFeeters, 1996), utiliza a combinação matemática das bandas do espectro verde e infravermelho próximo, presentes em satélites como Landsat e Sentinel-2, para realçar a presença de água livre em imagens ópticas. Posteriormente, (Xu, 2006) desenvolveu uma versão modificada deste índice, o MNDWI, que incorpora a banda do infravermelho de onda curta (SWIR) em sua formulação. Esta adaptação mostrou-se particularmente eficaz na redução de interferências causadas por solos úmidos e vegetação, problemas comuns na aplicação do NDWI.

O mapeamento de superfícies de água utilizando técnicas de sensoriamento remoto e classificação supervisionada com algoritmos de aprendizado de máquina tem sido amplamente estudado na literatura científica. O trabalho de (Ashhar; Keesara; Sridhar, 2025) baseia-se em diversas referências consolidadas que validam a eficácia dessas metodologias. Para a classificação de água, os autores utilizam principalmente dados SAR do Sentinel-1, processados no Google Earth Engine (GEE), e comparam o desempenho de quatro algoritmos de machine learning: Support Vector Machine (SVM), Random Forest (RF), Gradient Boosting Tree (GBT) e Classification and Regression Tree (CART).

A fundamentação teórica para o uso do algoritmo Random Forest (RF), de acordo com (Breiman, 2001), é que o método pode ser utilizado como uma técnica de ensemble learning baseada em múltiplas árvores de decisão. Outros autores, como (Belgiu; Drăguț, 2016), complementam essa base ao revisar aplicações de RF em sensoriamento remoto, destacando a importância de parâmetros como número de árvores e variáveis por divisão para otimizar a classificação. Para o Support Vector Machine (SVM), os autores seguem as recomendações de (Hsu; Chang; Lin, 2003), que fornecem um guia prático para seleção de kernels, como o Radial Basis Function (RBF), e ajuste de hiperparâmetros como função de custo e gamma.

O método Maximum Entropy (MaxEnt) tem sido adaptado para a definição de limiares na detecção de corpos d'água em sensoriamento remoto, oferecendo uma abordagem probabilística robusta. Diferentemente dos métodos tradicionais de limiarização fixa, o MaxEnt modela a distribuição espectral da água como uma função de máxima entropia, considerando as características locais da cena (Phillips; Anderson; Schapire, 2006).

Além disso, estudos como (Kumar; Karwariya; Kumar, 2022) e (Pham *et al.*, 2021) fornecem contextos adicionais sobre aplicações de machine learning e dados Sentinel em mapeamento de inundações, enquanto (Mayer *et al.*, 2021) explora métodos automatizados para detecção de superfície de água com deep learning. Essas referências, coletivamente, oferecem um sólido embasamento para a metodologia de delimitação de superfície de água, demonstrando a viabilidade das técnicas de classificação supervisionada para o mapeamento preciso de corpos d'água e áreas inundadas.

1.5.8 MODELOS DE DADOS EM GEOCOMPUTAÇÃO

Os dados de sensoriamento remoto são amplamente categorizados em dois tipos principais: dados vetoriais e dados matriciais, cada um com características distintas e aplicações

específicas. A escolha entre esses tipos de dados depende da natureza do estudo e do objetivo da análise.

Os dados vetoriais representam informações geoespaciais por meio de entidades geométricas, como pontos, linhas e polígonos. Esses elementos são definidos matematicamente por coordenadas que descrevem suas formas e localizações. Por exemplo, um ponto pode representar a localização de um poço de água, uma linha pode delinear um rio e um polígono pode indicar os limites de uma bacia hidrográfica. Dados vetoriais são amplamente utilizados em análises temáticas e em Sistemas de Informações Geográficas (SIG), devido à sua precisão na representação de fronteiras e atributos associados. Segundo (Jensen, 2016), os dados vetoriais são ideais para análises que requerem precisão espacial em limites e a possibilidade de associar atributos detalhados às feições geográficas.

Por outro lado, os dados matriciais consistem em uma matriz de células (pixels), onde cada célula possui um valor que representa uma característica específica da superfície terrestre, como reflexividade, temperatura ou elevação. Este formato é a base dos dados de sensoriamento remoto obtidos por sensores orbitais ou aerotransportados. Os dados matriciais são particularmente úteis para a análise contínua de fenômenos, como cobertura vegetal, uso do solo, índices espectrais e mudanças ambientais. Esses dados são processados em diferentes bandas espectrais, o que permite a extração de informações detalhadas sobre as propriedades biofísicas da superfície terrestre. De acordo com (Lillesand; Kiefer; Chipman, 2015), os dados matriciais são cruciais para a análise de superfícies contínuas e para a aplicação de técnicas de classificação automática.

Uma diferença fundamental entre esses tipos de dados reside na forma como as informações espaciais e atributivas são armazenadas e analisadas. Enquanto os dados vetoriais são altamente eficientes para representar limites precisos e informações temáticas associadas, os dados matriciais oferecem vantagens na análise de grandes áreas e na detecção de mudanças temporais. Em aplicações práticas, é comum a integração desses dois formatos para maximizar a eficiência das análises. O estudo pode utilizar dados matriciais para classificar elementos que representam água e dados vetoriais para delimitar as áreas de interesse específicas, como limites territoriais.

1.5.9 SENSORES ORBITAIS PARA MONITORAMENTO DA ÁGUA

Sensores orbitais são dispositivos instalados em satélites que capturam informações sobre a Terra, seus oceanos e atmosfera, permitindo aplicações como monitoramento ambiental, análise climática e mapeamento.

Os satélites de sensoriamento remoto podem ser divididos em duas categorias principais conforme sua órbita: geoestacionários e de órbita polar, cada um com características operacionais e aplicações específicas (Lillesand; Kiefer; Chipman, 2015), (Jensen, 2016).

Satélites geoestacionários orbitam a aproximadamente 35.786 km de altitude sobre o equador, mantendo-se fixos em relação a um ponto da superfície terrestre, o que permite uma cobertura contínua de cerca de um terço do planeta (Salomonson, 2014). Essa posição oferece alta resolução temporal, com capacidade de imageamento a cada 5-15 minutos, tornando-os ideais para monitoramento meteorológico em tempo real, como acompanhamento de furacões e tempestades (Parker, 2017). No entanto, sua grande distância da superfície resulta em resolução espacial limitada. Podemos citar como exemplos a série GOES (Estados Unidos), Himawari (Japão) e Meteosat (Europa), amplamente utilizados para previsão do tempo (World Meteorological Organization (WMO), 2020).

Já os satélites de órbita polar operam em altitudes entre 500-800 km, seguindo órbitas heliosíncronas próximas aos polos (Campbell; Wynne, 2021). Essa configuração permite cobertura global com revisita frequente (1-2 dias) e alta resolução espacial (de <1 m a 1 km), sendo essenciais para monitoramento ambiental, como desmatamento e agricultura de precisão (Belward; Skøien, 2015). Exemplos notáveis são o Landsat (ativo desde 1972), os Sentinel (Copernicus) e os sensores MODIS (Terra/Aqua) (NASA, 2021).

Esses sensores desempenham papel fundamental no sensoriamento remoto, que coleta dados sem contato direto com o objeto de estudo. Existem diferentes tipos de sensores orbitais, cada um com características e usos específicos. Os Sensores ópticos, como o OLI (Operational Land Imager) do Landsat-8 e o MSI (Multispectral Instrument) do Sentinel-2, captam radiação nas faixas do visível, infravermelho próximo (NIR) e infravermelho de onda curta (SWIR), sendo utilizados para monitorar vegetação, corpos d'água e uso da terra. Os Sensores de radar, como o SAR (Synthetic Aperture Radar) da missão Sentinel-1, operam em micro-ondas e são eficazes sob quaisquer condições climáticas ou iluminação, sendo cruciais para monitorar gelo, solos e desastres naturais. Os Sensores térmicos, como o TIRS (Thermal Infrared Sensor) do Landsat-8, detectam radiação infravermelha emitida pela superfície, úteis para estudos

de temperatura e evapotranspiração. Os Sensores hiperespectrais, como o PRISMA, capturam centenas de bandas espectrais, permitindo identificar a composição química de materiais, sendo usados em aplicações geológicas e agrícolas ([United States Geological Survey, 2024](#)). O programa Copernicus, que inclui uma série de satélites Sentinel projetados para fornecer dados de alta qualidade sobre a Terra. O Sentinel-2 utiliza sensores multiespectrais para capturar imagens em 13 bandas diferentes, permitindo análises detalhadas da vegetação, uso da terra e qualidade da água ([European Space Agency, 2024](#)).

1.5.9.1 LANDSAT 8

O satélite Landsat 8, lançado pela NASA (National Aeronautics and Space Administration) e USGS (United States Geological Survey) em 11 de fevereiro de 2013, é uma das plataformas mais avançadas para o monitoramento da superfície terrestre. Ele possui dois sensores principais: o Operational Land Imager (OLI) e o Thermal Infrared Sensor (TIRS). O OLI capta imagens multiespectrais em nove bandas espectrais, enquanto o TIRS coleta dados em duas bandas do infravermelho térmico, permitindo estimativas da temperatura da superfície terrestre ([Roy *et al.*, 2014](#)).

Com resolução espacial de 30 metros para as bandas espectrais do visível, infravermelho próximo (NIR - Near-Infrared) e infravermelho de onda curta (SWIR - Short-Wave Infrared), e resolução de 15 metros para a banda pancromática, o Landsat 8 proporciona dados de alta qualidade para aplicações ambientais. Sua cobertura global e periodicidade de 16 dias tornam-no especialmente valioso para análises temporais, como o monitoramento de mudanças no uso do solo, qualidade da água e cobertura vegetal ([Wulder *et al.*, 2019](#)).

Na área de qualidade da água, o Landsat 8 destaca-se no monitoramento de parâmetros como concentração de clorofila-a, turbidez, sólidos suspensos e temperatura superficial. As bandas do OLI (Operational Land Imager), especialmente a azul (B2), verde (B3), vermelho (B4) e infravermelho próximo (B5), são amplamente utilizadas em índices espectrais como o Índice de Clorofila Normalizado (NCI) e o Índice de Turbidez (TI), permitindo análises detalhadas de corpos hídricos ([Pompêo *et al.*, 2021](#)).

O Landsat 8 possui dois sensores principais, Operational Land Imager (OLI) que captura imagens em nove bandas espectrais. Thermal Infrared Sensor (TIRS), que realiza coleta dados em duas bandas do infravermelho térmico. Estes sensores cobrem o espectro do visível ao infravermelho térmico, sendo projetados para aplicações como monitoramento de mudanças

na superfície terrestre, análise ambiental, estudos de qualidade da água e vegetação. O sensor Landsat 8 possui as seguintes bandas como descrito na tabela 1.1.

Tabela 1.1 – Bandas espectrais do Satélite Landsat 8 com seus respectivos comprimentos de onda e resoluções espaciais.

Banda	Nome da Banda	Comprimento (μm)	Resolução (m)
1	Coastal/Aerosol	0,43–0,45	30
2	Blue	0,45–0,51	30
3	Green	0,53–0,59	30
4	Red	0,64–0,67	30
5	NIR	0,85–0,88	30
6	SWIR 1	1,57–1,65	30
7	SWIR 2	2,11–2,29	30
8	Panchromático	0,50–0,68	15
9	Cirrus	1,36–1,38	30
10	TIRS 1	10,60–11,19	100
11	TIRS 2	11,50–12,51	100

1.5.9.2 SENTINEL-2A

O Sentinel-2A é um dos satélites do programa Copernicus, desenvolvido pela Agência Espacial Europeia (ESA) em parceria com a Comissão Europeia. Lançado em 2015, o Sentinel-2A integra um sistema de observação da Terra projetado para fornecer dados de alta qualidade aplicáveis ao monitoramento ambiental, gestão de recursos naturais e pesquisas científicas.

Equipado com o sensor Multispectral Instrument (MSI), o Sentinel-2A captura imagens em 13 bandas espectrais que cobrem desde o espectro visível até o infravermelho de onda curta (SWIR - Short-Wave Infrared). Essas bandas apresentam resoluções espaciais distintas (10 m, 20 m e 60 m), possibilitando análises detalhadas de diversos elementos da superfície terrestre.

Suas principais aplicações incluem o monitoramento de vegetação, as bandas do espectro visível e infravermelho próximo (NIR - Near-Infrared) permitem calcular índices como o NDVI (Normalized Difference Vegetation Index), essencial para avaliar a saúde da vegetação. Gestão hídrica e qualidade da água, as bandas azul (B2) e verde (B3) são particularmente eficazes para análise de corpos d'água, possibilitando a detecção de parâmetros como turbidez e concentração de clorofila. Mapeamento do uso do solo, a combinação de diferentes bandas espectrais permite discriminar áreas urbanas, zonas agrícolas e regiões de vegetação natural. Monitoramento de desastres naturais, o satélite é amplamente utilizado para detectar e avaliar impactos de incêndios florestais, inundações e processos de desmatamento. As bandas podem ser observadas na tabela 1.2.

O Sentinel-2A opera em órbita heliossíncrona, cobrindo toda a superfície terrestre em um ciclo de cinco dias quando combinado com seu satélite gêmeo, o Sentinel-2B. Esta configuração proporciona alta frequência de revisita, facilitando o acompanhamento de dinâmicas temporais e processos de mudança ambiental (Wulder *et al.*, 2019; Gascon *et al.*, 2017).

Tabela 1.2 – Bandas espectrais do Satélite Sentinel-2A com seus respectivos comprimentos de onda e resoluções espaciais.

Banda	Nome da Banda	Comprimento (μm)	Resolução (m)
1	Coastal/Aerosol	0,433–0,453	60
2	Blue	0,458–0,523	10
3	Green	0,543–0,578	10
4	Red	0,650–0,680	10
5	Red Edge 1	0,698–0,713	20
6	Red Edge 2	0,733–0,748	20
7	Red Edge 3	0,773–0,793	20
8	NIR	0,785–0,900	10
8A	Red Edge 4	0,855–0,875	20
9	Water Vapor	0,935–0,955	60
10	SWIR-Cirrus	1,360–1,390	60
11	SWIR 1	1,565–1,655	20
12	SWIR 2	2,100–2,280	20

1.5.10 PROCESSAMENTO DE IMAGENS

O processamento de imagens é um campo multidisciplinar que envolve a manipulação e análise de imagens digitais para melhorar sua qualidade, extrair informações ou transformá-las para usos específicos. Ele é amplamente utilizado em diversas áreas, como engenharia, medicina, sensoriamento remoto, segurança e entretenimento.

Esse processo pode ser dividido em etapas fundamentais, incluindo o pré-processamento, que visa corrigir e preparar as imagens para análise; a segmentação, que separa os elementos da imagem com base em critérios como cor, textura ou brilho; e a classificação, que identifica padrões ou categorias dentro da imagem (Gonzalez; Woods, 2018).

O pré-processamento é essencial para corrigir distorções geométricas, ajustar o brilho ou remover ruídos presentes nas imagens capturadas. Técnicas como filtragem espacial e transformações no domínio da frequência são comuns para aprimorar a qualidade das imagens. Por exemplo, filtros de suavização ajudam a reduzir ruídos, enquanto filtros de realce destacam bordas e detalhes importantes (Jähne, 2005).

O processamento digital de imagens é a etapa que transforma os dados brutos capturados pelos sensores em informações interpretáveis. Esse processo inclui correções atmosféricas, radiométricas e geométricas, além da aplicação de técnicas de realce, classificação e segmentação de imagens. Utiliza-se aritmética de bandas e aplicação de índices (Richards; Jia, 2013).

1.5.11 GEOCOMPUTAÇÃO AMBIENTAL COM R

A geocomputação é uma área interdisciplinar que combina técnicas de análise espacial, ciência da computação e estatística para resolver problemas relacionados ao espaço geográfico. O R, uma linguagem de programação amplamente utilizada na análise de dados, tornou-se uma ferramenta fundamental para a geocomputação devido à sua capacidade de manipular, processar e visualizar dados espaciais de forma eficiente. Segundo (Lovelace; Nowosad; Muenchow, 2019), o R oferece uma ampla gama de pacotes especializados que suportam diferentes aspectos do trabalho com dados geográficos, como importação, processamento, análise e visualização.

Um dos principais pontos fortes do R na geocomputação é a sua flexibilidade e o suporte à análise de grandes volumes de dados espaciais. Pacotes como `sf` (Simple Features), `raster` e `terra` permitem o manuseio de dados vetoriais e matriciais, enquanto bibliotecas como `ggplot2` e `tmap` oferecem ferramentas poderosas para a visualização de mapas e dados espaciais. De acordo com (Lovelace; Nowosad; Muenchow, 2019), o pacote `sf` é particular-

mente relevante, pois introduz um modelo de dados simples e eficiente que melhora o desempenho e simplifica o manuseio de dados geográficos.

Além disso, o R promove a reproducibilidade das análises espaciais, uma característica essencial para a ciência. Scripts e códigos desenvolvidos no R podem ser compartilhados e reutilizados, garantindo que os métodos aplicados sejam verificáveis. Outro aspecto importante é a capacidade do R de se integrar a outras ferramentas e fontes de dados, como *Application Programming Interfaces* (APIs) para acesso a dados espaciais online, softwares GIS como QGIS, PostGIS e SAGA GIS, e linguagens de programação como Python. Essa interoperabilidade amplia ainda mais as possibilidades de aplicação da geocomputação em áreas como sensoriamento remoto, gestão ambiental e modelagem de mudanças climáticas.

1.5.12 PACOTES R

O R é amplamente reconhecido por suas capacidades analíticas e estatísticas, tem se destacado como uma ferramenta poderosa para manipulação e análise de dados geoespaciais. Dentre os principais pacotes para esse fim, destacam-se `raster`, `terra` e `sf`, cada um com funcionalidades e aplicações específicas.

O pacote `raster` foi um marco na análise de dados matriciais no R. Ele fornece ferramentas para leitura, manipulação, análise e escrita de dados matriciais, sendo particularmente útil para lidar com essas camadas em diversos formatos, como GeoTIFF e ASCII. Dentre as suas principais funcionalidades incluem a manipulação de grandes conjuntos de dados matriciais. Aplicação de operações matemáticas em imagens matriciais, como cálculo de índices, extração de valores matriciais com base em dados espaciais vetoriais (Hijmans, 2019)

Apesar de ser amplamente utilizado para dados geoespaciais, o pacote `raster` apresenta limitações de desempenho, especialmente ao lidar com grandes volumes de dados. Para superar essas restrições, foi criado o pacote `terra`, que é considerado seu sucessor. É uma evolução do `raster` e foi projetado para oferecer maior eficiência e desempenho. Ele utiliza bibliotecas modernas, como GDAL e PROJ, para manipular dados raster e vetoriais de forma mais eficaz. Possui suporte a múltiplos formatos espaciais. Melhor gerenciamento de memória e velocidade de processamento. E uma integração simplificada com outras ferramentas do R para análises espaciais (Hijmans, 2023).

O pacote `sf` (Simple Features) introduziu um novo paradigma para manipulação de dados vetoriais no R, substituindo o antigo pacote `sp`. Segue o padrão Simple Features, ampla-

mente utilizado em Sistemas de Informação Geográfica (SIG). As funcionalidades do `sf` estão relacionadas a leitura e escrita de formatos vetoriais, como shapefiles e GeoJSON. Permitindo realizar operações geoespaciais, como buffers, interseções e união de polígonos. Existe uma compatibilidade com sistemas de coordenadas por meio de reprojeção. E também a integração com outros pacotes do R de ciência de dados como `dplyr` e `ggplot2`, possibilitando a análise e visualização de dados (Pebesma, 2018)

O `RSToolbox` é um conjunto de ferramentas desenvolvido para o ambiente de programação R, voltado para o processamento de dados geoespaciais, especialmente aqueles provenientes de imagens de satélite. O pacote facilita a análise e manipulação de dados matriciais. Dentre as suas funcionalidades estão a manipulação de imagens matriciais, classificação de dados, criação de mapas, cálculo de índices espectrais (Bivand; R., 2018).

Além desses pacotes gerais para análise geoespacial, o R também oferece ferramentas especializadas para estudos ambientais, como o pacote `waterquality`, que permite a avaliação de parâmetros essenciais para o monitoramento de corpos hídricos.

1.5.12.1 PACOTE WATERQUALITY

O pacote `waterquality` da linguagem R é uma ferramenta desenvolvida para análise de dados relacionados à qualidade da água, permitindo cálculos e visualizações de índices que refletem aspectos como turbidez, clorofila e outros parâmetros físico-químicos e biológicos. Entre suas principais funcionalidades destacam-se. O Cálculo de Índices de Qualidade da Água (IQA), o pacote inclui métodos para calcular índices padronizados de qualidade da água, utilizando variáveis como pH, oxigênio dissolvido, fósforo e nitrogênio. Análise Temporal e Espacial, ferramentas para avaliar mudanças nos parâmetros de qualidade da água ao longo do tempo ou em diferentes locais (Liu; Han, 2016).

O pacote possui alguns algoritmos principais, dentre eles:

- **Al10SABI (Simple Atmospheric Baseline Index):**

O algoritmo `Al10SABI` é projetado para medir a presença e a intensidade de substâncias bio-ópticas, como fitoplâncton e partículas suspensas, em corpos d'água. Ele utiliza bandas do espectro visível e do infravermelho próximo (NIR), calculando um índice que reflete a contribuição relativa de matéria orgânica e inorgânica na coluna d'água. Este índice é sensível a variações atmosféricas e frequentemente utilizado para monitoramento de corpos hídricos em larga escala.

A fórmula do índice é dada por:

$$AI10SABI = \frac{R(NIR) - R(Blue)}{R(NIR) + R(Blue)}$$

onde R representa a reflectância nas bandas correspondentes.

- **MM12NDCI (Normalized Difference Chlorophyll Index):**

O MM12NDCI é um índice desenvolvido para estimar a concentração de clorofila-a em ambientes aquáticos. Ele utiliza as bandas do vermelho (Red) e do infravermelho próximo (NIR) para diferenciar regiões com altas concentrações de clorofila, sendo amplamente empregado em estudos de eutrofização e produtividade primária.

A fórmula do índice é dada por:

$$MN12NDCI = \frac{R(NIR) - R(Red)}{R(NIR) + R(Red)}$$

Este índice é ideal para corpos hídricos turvos ou com alta concentração de sedimentos.

- **Go04MCI (Maximum Chlorophyll Index):**

O algoritmo Go04MCI é uma abordagem refinada para estimar altas concentrações de clorofila-a, principalmente em áreas eutrofizadas. Ele utiliza bandas no vermelho (Red), no infravermelho próximo (NIR) e no vermelho distante (Red-edge) para capturar variações associadas à fluorescência da clorofila e à absorção de luz em altas densidades de fitoplâncton.

A fórmula do índice é dada por:

$$MCI = R(\lambda_{Red-edge}) - \left[R(\lambda_{Red}) + \frac{\lambda_{Red-edge} - \lambda_{Red}}{\lambda_{NIR} - \lambda_{Red}} \cdot (R(\lambda_{NIR}) - R(\lambda_{Red})) \right]$$

Este índice é amplamente utilizado em sensores como Sentinel-2 e OLCI para detectar florações de algas e monitorar ecossistemas aquáticos produtivos.

1.5.13 NORMALIZED DIFFERENCE WATER INDEX

O Índice de Água por Diferença Normalizada (NDWI, do inglês *Normalized Difference Water Index*) é uma métrica amplamente utilizada para monitorar corpos d'água em imagens de satélite. Ele foi desenvolvido para destacar áreas de água em imagens, especialmente em regiões onde a água pode estar parcialmente oculta ou misturada com outros elementos, como vegetação ou solo. Pode ser calculado usando a seguinte equação:

$$NDWI = \frac{NIR - Green}{NIR + Green}$$

O índice é especialmente útil para áreas costeiras, lagos e rios, pois permite distinguir a água da vegetação e da superfície do solo, mesmo quando esses elementos estão próximos. Ele pode ser utilizado para diversas finalidades, como Monitoramento da qualidade da água, detecção de mudanças no nível de água devido a eventos climáticos. Avaliação do impacto de construções ou alterações no uso do solo em áreas aquáticas. Detecção de inundações e secas em áreas propensas a esses eventos. Avaliação de parâmetros como salinidade e temperatura das águas

Sua aplicação vai além do simples monitoramento visual, permitindo a tomada de decisões mais fundamentadas sobre a qualidade, preservação e uso dos recursos hídricos (McFeeters, 1996; Gitelson; Merzlyak, 1994; Xu, 2006).

1.5.14 ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA

O Índice de Vegetação por Diferença Normalizada (NDVI, do inglês *Normalized Difference Vegetation Index*) é amplamente reconhecido como um dos índices mais utilizados em aplicações de sensoriamento remoto para a análise da cobertura vegetal. Sua fórmula, baseada na razão entre as bandas do infravermelho próximo (NIR) e do vermelho (RED), destaca as áreas de vegetação saudável devido à alta refletância no NIR e à baixa refletância no vermelho (Tucker, 1979). A equação do NDVI é dada por:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

No contexto de recursos hídricos, o NDVI pode ser adaptado para a identificação de corpos d'água, uma vez que a água apresenta valores baixos ou negativos no índice devido à sua refletância mínima em ambas as bandas. A criação de máscaras de água utilizando o NDVI tem se mostrado uma abordagem prática e eficaz em diversos contextos. Este método se baseia em estabelecer um limiar para os valores do NDVI que permite a separação entre áreas de água, vegetação e solo exposto. Em geral, valores de NDVI próximos a zero ou negativos são indicativos de corpos d'água (McFeeters, 1996).

1.5.15 TASSELED CAP

O Tasseled Cap (TC) é uma técnica amplamente utilizada no processamento de imagens de satélite para reduzir a complexidade dos dados e facilitar a análise de características específicas das superfícies terrestres. A técnica utiliza uma transformação linear das bandas espectrais de imagens, como as do Landsat, para destacar os componentes essenciais de uma cena, como brilho, umidade e vegetação, entre outros. No contexto da produção de máscaras de água, o Tasseled Cap tem se mostrado uma ferramenta valiosa, pois permite a identificação precisa de corpos d'água, melhorando a acurácia da classificação em áreas de grande extensão e complexidade.

O Tasseled Cap foi originalmente desenvolvido para imagens de satélite Landsat e tem sido amplamente empregado em diversas aplicações, como o monitoramento da vegetação, a identificação de áreas urbanas e a avaliação de mudanças no uso do solo (Kauth; Thomas, 1976). A transformação gerada por esse método resulta em três componentes principais: brilho, verde e umidade, que podem ser utilizadas para distinguir diferentes tipos de cobertura da terra. A partir dessas componentes, é possível segmentar áreas de interesse, como corpos d'água, com maior precisão.

A aplicação do Tasseled Cap na produção de máscaras de água envolve a utilização das componentes geradas, especialmente a componente de umidade, para identificar regiões aquáticas em uma imagem. A umidade da superfície é fortemente correlacionada com corpos d'água, permitindo que os pixels correspondentes a essas áreas sejam facilmente separados de outras superfícies, como vegetação ou solo. A técnica do Tasseled Cap, combinada com a análise de índices espectrais, como o NDWI (Normalized Difference Water Index), tem demonstrado eficácia na delimitação de corpos d'água em imagens de satélite de alta resolução (Souza *et al.*, 2013).

A principal vantagem do Tasseled Cap é sua simplicidade e eficiência no processamento de grandes volumes de dados, sem a necessidade de segmentações complexas. Ao aplicar essa técnica, é possível identificar corpos d'água com alta acurácia, mesmo em regiões de difícil acesso ou em imagens com grande variação na cobertura do solo. Além disso, a integração do Tasseled Cap com metodologias de aprendizado supervisionado e não supervisionado proporciona uma maneira robusta de melhorar a qualidade da classificação.

1.5.16 ALBEDO

O albedo é uma medida da refletância ou da capacidade de uma superfície refletir a radiação solar incidente. No contexto do sensoriamento remoto, o albedo das superfícies naturais varia de acordo com suas características físicas, sendo um parâmetro valioso para identificar diferentes tipos de cobertura terrestre. Em particular, o albedo apresenta diferenças significativas entre corpos d'água e superfícies terrestres, tornando-se uma ferramenta eficaz para a geração de máscaras de água.

Superfícies aquáticas, devido à sua baixa refletância em grande parte do espectro eletromagnético, apresentam valores de albedo relativamente baixos em comparação com áreas urbanas, agrícolas ou florestais. Essa característica permite que métodos baseados em índices de albedo sejam utilizados para distinguir corpos d'água de outras classes de uso e cobertura do solo em imagens de satélite (Liang, 2000; Schaepman-Strub *et al.*, 2006).

A geração de máscaras de água utilizando o albedo requer a análise espectral das bandas refletivas, geralmente as bandas visíveis e do infravermelho próximo (NIR). Por exemplo, satélites como o Landsat e o Sentinel fornecem dados espectrais com resolução suficiente para calcular o albedo e identificar áreas de baixa refletância que correspondem a corpos d'água (Liang; Fang; Chen, 2012).

O albedo pode ser combinado com outros índices espectrais, como o Índice de Vegetação por Diferença Normalizada (NDVI) ou o Índice Normalizado de Diferença da Água (NDWI), para aprimorar a precisão na identificação de corpos d'água. Essa abordagem híbrida permite reduzir falsos positivos em áreas que possam apresentar valores semelhantes de albedo, como solos escuros ou regiões urbanas (Breon; Tanre; Generoso, 2002).

1.5.17 CLASSIFICAÇÃO SUPERVISIONADA DA ÁGUA

A criação de máscaras de água a partir da classificação supervisionada em imagens de satélite é uma técnica amplamente utilizada no Sensoriamento Remoto para identificar e mapear corpos d'água com precisão. Esse método baseia-se no treinamento de um modelo para classificar os pixels da imagem em diferentes categorias, como "água" e "não água", com base em amostras previamente definidas. O processo pode ser dividido em etapas como a preparação dos dados, seleção de amostras de treinamento, treinamento do classificador, classificação propriamente dita e validação dos resultados.

Após o download e a correção radiométrica das imagens, a etapa seguinte envolve a seleção de amostras de treinamento representativas. Essas amostras são obtidas com base no conhecimento prévio da área de estudo, por meio da inspeção visual da imagem ou a partir de dados de campo. A representatividade e a variabilidade espectral das amostras são fundamentais para garantir que o modelo de classificação seja robusto e capaz de generalizar os padrões espectrais de água e de superfícies não aquáticas (Foody, 2002).

O treinamento do modelo é realizado utilizando algoritmos de aprendizado supervisionado, como Máquinas de Vetores de Suporte (SVM), Redes Neurais Artificiais (ANN) e Random Forest. O algoritmo SVM, por exemplo, é amplamente utilizado devido à sua capacidade de lidar com fronteiras não lineares entre classes. Por outro lado, o Random Forest é conhecido por sua robustez contra ruídos e pela facilidade em lidar com grandes conjuntos de dados (Pal; Mather, 2005).

A validação dos resultados, para avaliar a precisão da máscara gerada, pode ser feita por meio de métricas como a acurácia geral, o coeficiente kappa e a matriz de confusão, amplamente utilizadas na validação de classificações. O pós-processamento também pode ser necessário para corrigir erros pontuais, como a remoção de pequenos grupos de pixels mal classificados, melhorando assim a qualidade final do mapa (Congalton; Green, 2009).

1.5.17.1 MULTIPLE ENDMEMBER SPECTRAL MIXTURE ANALYSIS

O Multiple Endmember Spectral Mixture Analysis (MESMA) é uma técnica em sensoriamento remoto que permite a análise da composição espectral de pixels que contêm múltiplos materiais ou superfícies. O pacote `RStoolbox` oferece ferramentas para a análise de mistura espectral, implementando especificamente essa abordagem. O MESMA é uma abordagem robusta para estimar as frações de classes espectrais, permitindo identificar a contribuição de diferentes materiais dentro de um pixel, em uma escala subpixel. Essa técnica é particularmente útil em situações em que a resolução espacial da imagem não é alta o suficiente para distinguir materiais individuais de forma explícita, como em áreas com vegetação densa ou corpos d'água (Adams *et al.*, 1993).

Em termos práticos, o procedimento básico envolve três etapas principais: primeiro, a definição dos endmembers, em seguida, a aplicação do modelo de mistura espectral para calcular as frações. E por fim, a interpretação dos resultados para compreender a composição do

terreno ou da superfície em estudo. O resultado da análise oferece uma representação quantitativa da distribuição dos materiais como solos, vegetação e água dentro de cada pixel.

A estimativa das frações de cada material é realizada utilizando algoritmos de otimização, como o método Least Squares Estimation (LSE), que minimiza a diferença entre o espectro observado e o espectro gerado pela combinação dos endmembers (Boardman; Kruse; Green, 1995). Após a estimativa das frações, a precisão dos resultados é validada, geralmente com dados de campo ou imagens de maior resolução espacial. A validação é essencial para garantir que as estimativas das frações dos materiais sejam precisas e representativas da realidade (Roberts *et al.*, 1998).

1.5.17.2 MAXIMUM ENTROPY MODELING

O Maximum Entropy Modeling (MaxEnt) é um dos métodos mais utilizados para modelagem de distribuição de espécies Species Distribution Modeling (SDM) a partir de dados de presença. Desenvolvido originalmente por (Phillips; Anderson; Schapire, 2006) e (Phillips; Dudík; Schapire, 2017), o algoritmo tem sido amplamente aplicado em ecologia, conservação, arqueologia e outras áreas que necessitam prever a distribuição espacial de fenômenos com base em dados de presença e variáveis ambientais.

O princípio fundamental do MaxEnt é encontrar a distribuição de probabilidade que maximiza a entropia — ou seja, que é a mais dispersa ou a mais próxima da uniformidade, sujeita às restrições impostas pelas variáveis ambientais nos locais de presença conhecidos. Diferentemente de outros métodos que requerem dados de ausência, o MaxEnt utiliza apenas dados de presença e pontos de fundo, que representam as condições ambientais disponíveis na área de estudo. O algoritmo funciona comparando as condições ambientais nos locais de presença com aquelas existentes em toda a área de estudo, calculando duas funções de densidade de probabilidade: uma para os pontos de presença e outra para os pontos de fundo. A razão entre essas densidades fornece a adequabilidade ambiental relativa para cada ponto da área de estudo (Elith *et al.*, 2011).

O MaxEnt considera seis tipos de features que permitem diferentes formas para as curvas de resposta ambiental. Por padrão, o algoritmo utiliza todos os tipos, mas é possível simplificar o modelo empregando apenas alguns deles. Para evitar o sobreajuste, overfitting, o MaxEnt aplica regularização de duas formas: relaxando as restrições, utilizando intervalos de confiança em vez de valores exatos, e penalizando a complexidade ao excluir features que não contribuem

significativamente para o modelo. A saída bruta do MaxEnt passa por uma transformação logística para facilitar a interpretação, produzindo valores entre 0 e 1, que podem ser interpretados como a probabilidade de presença (Phillips; Dudík, 2008).

REFERÊNCIAS GERAIS

ADAMS, R. M. *et al.* Thematic mapper spectral mixture analysis. **Remote Sensing of Environment**, v. 44, n. 3, p. 255–268, 1993.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Sistema de Informações Hidrológicas**. [S. l.: s. n.], 2023. Acesso em: 18 mai. 2025. Disponível em: <https://www.snirh.gov.br/hidroweb/>.

ALLAN, J. D. *et al.* The influence of land use and land cover change on stream hydrology and water quality in the semi-arid region of the north-eastern United States. **Hydrological Processes**, v. 23, n. 4, p. 574–588, 2009. DOI: [10.1002/hyp.7164](https://doi.org/10.1002/hyp.7164).

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. DOI: [10.1127/0941-2948/2013/0507](https://doi.org/10.1127/0941-2948/2013/0507).

ASHHAR, M.; KEESARA, V. R.; SRIDHAR, V. Flood Inundation Mapping of a River Stretch Using Machine Learning Algorithms in the Google Earth Engine Environment. **Journal of Flood Risk Management**, v. 18, e70062, 2025. DOI: [10.1111/jfr3.70062](https://doi.org/10.1111/jfr3.70062).

BARROS, H. P.; FERREIRA, E. A. A.; SILVA, F. R. **Monitoramento da qualidade da água em corpos hídricos: metodologia e resultados**. Rio de Janeiro: Editora ABRH, 2005.

BELGIU, M.; DRĂGUT, L. Random Forest in Remote Sensing: A Review of Applications and Future Directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016. DOI: [10.1016/j.isprsjprs.2016.01.011](https://doi.org/10.1016/j.isprsjprs.2016.01.011).

BELWARD, A.; SKØIEN, J. O. Who launched what, when and why? Trends in global land-cover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 115–128, 2015. DOI: [10.1016/j.isprsjprs.2014.03.009](https://doi.org/10.1016/j.isprsjprs.2014.03.009).

BIVAND, R.; R. RS-Toolbox: A toolbox for the processing of geospatial data in R. **Journal of Geospatial Analysis**, v. 16, n. 2, p. 101–115, 2018.

BOARDMAN, J. W.; KRUSE, F. A.; GREEN, R. O. Mapping target signatures via partial unmixing of AVIRIS data. **Summaries of the Fifth Annual JPL Airborne Earth Science Workshop**, p. 23–26, 1995.

BRASIL. **Conama 357/2005: Estabelece as condições e padrões para o lançamento de efluentes no meio ambiente**. [S. l.: s. n.], 2005. Ministério do Meio Ambiente, Brasil.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI: [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324).

BREON, F.-M.; TANRE, D.; GENEROSO, S. Aerosol effect on cloud droplet size monitored from satellite. **Science**, American Association for the Advancement of Science, v. 295, n. 5556, p. 834–838, 2002.

CAMPBELL, J. B.; WYNNE, R. H. **Introduction to Remote Sensing**. 6. ed. New York: Guilford Press, 2021.

CHAPRA, S. C.; B., R. P. K. T. D. P. R. J. W. A. K. T. P. K. D. **Surface Water-Quality Modeling**. [S. l.]: Waveland Press, 1997.

CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 2nd. [S. l.]: CRC Press, 2009.

CUNHA, D. F.; RODRIGUES, F. T.; BARBOSA, D. A. **Monitoramento ambiental: métodos e técnicas**. São Paulo: Editora Ática, 2007.

DEKKER, A. G.; PETERS, S. W. The use of the thematic mapper for the analysis of water quality parameters in lakes. **Remote Sensing of Environment**, v. 66, p. 496–501, 2001.

ELITH, J. *et al.* A statistical explanation of MaxEnt for ecologists. **Diversity and Distributions**, Wiley Online Library, v. 17, n. 1, p. 43–57, 2011.

EUROPEAN SPACE AGENCY. **Copernicus Sentinel-2 Overview**. [S. l.: s. n.], 2024. Accessed: 2024-12-22. Disponível em: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2.

FEYISA, G. L. *et al.* Automated Water Extraction Index: A New Technique for Surface Water Mapping Using Landsat Imagery. **Remote Sensing of Environment**, v. 140, p. 23–35, 2014. DOI: [10.1016/j.rse.2013.08.029](https://doi.org/10.1016/j.rse.2013.08.029).

FISHER, A.; FLOOD, N.; DANAHER, T. Comparing Landsat Water Index Methods for Automated Water Classification in Eastern Australia. **Remote Sensing of Environment**, v. 175, p. 167–182, 2016. DOI: [10.1016/j.rse.2016.03.029](https://doi.org/10.1016/j.rse.2016.03.029).

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, Elsevier, v. 80, n. 1, p. 185–201, 2002. DOI: [10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4).

GAO, B.-C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, p. 257–266, 1996.

GASCON, F. *et al.* Copernicus Sentinel-2A Calibration and Products Validation Status. **Remote Sensing**, v. 9, n. 6, p. 584, 2017. DOI: [10.3390/rs9060584](https://doi.org/10.3390/rs9060584).

GHOLIZADEH, M. H.; MELESSE, A. M.; REDDI, L. A comprehensive review on water quality parameters estimation using remote sensing techniques. **Sensors**, v. 16, n. 8, p. 1298, 2016.

GITELSON, A. A.; MERZLYAK, M. N. Spectral Reflectance Characteristics of Growing Green Leaves and Natural Vegetation. **Remote Sensing of Environment**, v. 47, n. 3, p. 1–21, 1994. DOI: [10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1).

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 4th. Upper Saddle River, NJ, USA: Pearson, 2018.

HIJMANS, R. J. **raster: Geographic Data Analysis and Modeling**. [S. l.], 2019. R package version 3.5-21. Disponível em: <https://CRAN.R-project.org/package=raster>.

HIJMANS, R. J. **terra: Spatial Data Analysis**. [S. l.], 2023. R package version 1.7-29. Disponível em: <https://cran.r-project.org/package=terra>.

HSU, C.-W.; CHANG, C.-C.; LIN, C.-J. A Practical Guide to Support Vector Classification, 2003. Disponível em: <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual Técnico da Vegetação Brasileira**. 2. ed. Rio de Janeiro, 2019.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Banco de Dados Meteorológicos**. [S. l.: s. n.], 2023. Acesso em: 18 mai. 2025. Disponível em: <https://portal.inmet.gov.br/>.

JÄHNE, B. **Digital Image Processing**. 6th. Berlin, Germany: Springer, 2005.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2nd. Upper Saddle River, NJ: Pearson Prentice Hall, 2007.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2. ed. [S. l.]: Pearson, 2016.

KAUTH, R. J.; THOMAS, G. S. The tasseled cap—A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. *In: PROCEEDINGS of the Symposium on Machine Processing of Remotely Sensed Data. [S. l.: s. n.], 1976. p. 4–9.*

KIBLER, D.; ADIM, A.; AL., et. Real-time water quality monitoring for environmental management: A review. **Water Quality Research Journal of Canada**, v. 46, n. 4, p. 305–315, 2011. DOI: [10.2166/wqrjc.2011.049](https://doi.org/10.2166/wqrjc.2011.049).

KUMAR, H.; KARWARIYA, S. K.; KUMAR, R. Google Earth Engine-Based Identification of Flood Extent and Flood Affected Paddy Rice Fields Using Sentinel-2 MSI and Sentinel-1 SAR Data in Bihar State, India. **Journal of the Indian Society of Remote Sensing**, v. 50, p. 791–803, 2022. DOI: [10.1007/s12524-021-01487-3](https://doi.org/10.1007/s12524-021-01487-3).

LEHNINGER, A. L.; NELSON, D. L.; COX, M. M. **Princípios de Bioquímica**. 6. ed. Porto Alegre: Artmed Editora, 2017. ISBN 978-8582715119.

LI, L.; LI, J.; GONG, P. A review of remote sensing image classification techniques: the role of spatio-contextual information. **European Journal of Remote Sensing**, v. 50, p. 331–350, 2017.

LI, W.; DU, Z. *et al.* A Comparison of Land Surface Water Mapping Using the Normalized Difference Water Index from TM, ETM+ and ALI. **Remote Sensing**, v. 5, n. 11, p. 5530–5549, 2013. DOI: [10.3390/rs5115530](https://doi.org/10.3390/rs5115530).

LIANG, S. Narrowband to broadband conversions of land surface albedo I: Algorithms. **Remote Sensing of Environment**, Elsevier, v. 76, n. 2, p. 213–238, 2000.

LIANG, S.; FANG, H.; CHEN, M. Atmospheric correction of Landsat ETM+ land surface imagery—Part I: Methods. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 51, n. 2, p. 660–670, 2012.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote Sensing and Image Interpretation**. 7th. [S. l.]: Wiley, 2015.

LIU, Y.; HAN, J. **waterquality: Water Quality Index Computation**. [S. l.], 2016. R package version 1.0. Disponível em: <https://cran.r-project.org/package=waterquality>.

LOVELACE, R.; NOWOSAD, J.; MUENCHOW, J. **Geocomputation with R: Solving Geographical Problems Using Combinations of Open Source Software**. Boca Raton, FL: CRC Press, 2019.

MAPBIOMAS. **Coleção 7 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil**. [S. l.: s. n.], 2022. Acesso em: 18 mai. 2025. Disponível em: <https://mapbiomas.org/>.

MAYER, T. *et al.* Deep Learning Approach for Sentinel-1 Surface Water Mapping Leveraging Google Earth Engine. **ISPRS Open Journal of Photogrammetry and Remote Sensing**, v. 2, p. 100005, 2021. DOI: [10.1016/j.ophoto.2021.100005](https://doi.org/10.1016/j.ophoto.2021.100005).

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. DOI: [10.1080/01431169608948714](https://doi.org/10.1080/01431169608948714).

NASA. **Earth Observing System (EOS): MODIS**. [S. l.: s. n.], 2021.
<https://modis.gsfc.nasa.gov/>. Accessed: 2023-10-10.

OUMA, Y. O.; TATEISHI, R. Urban flood vulnerability and risk mapping using integrated multi-parametric AHP and GIS: Methodological overview and case study assessment. **Water**, v. 4, n. 4, p. 590–591, 2012.

PAHLEVAN, N.; SCHOTT, J. R. Landsat 8 remote sensing reflectance (Rrs) products: Evaluations, intercomparisons, and enhancements. **Remote Sensing of Environment**, v. 239, p. 111610, 2020. DOI: [10.1016/j.rse.2019.111610](https://doi.org/10.1016/j.rse.2019.111610).

PAL, M.; MATHER, P. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, Taylor & Francis, v. 26, n. 5, p. 1007–1011, 2005.

PARKER, W. S. **Satellite Meteorology**. [S. l.]: Cambridge University Press, 2017.

PEBESMA, E. Simple Features for R: Standardized Support for Spatial Vector Data. **The R Journal**, v. 10, n. 1, p. 439–446, 2018. Disponível em:
<https://CRAN.R-project.org/package=sf>.

PEKEL, J.-F. *et al.* High-Resolution Mapping of Global Surface Water and Its Long-Term Changes. **Nature**, v. 540, n. 7633, p. 418–422, 2016. DOI: [10.1038/nature20584](https://doi.org/10.1038/nature20584).

PEREIRA, L. S.; ALLEN, R. G. Crop evapotranspiration estimation with remote sensing: A new perspective for modelling and observation. **Irrigation and Drainage Systems**, v. 33, p. 309–320, 2019.

PHAM, B. *et al.* Flood Risk Assessment Using Deep Learning Integrated With Multi-Criteria Decision Analysis. **Knowledge-Based Systems**, v. 219, p. 106899, 2021. DOI: [10.1016/j.knosys.2021.106899](https://doi.org/10.1016/j.knosys.2021.106899).

PHILLIPS, S. J.; DUDÍK, M. Modeling of species distributions with Maxent: new extensions and a comprehensive evaluation. **Ecography**, Wiley Online Library, v. 31, n. 2, p. 161–175, 2008.

PHILLIPS, S. J.; DUDÍK, M.; SCHAPIRE, R. E. Opening the black box: an open-source release of Maxent. **Ecography**, Wiley Online Library, v. 40, n. 7, p. 887–893, 2017.

PHILLIPS, S. J.; ANDERSON, R. P.; SCHAPIRE, R. E. Maximum entropy modeling of species geographic distributions. **Ecological Modelling**, v. 190, n. 3-4, p. 231–259, 2006. DOI: [10.1016/j.ecolmodel.2005.03.026](https://doi.org/10.1016/j.ecolmodel.2005.03.026).

POMPÊO, M. *et al.* Water quality assessment using Sentinel-2 imagery with estimates of chlorophyll a, Secchi disk depth, and Cyanobacteria cell number: the Cantareira System reservoirs (São Paulo, Brazil). **Environmental Science and Pollution Research**, v. 28, n. 26, p. 34990–35011, 2021. ISSN 1614-7499. DOI: [10.1007/s11356-021-12975-x](https://doi.org/10.1007/s11356-021-12975-x). Disponível em: <https://doi.org/10.1007/s11356-021-12975-x>.

POSTEL, S. L.; DAILY, G. C.; EHRLICH, P. R. Human appropriation of renewable fresh water. **Science**, v. 271, n. 5250, p. 785–788, 1996.

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis**. 5th. [S. l.]: Springer, 2013. ISBN 978-3-642-30061-5.

ROBERTS, D. A. *et al.* Mapping forest composition using airborne imaging spectroscopy and neural networks. **Remote Sensing of Environment**, v. 65, n. 3, p. 285–297, 1998. DOI: [10.1016/S0034-4257\(98\)00061-3](https://doi.org/10.1016/S0034-4257(98)00061-3).

ROY, D. P. *et al.* Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, p. 154–172, 2014. DOI: [10.1016/j.rse.2014.02.001](https://doi.org/10.1016/j.rse.2014.02.001). Disponível em: <https://doi.org/10.1016/j.rse.2014.02.001>.

RUDORFF, N.; BERNARDO, N.; WATANABE, F. Heterogeneidade espacial e temporal de variáveis limnológicas no reservatório de Itupararanga associadas com o uso do solo na Bacia do Alto Sorocaba-SP. **Revista Brasileira de Recursos Hídricos**, v. 27, e15, 2022. DOI: <https://doi.org/10.4136/ambi-agua.1715>.

SALOMONSON, V. V. Earth Observing System (EOS): Overview. *In*: WENG, Q. (ed.). **Encyclopedia of Remote Sensing**. [S. l.]: Springer, 2014. p. 185–190.

SAÚDE, O. M. da. **Água potável e saúde**. [S. l.: s. n.], 2017. <https://www.who.int/health-topics/drinking-water>.

SCHAEPMAN-STRUB, G. *et al.* Reflectance quantities in optical remote sensing—Definitions and case studies. **Remote Sensing of Environment**, Elsevier, v. 103, n. 1, p. 27–42, 2006.

SOUZA, L. F. *et al.* Application of tasseled cap transformation in remote sensing for the identification of water bodies. **Remote Sensing**, v. 5, n. 7, p. 3509–3520, 2013. DOI: [10.3390/rs5073509](https://doi.org/10.3390/rs5073509).

TOMING, K.; KUTSER, T.; UIBOUPIN, R. Mapping water quality parameters with Sentinel-3 Ocean and Land Colour Instrument imagery in the Baltic Sea. **Remote Sensing**, v. 8, n. 7, p. 640, 2016. DOI: [10.3390/rs8080640](https://doi.org/10.3390/rs8080640).

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, Elsevier, v. 8, n. 2, p. 127–150, 1979.

UNESCO. **The United Nations World Water Development Report 2020: Water and Climate Change**. Paris, France: UNESCO Publishing, 2020.

UNITED STATES GEOLOGICAL SURVEY. **Landsat Missions**. [S. l.: s. n.], 2024. Accessed: 2024-12-22. Disponível em: <https://www.usgs.gov/landsat-missions>.

VANHELLEMONT, Q.; RUDDICK, K. G. A method for the retrieval of suspended matter concentrations in turbid waters from Sentinel-2 data. **Remote Sensing of Environment**, v. 166, p. 1–13, 2015. DOI: [10.1016/j.rse.2015.06.023](https://doi.org/10.1016/j.rse.2015.06.023). Disponível em: <https://doi.org/10.1016/j.rse.2015.06.023>.

WORLD METEOROLOGICAL ORGANIZATION (WMO). **Handbook on the Use of Satellite Data**. Geneva: WMO, 2020.

WU, Q.; LANE, C. R.; LIU, H. An automated method to delineate surface water extent from multi-temporal Landsat imagery. **Environmental Modelling & Software**, v. 104, p. 162–171, 2019.

WULDER, M. A. *et al.* Current status of Landsat program, science, and applications. **Remote Sensing of Environment**, v. 225, p. 127–147, 2019. DOI: [10.1016/j.rse.2019.02.015](https://doi.org/10.1016/j.rse.2019.02.015). Disponível em: <https://doi.org/10.1016/j.rse.2019.02.015>.

XU, H. Modification of normalised difference water index (MNDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035–3051, 2006. DOI: [10.1080/01431160600750302](https://doi.org/10.1080/01431160600750302). Disponível em: <https://doi.org/10.1080/01431160600750302>.

2 DELIMITAÇÃO DE ÁREA SUPERFICIAL DE ÁGUA DA REPRESA DO FUNIL A PARTIR DE SENSORIAMENTO REMOTO

RESUMO

O sensoriamento remoto é uma ferramenta essencial para o monitoramento de corpos hídricos, permitindo a análise eficiente e econômica de recursos naturais. Este estudo teve como objetivo delimitar a área superficial de água da Represa do Funil, localizada em Minas Gerais, Brasil, utilizando imagens dos satélites Landsat-8 e Sentinel-2A, adquiridas em setembro de 2024. Foram aplicados diferentes métodos, incluindo índices espectrais e classificação não supervisionada, para comparar a eficácia das técnicas na identificação de corpos d'água. Os índices utilizados incluíram o Normalized Difference Water Index (NDWI), o Modified NDWI (MNDWI), o Normalized Difference Vegetation Index (NDVI), o Normalized Difference Drought Index (NDDI), o Land Surface Water Index (LSWI) e o cálculo do albedo. Além disso, foi empregado o algoritmo K-means para classificação automática de pixels. Os resultados demonstraram que o MNDWI e o NDWI foram os mais precisos, delimitando áreas de 32,63 km² e 29,42 km², respectivamente, no Landsat-8, enquanto o Sentinel-2A apresentou variações devido à sua maior resolução espacial. A classificação não supervisionada identificou 31,74 km² (Landsat-8) e 116,55 km² (Sentinel-2A), indicando a influência da resolução na detecção. O estudo também destacou limitações, como interferência de nuvens, sombras e vegetação úmida, que podem afetar a precisão dos índices. Conclui-se que a combinação de MNDWI e NDWI é a mais eficaz para mapeamento de água, enquanto técnicas complementares, como classificação por K-means, podem aprimorar a análise. Os resultados contribuem para o monitoramento sustentável de reservatórios, auxiliando na gestão de recursos hídricos.

Keywords: monitoramento hídrico; índices espectrais; geotecnologias; Sentinel; Landsat.

ABSTRACT

Remote sensing is an essential tool for monitoring water bodies, enabling efficient and cost-effective analysis of natural resources. This study aimed to delimit the surface water area of the Funil Reservoir, located in Minas Gerais, Brazil, using images from the Landsat-8 and Sentinel-2A satellites, acquired in September 2024. Different methods, including spectral indices and unsupervised classification, were applied to compare the effectiveness of the techniques in identifying water bodies. The indices used included the Normalized Difference Water Index (NDWI), the Modified NDWI (MNDWI), the Normalized Difference Vegetation Index (NDVI), the Normalized Difference Drought Index (NDDI), the Land Surface Water Index (LSWI), and the calculation of albedo. In addition, the K-means algorithm was used for automatic pixel classification. The results demonstrated that MNDWI and NDWI were the most accurate, delimiting areas of 32.63 km² and 29.42 km², respectively, in Landsat-8, while Sentinel-2A presented variations due to its higher spatial resolution. The unsupervised classification identified 31.74 km² (Landsat-8) and 116.55 km² (Sentinel-2A), indicating the influence of resolution on detection. The study also highlighted limitations, such as interference from clouds, shadows and wet vegetation, which can affect the accuracy of the indices. It is concluded that the combination of MNDWI and NDWI is the most effective for water mapping, while complementary techniques, such as K-means classification, can improve the analysis. The results contribute to the sustainable monitoring of reservoirs, assisting in the management of water resources.

Keywords: water monitoring; spectral indices; geotechnologies; Sentinel; Landsat.

2.1 INTRODUÇÃO

O sensoriamento remoto tem se consolidado como uma ferramenta essencial para o monitoramento de corpos hídricos, oferecendo uma abordagem eficiente e econômica para a gestão de recursos naturais. Imagens matriciais, representadas por grades regulares de pixels que armazenam informações espectrais, têm sido amplamente utilizadas na análise e no monitoramento ambiental. Nesse contexto, o desenvolvimento de máscaras de água — especialmente para a delimitação de áreas de estudo em corpos hídricos, como a Represa do Funil — surge como uma metodologia indispensável.

A Represa do Funil, localizada em Minas Gerais, Brasil, é um reservatório de grande importância estratégica para a região, desempenhando papéis fundamentais no abastecimento de água, geração de energia e atividades recreativas. Entretanto, esse ecossistema está sujeito a pressões ambientais decorrentes de mudanças no uso do solo, poluição e alterações climáticas. A aplicação de máscaras de água em imagens matriciais permite identificar, delimitar e monitorar a extensão da superfície do reservatório correspondente à água, oferecendo suporte para análises detalhadas sobre a qualidade dos recursos hídricos disponíveis.

As máscaras de água são geradas a partir de classificações espectrais que distinguem os pixels correspondentes à água dos demais elementos da paisagem, como vegetação, solo exposto e áreas urbanas. Essa abordagem possibilita uma análise espacial precisa, destacando-se por sua capacidade de identificar alterações na cobertura hídrica e monitorar eventos críticos, como períodos de seca ou enchentes. Segundo (Lillesand, T. M.; Kiefer; Chipman, J. W., 2015), o uso de técnicas de classificação em imagens matriciais é essencial para a extração de informações específicas, como a delimitação de corpos hídricos, de forma rápida e com elevada acurácia.

2.1.1 OBJETIVOS


O objetivo deste trabalho é desenvolver e aplicar diferentes metodologias para a delimitação da feição de água da Represa do Funil. Os objetivos específicos incluem a comparação das áreas obtidas por meio dos diferentes métodos utilizados.

2.2 MATERIAL E MÉTODOS

Para a realização deste estudo, foram selecionadas uma imagem do satélite Landsat-8 e uma do Sentinel-2, ambas cobrindo a área de interesse. As imagens foram escolhidas com base no critério de proximidade temporal, ou seja, capturadas no mesmo dia ou em dias próximos, a fim de evitar variações sazonais que possam afetar o espelho d'água. Ambas as imagens foram adquiridas de seus respectivos catálogos já previamente corrigidas quanto a distorções geométricas e atmosféricas, garantindo qualidade e consistência nos dados. As datas de aquisição das imagens são 8 e 12 de setembro de 2024.

As imagens foram recortadas de acordo com a extensão do arquivo vetorial correspondente aos limites municipais. Como pode ser observado na Figura 2.1, os municípios limítrofes à Barragem do Funil selecionados foram: Lavras, Ijaci, Perdões, Ribeirão Vermelho, Bom Sucesso, Itumirim e Ibituruna.


Figura 2.1 – Região utilizada como base para o estudo. Fonte: Sentinel-2A.



2.2.1 DESCRIÇÃO DA ÁREA

A região da Barragem do Funil, localizada no Campo das Vertentes, próxima ao sul do estado de Minas Gerais, Brasil, abrange municípios limítrofes como Lavras, Ijaci, Perdões, Ribeirão Vermelho, Bom Sucesso, Itumirim e Ibituruna (Figura 2.4). Trata-se de uma área de importância estratégica, por abrigar um dos principais reservatórios da bacia do rio Grande, desempenhando funções essenciais no abastecimento público, irrigação agrícola, geração de energia hidrelétrica e controle de vazões ([Agência Nacional de Águas \(ANA\), 2023](#)).

Figura 2.2 – Mapa de localização da Represa do Funil em nível nacional.




No que se refere ao clima, a região é classificada como Cwa, segundo o sistema de Köppen-Geiger, caracterizando-se por verões quentes e chuvosos, com temperaturas médias acima de 22°C e precipitação concentrada entre os meses de outubro e março, e por invernos secos e amenos, com temperaturas médias entre 14°C e 18°C ([Alvares *et al.*, 2013](#)). A precipitação média anual situa-se entre 1.400 e 1.600 mm, com variações sazonais influenciadas por sistemas frontais e convectivos, características que impactam diretamente a dinâmica hídrica do reservatório ([Instituto Nacional de Meteorologia \(INMET\), 2023](#)).

Do ponto de vista geomorfológico, a área insere-se no Planalto Atlântico, apresentando relevo que varia de suavemente ondulado a montanhoso, com altitudes entre 800 e 1.200 me-

Figura 2.3 – Mapa de localização da Represa do Funil em nível estadual.

Localização da Região da Represa do Funil em Minas Gerais


Área de estudo destacada em azul



Fonte: IBGE/Geobr 2024

tros ([Instituto Brasileiro de Geografia e Estatística \(IBGE\), 2019](#)). A cobertura vegetal original consistia predominantemente de Mata Atlântica e cerrado; contudo, atualmente, a região apresenta extensas áreas de cultivo agrícola, especialmente de café, além de pastagens ([MapBio-mas, 2022](#)). Essa transição entre áreas naturais e antropizadas torna a região particularmente relevante para estudos agrícolas e ambientais, pois permite avaliar os impactos das atividades humanas sobre os recursos hídricos.

Figura 2.4 – Mapa de localização da Represa do Funil e municípios vizinhos.



2.2.2 DEFINIÇÃO DA ÁREA

O processo de delimitação de um polígono de um arquivo matricial e a criação de uma máscara com base no tamanho de um arquivo vetorial são etapas fundamentais em análises geoespaciais. Esse procedimento é utilizado em estudos de sensoriamento remoto e Sistemas de Informação Geográfica (SIG), permitindo que a análise se concentre em áreas de interesse específicas, otimizando a eficiência do processamento e a clareza dos resultados. O mapa com o contorno dos municípios foi construído a partir de dados obtidos do Instituto Brasileiro de Geografia e Estatística (IBGE). Esses dados estão com o Coordinate Reference System (CRS) em Sistema de Referência Geocêntrico para as Américas 2000 (SIRGAS 2000). Foram então transformados para World Geodetic System 1984 (WGS84), que é o mesmo sistema de referência das imagens de satélite.

Para a data referente ao mês de setembro de 2024, o sensor Landsat 8 possui 6 imagens. O Landsat 8 tem uma revisita de 16 dias, mas a área de interesse da represa do Funil está no limite entre duas órbitas adjacentes, então são necessárias duas cenas por data, geralmente com ângulos de visada diferentes. As imagens disponíveis do Landsat 8 para o mês de setembro de 2024 estão descritas na Tabela 2.1.

Tabela 2.1 – Imagens Landsat 8 disponíveis para a área de estudo em setembro de 2024

Sensor	Data de Aquisição	Quantidade
Landsat 8	08/09/2024	2
Landsat 8	15/09/2024	2
Landsat 8	24/09/2024	2

Já as imagens do sensor Sentinel-2A encontram-se disponíveis em 9 imagens no mês de setembro de 2024 como descrito na Tabela 2.2. O Sentinel-2A tem revisita de 5 dias, mas sua área está coberta por 3 tiles diferentes. A imagem sentinel 2A utilizada foi do dia 12 de setembro de 2019. O Sentinel-2A divide a Terra em uma grade de células chamadas "tiles" ou "granules", cada uma identificada por um código único no formato TXXYYY, onde:

- T = Indica que é um tile.
- XX = Faixa longitudinal (ex.: 23).
- YYY = Faixa latitudinal (ex.: KPU, KQV).

Tabela 2.2 – Imagens Sentinel-2A disponíveis para a área de estudo em setembro de 2024

Sensor	Data de Aquisição	Quantidade
Sentinel-2A	02/09/2024	3
Sentinel-2A	12/09/2024	3
Sentinel-2A	22/09/2024	3

Após carregar os dados matriciais, as imagens de satélite Landsat 8 e Sentinel-2A e os dados vetoriais que delimitam a área de interesse, e verificar que ambos os arquivos estão no mesmo sistema de coordenadas, foi desenvolvida a máscara. A máscara é derivada da geometria do arquivo vetorial. Isso significa que apenas os pixels dos dados matriciais que intersectam a geometria do shapefile são mantidos no produto final. A máscara atua como um filtro espacial, transformando áreas fora do arquivo vetorial em valores nulos ou ignorados na análise. O recorte é aplicado utilizando os pacotes de programação da linguagem R *raster* e *sf*. Esse procedimento é essencial para delimitar os dados de uma imagem matricial a uma área específica, definida por um vetor ou outras geometrias vetoriais (Hijmans, 2019; Pebesma, 2018).

As imagens utilizadas neste estudo foram obtidas por meio da plataforma Google Earth Engine (GEE) (Gorelick *et al.*, 2017), que integra dados de satélites como Landsat 8 (disponibilizados pelo USGS Earth Explorer) e Sentinel-2A (distribuídos pelo Copernicus Open Access Hub). O processamento foi realizado em JavaScript (JS), seguindo as etapas abaixo:

- **Carregamento da área de estudo:** Delimitação da região do Funil, municípios vizinhos em formato vetorial.
- **Filtragem das imagens:** Seleção de cenas do Landsat 8 para setembro/2024, com prioridade para menor cobertura de nuvens.
- **Correção radiométrica:** Ajuste das bandas espectrais (SR_B4, SR_B3, SR_B2 para composição RGB) conforme fatores de calibração.

```

1 // 1. Carregar area de estudo
2 var funil = ee.FeatureCollection("projects/ee-represafunil/assets/
   funil");
3 Map.centerObject(funil, 10);
4
5 // 2. Filtrar imagens Landsat 8 (Set/2024)
6 var colecaoL8 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
7   .filterBounds(funil)
8   .filterDate('2024-09-01', '2024-09-30')
9   .sort('CLOUD_COVER');
10
11 // 3. Selecionar imagem com menor cobertura de nuvens
12 var melhorImagem = colecaoL8.first();
13
14 // 4. Aplicar correcao radiometrica e exportar
15 var corrigirBandas = function(image) {
16   var optical = image.select(['SR_B4', 'SR_B3', 'SR_B2']) // RGB
17     .multiply(0.0000275).add(-0.2);
18   return optical.clip(funil);
19 };
20
21 var imagemProcessada = corrigirBandas(melhorImagem);

```

```
22 Map.addLayer(imagemProcessada, {min: 0, max: 0.3}, 'Landsat RGB');
```

Código 2.1 – Código JS para obtenção de imagens Landsat 8 no GEE para a área do Funil.

As imagens do Sentinel-2A, obtidas através do Copernicus Open Access Hub, foram processadas no Google Earth Engine (GEE) para complementar a análise. O fluxo de trabalho consistiu em:

- **Seleção da área de interesse:** Delimitação da região do Funil utilizando o shapefile georreferenciado.
- **Filtragem temporal e espacial:** Coleta de cenas do período de setembro/2024 com recorte para a área de estudo.
- **Controle de qualidade:** Seleção das imagens com menor cobertura de nuvens
- **Pré-processamento:** Aplicação de correção atmosférica utilizando o algoritmo `sen2cor` e extração das bandas espectrais (B4, B3 e B2 para composição RGB).

```
1 // 1. Carregar area de estudo
2 var funil = ee.FeatureCollection("projects/ee-represafunil/assets/
   funil");
3 Map.centerObject(funil, 10);
4
5 // 2. Filtrar imagens Sentinel-2A (Set/2024)
6 var colecaoS2 = ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
7   .filterBounds(funil)
8   .filterDate('2024-09-01', '2024-09-30')
9   .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 20))
10  .sort('CLOUDY_PIXEL_PERCENTAGE');
11
12 // 3. Selecionar imagem mais livre de nuvens
13 var melhorImagem = colecaoS2.first();
14
15 // 4. Processar bandas RGB
16 var imagemRGB = melhorImagem.select(['B4', 'B3', 'B2']) // RGB
17   .clip(funil);
```


```

18
19 // 5. Visualizacao
20 Map.addLayer(imagemRGB, {min: 500, max: 3000, gamma: 1.2}, 'Sentinel
    -2 RGB');

```

Código 2.2 – Código JS para obtenção de imagens Landsat 8 no GEE para a área do Funil

Figura 2.5 – Imagens Sentinel 2A e Landsat 8 selecionadas



2.2.3 MÉTODOS EMPIRICOS

Com as imagens devidamente carregadas, aplicamos basicamente dois métodos para delimitação da feição de água da Represa do Funil: Métodos empíricos, a partir de índices espectrais provenientes de aritmética de bandas, e Métodos de classificação supervisionada.

Os índices Normalized Difference Water Index (NDWI) e Normalized Difference Vegetation Index (NDVI) foram utilizados para identificar as áreas da imagem cobertas por água. Tanto o NDWI quanto o NDVI foram empregados para discriminar áreas de água e vegetação na imagem. O NDWI é um indicador espectral que explora a forte absorção de água nas bandas do infravermelho próximo (NIR) em contraste com a reflectância na banda do verde,

sendo particularmente eficaz para mapeamento de corpos d'água superficiais. Já o NDVI utiliza a diferença entre as reflectâncias no infravermelho próximo e no vermelho para quantificar a densidade e vigor da vegetação, servindo como ferramenta complementar para distinguir entre corpos d'água e áreas vegetadas.

Também foram utilizados o Modified Normalized Difference Water Index (MNDWI), um índice modificado para detecção mais precisa de corpos d'água, especialmente em áreas urbanas, reduzindo falsos positivos causados por solo nu ou vegetação (Xu, 2006), e o Normalized Difference Water Index 2 (NDWI2), uma variante do NDWI que emprega o infravermelho médio (MIR) em vez do NIR, melhorando a discriminação entre água e vegetação úmida (Rogers; Mueller-Dombois, 1996).

Ambos os índices são amplamente utilizados no sensoriamento remoto para analisar a cobertura vegetal e a presença de corpos d'água. O pacote *RStoolbox* no R é uma ferramenta versátil para o processamento de dados matriciais, incluindo o cálculo de índices como NDWI, NDVI, MNDWI e NDWI2. O pacote pode processar imagens de diversos satélites, como Landsat 8 e Sentinel-2. A função `spectralIndices` do *RStoolbox* suporta múltiplos índices simultaneamente, simplificando o fluxo de trabalho (Leutner; Horning; Team, 2021).

O NDWI é dado pela seguinte formula (McFeeters, 1996):

$$NDWI = \frac{\rho_{Green} - \rho_{NIR}}{\rho_{Green} + \rho_{NIR}} \quad (2.1)$$

O NDVI é dado pela seguinte formula (Rouse *et al.*, 1974):

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (2.2)$$

O MNDWI é dado pela seguinte formula (Xu, 2006):

$$MNDWI = \frac{\rho_{Green} - \rho_{SWIR1}}{\rho_{Green} + \rho_{SWIR1}} \quad (2.3)$$

O NDWI2 é dado pela seguinte formula (Rogers; Mueller-Dombois, 1996).

$$NDWI2 = \frac{\rho_{Green} - \rho_{MIR}}{\rho_{Green} + \rho_{MIR}} \quad (2.4)$$

Os índices aplicados indicam valores normalizados, que são resultados de um processo matemático que visa transformar os dados de reflectância das imagens de satélite em um valor dentro de uma escala padronizada, variando entre -1 e +1. Este processo de normalização é essencial para facilitar a comparação entre diferentes tipos de cobertura do solo (como água, vegetação e solo exposto) e para destacar os elementos de interesse de forma mais eficaz. Os índices foram obtidos utilizando a função `Spectral Índices` do pacote *RStoolbox*.

```

1 # Carregamento de pacotes
2 library(terra)      # Dados raster
3 library(RStoolbox)  # Calculo de indices espectrais
4
5 # Leitura da imagem Landsat 8
6 lsat <- rast("/caminho/L8_Funil_20240924.tif")
7
8 # Nomear as bandas conforme especificacao Landsat 8
9 names(lsat) <- c('coastal', 'blue', 'green', 'red', 'nir',
10                 'swir2', 'swir3', 'swir1', 'tir1', 'tir2')
11
12 # Calculo dos indices:
13 # NDVI = (NIR-Red)/(NIR+Red) [Saude vegetacao]
14 # MNDWI = (Green-SWIR1)/(Green+SWIR1) [Agua modificado]
15 # NDWI = (Green-NIR)/(Green+NIR) [Agua original]
16 # NDWI2 = (Green-SWIR2)/(Green+SWIR2) [Agua alternativo]
17 si <- spectralIndices(lsat,
18                       blue = 'blue',
19                       green = "green",
20                       red = "red",
21                       nir = "nir",
22                       swir1 = "swir1",
23                       swir2 = "swir2",
24                       indices = c("NDVI", "MNDWI", "NDWI", "NDWI2"))
25
26 # Visualizar os resultados
27 plot(si, col = hcl.colors(100, "Spectral"))

```

Código 2.3 – Código R para cálculo de índices espectrais utilizando o pacote RStoolbox

A partir da aplicação dos índices iniciais podemos trabalhar com Normalized Drought Difference Index (NDDI), que é um índice espectral utilizado para monitorar condições de seca, combinando informações do NDVI e NDWI sua formula é dada por (Gu *et al.*, 2007):

$$NDDI = \frac{NDVI - NDWI}{NDVI + NDWI} \quad (2.5)$$

O NDDI varia entre 0 e 2, onde valores mais altos indicam maior estresse hídrico. Esse índice é útil para identificar áreas com vegetação sob seca, uma vez que a redução no conteúdo de água foliar e no vigor da vegetação é capturada pela diferença entre NDVI e NDWI.

O Land Surface Water Index (LSWI) é um índice sensível ao conteúdo de água na vegetação e no solo, utilizando bandas do infravermelho próximo (NIR) e do infravermelho de onda curta (SWIR). O LSWI varia entre -1 e 1, com valores mais altos indicando maior umidade. É amplamente utilizado em estudos de dinâmica de inundações, umidade do solo e monitoramento agrícola. Sua fórmula é dada por (Xiao *et al.*, 2002):

$$LSWI = \frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}} \quad (2.6)$$

```

1 # Funcao Base: .normalized_index
2 .normalized_index <- function(x1, x2) {
3   return((x1-x2)/(x1+x2))
4 }
5 # Funcao nddi: Calculo do Indice de Seca
6 nddi <- function(ndvi, ndwi) {
7   result <- .normalized_index(ndvi, ndwi)
8   result[is.infinite(result)] <- NA
9   result[result < 0] <- 0
10  result[result > 2] <- 2
11  return(result)
12 }
13
14 # Aplicacao do NDDI
15 nddi_lsar <- nddi(si$NDVI, si$NDWI)
16
17 # Funcao lswi: Calculo do Indice de Agua Superficial
18 lswi <- function(nir, swir3) {
19   result <- .normalized_index(nir, swir3)
20   result[is.infinite(result)] <- NA
21   result[result < -1] <- -1

```

```

22   result[result >1] <- 1
23   return(result)
24 }
25
26 # Aplicacao do LSWI
27 lswi_lsatsat<- lswi(lsatsat$ nir, lsatsat$swir3)

```

Código 2.4 – Código R para cálculo de índices NDDI e LSWI

Ainda dentro dos métodos empíricos, o albedo é uma medida da refletância, ou seja, da capacidade de uma superfície refletir a radiação solar incidente. No contexto de sensoriamento remoto, o albedo de superfícies naturais varia de acordo com suas características físicas, sendo um parâmetro valioso para identificar diferentes tipos de cobertura terrestre. Em particular, o albedo apresenta diferenças significativas entre corpos d'água e superfícies terrestres, tornando-se uma ferramenta eficaz para a geração de máscaras de água. Foi criada uma função para calcular o albedo utilizando uma combinação linear das reflectâncias de múltiplas bandas dos sensores, em que cada banda contribui com um peso específico, determinado por estudos de sensoriamento remoto (Liang, 2001).

```

1 #Funcao para calculo do albedo
2 albedoLandsat <- function(blue, green, red, nir, swir2, swir3) {
3   return(0.293 * blue + 0.274 * green + 0.233 * red +
4         0.156 * nir + 0.333 * swir2 + 0.011 * swir3)
5 }
6
7 #Aplicacao do albedo
8 albedo <- albedoLandsat(lsatsat$blue, lsatsat$green, lsatsat$red,
9                        lsatsat$nir, lsatsat$swir2, lsatsat$swir3)

```

Código 2.5 – Código R para cálculo do albedo

A partir do albedo calculado foi desenvolvida a função water para detecção de água nas imagens de satélite. Esta função tem como objetivo identificar pixels de água em imagens de satélite através da combinação de dois índices: NDVI e albedo.

A função utiliza duas condições principais para identificar pixels de água em imagens de satélite. Primeiro, considera pixels com valores de NDVI abaixo de 0,1, que geralmente

representam água ou áreas sem vegetação. Segundo, analisa pixels com albedo abaixo de 0,1, que normalmente correspondem a superfícies escuras como corpos d'água.

A combinação dessas condições é feita através do operador lógico & (AND), que garante que apenas os pixels que satisfaçam ambas as condições simultaneamente serão classificados como água.

O resultado final é um vetor lógico composto por valores TRUE/FALSE, onde TRUE indica os pixels que atendem aos critérios para serem considerados água, enquanto FALSE representa todos os outros casos que não cumprem as duas condições estabelecidas. Essa abordagem permite uma identificação básica de massas d'água a partir de dados de sensoriamento remoto.

```

1
2 #Funcao water
3 water <- function (ndvi, albedo) {
4   return( (ndvi < 0.1) & (albedo <- 0.1))
5 }
6
7 # Aplicacao da funcao water
8 water_lsats <- water(si$NDVI, albedo)

```

Código 2.6 – Código R para cálculo da Função Water

Tabela 2.3 – Métodos empíricos aplicados aos sensores Landsat 8 e Sentinel-2A

Método Empírico	Sensor
NDVI (Normalized Difference Vegetation Index)	Landsat 8, Sentinel-2A
MNDWI (Modified Normalized Difference Water Index)	Landsat 8, Sentinel-2A
NDWI (Normalized Difference Water Index)	Landsat 8, Sentinel-2A
NDWI2 (Normalized Difference Water Index 2)	Landsat 8, Sentinel-2A
NDDI (Normalized Difference Drought Index)	Landsat 8, Sentinel-2A
LSWI (Land Surface Water Index)	Landsat 8, Sentinel-2A
Albedo	Landsat 8, Sentinel-2A
Water (Detecção de Água)	Landsat 8, Sentinel-2A

2.2.4 ALGORITMO K-MEANS

A utilização do algoritmo K-médias (K-means) por meio do pacote RStoolbox no ambiente R para identificar corpos d'água em uma imagem Landsat 8 e Sentinel 2A é também uma forma de classificação não supervisionada. O método permite a segmentação automática de pixels com assinaturas espectrais semelhantes, sendo particularmente útil em análises onde amostras de referência são escassas (Congalton; Green, 2009).

O processamento iniciou-se com o carregamento da imagem raster utilizando a função `rast()` do pacote `terra`. Para garantir a qualidade dos dados, pixels inválidos (NA) foram removidos por meio de uma máscara lógica. A classificação não supervisionada foi executada com a função `unsuperClass()`, definindo 4 classes como parâmetro inicial. O algoritmo K-médias agrupou os pixels com base na similaridade espectral. A saída foi visualizada com `ggR()`, atribuindo cores intuitivas às classes (azul para água, verde para vegetação, amarelo e marrom para solos) (Müller *et al.*, 2024).

A classe de água (identificada como classe 4) foi isolada mediante uma máscara binária, e sua extensão foi quantificada em hectares. Para isso, a imagem classificada foi reprojeta para o sistema UTM (EPSG:32723), permitindo o cálculo de áreas em unidades métricas (Lillesand, T.; Kiefer; Chipman, J., 2015). A área ocupada pela água foi derivada multiplicando a contagem de pixels pela resolução espacial ($30\text{ m} \times 30\text{ m} = 900\text{ m}^2$ por pixel) e convertendo para hectares ($1\text{ ha} = 10.000\text{ m}^2$).

```

1
2 # Classificacao Nao Supervisionada RStollBox
3 library(terra)
4 library(ggplot2)
5 library(RStoolbox)
6
7 lsat <- rast("/home/L8_Funil_20240924.tif")
8 names(lsat)
9
10 # Mascara de pixels validos (remove linhas completas com NA)
11 lsat_clean <- mask(lsat, !is.na(sum(lsat)))
12
13 # Classificacao nao supervisionada em 4 classes
14 uc <- unsuperClass(lsat_clean, nClasses = 4)

```

```

15
16 # Visualizacao
17 ggR(uc$map, geom_raster = TRUE, forceCat = TRUE) +
18   scale_fill_manual(values = c("green", "yellow", "brown", "blue"))
19
20 # Reprojetar a imagem classificada para UTM
21 uc_proj <- project(uc$map, "EPSG:32723") # UTM zona 23 Sul
22
23 # Frequencia por classe
24 freq_table <- freq(uc_proj)
25
26 # Calcular area de um pixel
27 area_pix_m2 <- prod(res(uc_proj)) # ex: 30 x 30 = 900
28
29 # Calcular area por classe
30 freq_table$area_ha <- (freq_table$count * area_pix_m2) / 10000
31 print(freq_table)

```

Código 2.7 – Código R para Classificação não Supervisionada utilizando o RStoolbox

2.2.5 CÁLCULO DE ÁREA

Para a delimitação da área seguiu uma abordagem em quatro etapas principais: limiarização, vetorização e pós-processamento, cálculo de áreas e saída dos resultados. O processamento inicia com a limiarização dos índices anteriormente aplicados como o NDVI, NDWI onde a função *classify()* do pacote *terra* é aplicada para segmentar a imagem. Nesta etapa, valores dos índices abaixo ou acima do valor observado são considerados como não água e convertidos para NA, enquanto valores iguais ou superiores aos observados como água (Hijmans, 2023).

O cálculo da área é realizado pela função *expand()* do pacote *terra*, que garante cálculos precisos independentemente do sistema de referência espacial utilizado. Quando os dados estão em coordenadas geográficas (latitude/longitude), a função automaticamente converte para um sistema métrico intermediário, assegurando que os cálculos de área levem em consideração a curvatura da Terra e mantenham a precisão métrica. A função permite o cálculo simultâneo das áreas em diferentes unidades: hectares (*unit="ha"*), que são mais adequados para análises

agronômicas e florestais, e quilômetros quadrados (*unit="km"*), mais úteis para estudos em escala regional. Para garantir consistência e padronização nos relatórios e análises, todos os resultados são apresentados com arredondamento para duas casas decimais através da função *round(2)*, o que facilita a comparação entre diferentes áreas estudadas e assegura uniformidade na apresentação dos dados. Essa abordagem de cálculo garante que as estimativas de área sejam mais precisas e confiáveis.

```

1 library(terra)
2 # 1. Aplicar limiar ao NDVI
3 ndvi_bin <- classify(
4   si$NDVI,
5   matrix(c(-Inf, 0.2, NA, 0.2, Inf, 1), ncol = 3, byrow = TRUE)
6 )
7
8 # 2. Vetorizacao e pos-processamento do NDVI
9 ndvi_poligonos <- as.polygons(ndvi_bin) %>%
10   aggregate() %>%
11   subset(expanse(.) > 450) %>% # Filtro de area mnima
12   buffer(15) %>%             # Suavizacao
13   buffer(-10)                 # Refinamento
14
15 # 2.5 Calculo da area total detectada (em hectares e km2)
16 area_ha <- expanse(ndvi_poligonos, unit="ha") %>% round(2)
17 area_km2 <- expanse(ndvi_poligonos, unit="km") %>% round(2) # 'unit
18   ="km"' retorna km2
19
20 cat("Area total de Agua detectada:\n")
21 cat(area_ha, "hectares\n")
22 cat(area_km2, "km2\n")

```

Código 2.8 – Código R, exemplo cálculo de área função *expanse()* pacote *terra*


2.3 RESULTADOS

Os resultados foram divididos em Métodos Empírico com os sensores Landsat8 e Sentinel 2A, e classificação não supervisionada com os mesmos respectivos sensores. A feição de água a partir dos critérios adotados e o cálculo da área.

2.3.1 MÉTODOS EMPIRICOS LANDSAT 8

A partir dos métodos empíricos diretos, é possível visualmente identificar a superfície de água. Os histogramas para cada índice ajudam a identificar qual valores mais recorrentes dos índices aplicados.

Figura 2.6 – Índice Espectrais aplicados à região da Represa do Funil.



A integração de índices calculados a priori com variáveis trouxe novos resultados para a classificação empírica, gerando informações a partir dos índices que já possuíam certo nível de identificação de superfície de água.

Comparar diferentes métodos e abordagens para obtenção de máscara de água na represa do funil. O uso combinado de índices espectrais e técnicas de classificação supervisionada é uma abordagem robusta para a extração de máscaras de água, possibilitando essa comparação entre as técnicas. Espera-se que os resultados obtidos com essa metodologia tenham o potencial de subsidiar iniciativas monitoramento de recursos hídricos via Sensoriamento Remoto.

Figura 2.7 – Histograma dos índice aplicados a região da Represa do Funil.




Figura 2.8 – Limiar de água da região da Represa do Funil a partir do Landsat 8




Tabela 2.4 – Áreas de água detectadas por diferentes índices espectrais

Índice	Área (hectares)	Área (km ²)	Sensor
NDVI	205.187,3	2.051,87	Landsat 8
MNDWI	3.263,27	32,63	Landsat 8
NDWI	2.941,58	29,42	Landsat 8
NDWI2	3.195,03	31,95	Landsat 8

Figura 2.9 – Índices NDDI, LSWI, albedo, water aplicados a região da Represa do Funil no Landsat 8




Figura 2.10 – Histograma dos índices WSI aplicados a região da Represa do Funil no Landsat 8




Figura 2.11 – Delimitação dos cursos d'água a partir dos Índices NDDI, LSWI, albedo, water no Landsat

8




Tabela 2.5 – Áreas de água detectadas por diferentes índices espectrais no Landsat 8

Índice	Área (ha)	Área (km²)	Sensor
NDDI	177.594,50	1.775,95	Landsat 8
LSWI	38.008,47	380,08	Landsat 8
Albedo	52.460,43	524,60	Landsat 8
Water	3.668,16	36,68	Landsat 8

2.3.2 MÉTODOS EMPIRICOS SENTINEL 2A

Figura 2.12 – Índice espectrais aplicados à região da Represa do Funil Sentinel 2A.




Figura 2.13 – Histograma dos índice aplicados a região da Represa do Funil Sentinel 2A.




Figura 2.14 – Limiar de água da região da Represa do Funil Sentinel 2A.




Tabela 2.6 – Áreas de água detectadas por diferentes índices espectrais Sentinel 2A

Índice	Área (hectares)	Área (km ²)	Sensor
NDVI	1.351,46	13,5146	Sentinel 2A
MNDWI	3.508,58	35,0858	Sentinel 2A
NDWI	3.129,16	31,2916	Sentinel 2A
NDWI2	220,10	2,201	Sentinel 2A

Figura 2.15 – Índices aplicados a Represa do Funil Sentinel 2A




Figura 2.16 – Histograma dos Índices aplicados a Represa do Funil Sentinel 2A




Figura 2.17 – Índices aplicados a Represa do Funil, Sentinel 2A




Tabela 2.7 – Resultados dos índices espectrais calculados (Sentinel-2)

Índice	Área (ha)	Área (km²)	Sensor
NDDI	224.372,28	2.243,72	Sentinel-2A
LSWI	224.632,66	2.246,33	Sentinel-2A
Albedo	222.737,48	2.227,37	Sentinel-2A
Water	36.788,50	367,89	Sentinel-2A

2.3.3 CLASSIFICAÇÃO NÃO SUPERVISIONADA RStoolbox

Figura 2.18 – Classificação Não Supervisionada RStollBox, Landsat 8




Figura 2.19 – Limiar de água a partir da Classificação não Supervisionada RStollBox, Landsat 8




Figura 2.20 – Classificação Não Supervisionada RStollBox, Sentinel2 A




Figura 2.21 – Limiar de água a partir da Classificação Não Supervisionada RStollBox, Sentinel2 A




Tabela 2.8 – Resultados da classificação de água em imagens Landsat 8 e Sentinel-2A

Sensor	Classe	Área (ha)	Área (km ²)
Landsat 8	Água	3.173,58	31,74
Sentinel-2A	Água	11.654,52	116,55

2.4 DISCUSSÃO DOS RESULTADOS

Os resultados demonstraram que o NDWI (Normalized Difference Water Index) e o MNDWI (Modified Normalized Difference Water Index) foram os mais eficientes na identificação de corpos d'água, apresentando valores consistentes com a área esperada da Represa do Funil. Enquanto o NDWI original (McFeeters, 1996) mostrou uma área de 29,42 km², o MNDWI (Xu, 2006) apresentou 32,63 km², indicando uma melhor discriminação entre água e vegetação adjacente devido à inclusão da banda SWIR1, que reduz falsos positivos causados por solo úmido ou sombras.

O NDWI2, que utiliza a banda SWIR2, apresentou resultados divergentes entre os sensores: no Landsat-8, detectou 31,95 km², enquanto no Sentinel-2A, apenas 2,20 km². Essa discrepância pode estar relacionada à diferença nas bandas espectrais e resoluções espaciais entre os sensores, reforçando a necessidade de calibração específica para cada plataforma.

O NDVI, embora não seja um índice projetado para detecção de água, foi incluído como referência e, como esperado, apresentou valores elevados (2.051,87 km² no Landsat-8 e 13,51 km² no Sentinel-2A), confirmando sua inadequação para esse propósito, uma vez que responde principalmente à presença de vegetação.

O NDDI (Normalized Difference Drought Index) mostrou-se útil para identificar áreas sob estresse hídrico, mas sua aplicação para delimitação de água foi menos precisa, resultando em superestimativas (1.775,95 km² no Landsat-8 e 2.243,72 km² no Sentinel-2A).

O LSWI (Land Surface Water Index) apresentou resultados intermediários (380,08 km² no Landsat-8 e 2.246,33 km² no Sentinel-2A), sendo mais sensível a áreas úmidas e vegetação inundada, o que pode explicar sua maior variabilidade.

A abordagem baseada em albedo demonstrou potencial, mas também superestimou a área de água (524,60 km² no Landsat-8 e 2.227,37 km² no Sentinel-2A), possivelmente devido à influência de superfícies escuras não relacionadas a corpos hídricos.

A função water, que combina NDVI e albedo, foi a mais precisa entre os métodos empíricos avançados, delimitando 36,68 km² no Landsat-8 e 367,89 km² no Sentinel-2A. Essa diferença significativa entre os sensores sugere que a função pode requerer ajustes de limiares específicos para cada plataforma.

2.4.1 COMPARAÇÃO ENTRE LANDSAT-8 E SENTINEL-2A

A análise comparativa entre os dois sensores revelou diferenças marcantes nas áreas detectadas, mesmo quando aplicados os mesmos índices espectrais. Enquanto o Landsat-8 apresentou resultados mais consistentes com a área conhecida da represa (aproximadamente 30–35 km²), o Sentinel-2A mostrou maior variabilidade, especialmente nos índices NDDI, LSWI e albedo. Essa divergência pode ser atribuída a alguns fatores como a resolução espacial diferente entre os sensores que desempenha um papel crucial. O Sentinel-2A, com sua maior resolução (10 m nas bandas ópticas e 30 m do Landsat-8), é capaz de captar mais detalhes da superfície, o que pode incluir falsos positivos, como pequenas áreas de sombra ou solo úmido que são erroneamente são classificadas como água.

As bandas espectrais distintas, principalmente nas regiões do infravermelho de onda curta (SWIR), afetam diretamente índices como MNDWI e NDWI2. O Sentinel-2A possui bandas SWIR com características diferentes das do Landsat-8, o que pode alterar a resposta espectral e, conseqüentemente, a eficácia dos índices na discriminação entre água e outros alvos. Por fim, as condições atmosféricas no momento da aquisição podem influenciar a reflectância medida por cada sensor. Variações na nebulosidade, umidade atmosférica ou ângulo de iluminação solar podem levar a diferenças na detecção de água, mesmo quando as imagens são adquiridas em datas próximas.

2.4.2 LIMITAÇÕES E DESAFIOS

Apesar dos avanços metodológicos, algumas limitações devem ser consideradas. A influência de nuvens e sombras ainda é um desafio significativo, especialmente em índices baseados no infravermelho próximo (NIR) e SWIR, que podem ser confundidos com áreas de sombreamento. Isso pode limitar a aquisição de imagens em época de maior nebulosidade, ou mesmo em uma temporada de chuva. A proximidade de vegetação adjacente e áreas úmidas, como matas ciliares e zonas alagadiças, pode interferir na precisão de índices como o LSWI, que são sensíveis tanto à água quanto à vegetação com alto teor de umidade.

Outro fator relevante é a variação sazonal. Como este estudo utilizou apenas imagens de setembro de 2024, análises multitemporais seriam necessárias para avaliar a dinâmica do reservatório ao longo do ano, incluindo períodos de seca e cheia. Por último, a definição de limiares empíricos para classificação binária (água/não água) é um processo subjetivo que pode variar conforme as condições locais, exigindo calibração específica para cada área de estudo.

Essas limitações destacam a importância de combinar múltiplas abordagens, como a integração de dados de radar (SAR) para minimizar interferências atmosféricas e a validação em campo para ajustar os modelos de classificação. Futuros trabalhos podem explorar técnicas de machine learning para automatizar a seleção de limiares e melhorar a precisão na delimitação de corpos hídricos.

2.5 CONCLUSÃO

Os resultados confirmam que o MNDWI e o NDWI são os índices mais confiáveis para delimitação de água na Represa do Funil, enquanto métodos como NDDI e LSWI são mais adequados para monitoramento de umidade e estresse hídrico. Os índices combinados a outros parâmetros como foi o caso do índice water podem ser eficientes para delimitação de água nas imagens. A comparação entre Landsat-8 e Sentinel-2A evidenciou a necessidade de ajustes metodológicos específicos para cada sensor. Este estudo fornece uma base sólida para o monitoramento contínuo de reservatórios, contribuindo para a gestão sustentável de recursos hídricos.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Sistema de Informações Hidrológicas**. [S. l.: s. n.], 2023. Acesso em: 18 mai. 2025. Disponível em: <https://www.snirh.gov.br/hidroweb/>.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. DOI: [10.1127/0941-2948/2013/0507](https://doi.org/10.1127/0941-2948/2013/0507).

CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 2nd. [S. l.]: CRC Press, 2009.

GORELICK, N. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, Elsevier, 2017. DOI: [10.1016/j.rse.2017.06.031](https://doi.org/10.1016/j.rse.2017.06.031). Disponível em: <https://doi.org/10.1016/j.rse.2017.06.031>.

GU, Y. *et al.* A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, v. 34, n. 6, p. l06407, 2007. DOI: [10.1029/2006GL029127](https://doi.org/10.1029/2006GL029127).

HIJMANS, R. J. **raster: Geographic Data Analysis and Modeling**. [S. l.], 2019. R package version 3.5-21. Disponível em: <https://CRAN.R-project.org/package=raster>.

HIJMANS, R. J. **terra: Spatial Data Analysis**. [S. l.], 2023. R package version 1.7-29. Disponível em: <https://cran.r-project.org/package=terra>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual Técnico da Vegetação Brasileira**. 2. ed. Rio de Janeiro, 2019.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Banco de Dados Meteorológicos**. [S. l.: s. n.], 2023. Acesso em: 18 mai. 2025. Disponível em: <https://portal.inmet.gov.br/>.

LEUTNER, B.; HORNING, N.; TEAM, R. **RStoolbox: Tools for Remote Sensing Data Analysis**. [S. l.], 2021. Disponível em: <https://cran.r-project.org/package=RStoolbox>.

LIANG, S. Narrowband to broadband conversions of land surface albedo: Algorithms. **Remote Sensing of Environment**, v. 76, n. 2, p. 213–238, 2001. DOI: [10.1016/S0034-4257\(00\)00205-4](https://doi.org/10.1016/S0034-4257(00)00205-4). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425700002054>.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote Sensing and Image Interpretation**. 7th. [S. l.]: Wiley, 2015.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 7th. Hoboken, NJ: Wiley, 2015.

MAPBIOMAS. **Coleção 7 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil**. [S. l.: s. n.], 2022. Acesso em: 18 mai. 2025. Disponível em: <https://mapbiomas.org/>.

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. DOI: [10.1080/01431169608948714](https://doi.org/10.1080/01431169608948714).

MÜLLER, K. *et al.* RStoolbox: An R package for Remote Sensing Data Analysis. **Methods in Ecology and Evolution**, 2024. DOI: [10.1111/2041-210X.14451](https://doi.org/10.1111/2041-210X.14451).

PEBESMA, E. Simple Features for R: Standardized Support for Spatial Vector Data. **The R Journal**, v. 10, n. 1, p. 439–446, 2018. Disponível em: <https://CRAN.R-project.org/package=sf>.

ROGERS, A.; MUELLER-DOMBOIS, D. Water indices for remote sensing: Theoretical foundation and comparative analysis. **Journal of Hydrology**, v. 184, p. 3–20, 1996.

ROUSE, J. *et al.* Monitoring vegetation systems in the Great Plains with ERTS. **NASA Special Publication**, v. 351, p. 309, 1974.

XIAO, X. *et al.* Characterization of forest types in Northeastern China, using multi-temporal SPOT-4 VEGETATION sensor data. **Remote Sensing of Environment**, v. 82, n. 2-3, p. 335–348, 2002. DOI: [10.1016/S0034-4257\(02\)00051-2](https://doi.org/10.1016/S0034-4257(02)00051-2).

XU, H. Modification of normalised difference water index (MNDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035–3051, 2006. DOI: [10.1080/01431160600750302](https://doi.org/10.1080/01431160600750302). Disponível em: <https://doi.org/10.1080/01431160600750302>.

3 DELIMITAÇÃO DE ÁREA SUPERFICIAL DE ÁGUA DA REPRESA DO FUNIL A PARTIR DE SENSORIAMENTO REMOTO CLASSIFICAÇÃO SUPERVISIONADA

RESUMO

O sensoriamento remoto é uma ferramenta fundamental para o monitoramento de corpos hídricos, permitindo análises eficientes e econômicas de recursos naturais. Este estudo teve como objetivo delimitar a área superficial de água da Represa do Funil, localizada em Minas Gerais, Brasil, utilizando imagens dos satélites Landsat-8 e Sentinel-2A, adquiridas em setembro de 2024. Foram aplicados três métodos de classificação supervisionada, Random Forest (RF), MESMA (Multiple Endmember Spectral Mixture Analysis) e MaxEnt (Maximum Entropy Modeling) para comparar sua eficácia na identificação de corpos d'água. Os resultados demonstraram que o RF apresentou alta acurácia (94,5% para Landsat-8 e 93,9% para Sentinel-2A), com áreas estimadas em 47,87 km² e 48,19 km², respectivamente. O MESMA, por sua vez, mostrou maior sensibilidade a pixels mistos, resultando em áreas menores (27,84 km² para Landsat-8 e 31,31 km² para Sentinel-2A) e acurácia superior (97,9% e 95,5%). O MaxEnt destacou-se pelo excelente desempenho, com áreas de 33,99 km² (Landsat-8) e 32,88 km² (Sentinel-2A). As diferenças entre os métodos evidenciaram a influência da resolução espacial e dos critérios de classificação, sendo o Sentinel-2A mais detalhado devido à sua maior resolução (10 m). Conclui-se que a combinação de métodos pode otimizar o mapeamento, contribuindo para a gestão sustentável de reservatórios e o monitoramento hidrológico.

Palavras-chave: algoritmos de classificação; classificação supervisionada; random forest; MESMA; MaxEnt. represa do funil.

ABSTRACT

Remote sensing is a fundamental tool for monitoring water bodies, enabling efficient and cost-effective analysis of natural resources. This study aimed to delineate the surface water area of the Funil Reservoir, located in Minas Gerais, Brazil, using images from the Landsat-8 and Sentinel-2A satellites acquired in September 2024. Three supervised classification methods, Random Forest (RF), MESMA (Multiple Endmember Spectral Mixture Analysis), and MaxEnt (Maximum Entropy Modeling). Were applied to compare their effectiveness in identifying water bodies. The results showed that RF achieved high accuracy (94.5% for Landsat-8 and 93.9% for Sentinel-2A), with estimated areas of 47.87 km² and 48.19 km², respectively. MESMA demonstrated greater sensitivity to mixed pixels, resulting in smaller areas (27.84 km² for Landsat-8 and 31.31 km² for Sentinel-2A) and higher accuracy (97.9% and 95.5%). MaxEnt stood out for its excellent performance, with areas of 33.99 km² (Landsat-8) and 32.88 km² (Sentinel-2A). The differences between the methods highlighted the influence of spatial resolution and classification criteria, with Sentinel-2A providing more detailed results due to its higher resolution (10 m). The study concludes that combining these methods can optimize mapping, supporting sustainable reservoir management and hydrological monitoring.

Keywords: classification algorithms; supervised classification; random forest; MESMA; MaxEnt; Funil Reservoir.

3.1 INTRODUÇÃO

O sensoriamento remoto tem se consolidado como uma ferramenta essencial no monitoramento de corpos hídricos, oferecendo uma abordagem eficiente e econômica para a gestão de recursos naturais. Imagens matriciais, representadas por grades regulares de pixels que armazenam informações espectrais, têm sido amplamente utilizadas para análise e monitoramento ambiental. Nesse contexto, o desenvolvimento de máscaras de água, especialmente para delimitação de áreas de estudo em corpos hídricos como a Represa do Funil, surge como uma metodologia indispensável.

A Represa do Funil, localizada em Minas Gerais, Brasil, é um reservatório de grande importância estratégica para a região, desempenhando papéis fundamentais no abastecimento de água, geração de energia e recreação. Entretanto, esse ecossistema está sujeito a pressões ambientais decorrentes de mudanças no uso do solo, poluição e alterações climáticas. A aplicação de máscaras de água em imagens matriciais permite identificar, delimitar e monitorar a extensão da superfície do reservatório que corresponde à água, oferecendo suporte para análises detalhadas sobre a qualidade dos recursos hídricos disponíveis.

As máscaras de água são geradas a partir de classificações espectrais que distinguem os pixels correspondentes à água dos demais elementos da paisagem, como vegetação, solo exposto e áreas urbanas. Essa abordagem possibilita uma análise espacial precisa, destacando-se por sua capacidade de identificar alterações na cobertura hídrica e monitorar eventos críticos, como períodos de seca ou enchentes. Segundo (Lillesand; Kiefer; Chipman, 2015), o uso de técnicas de classificação em imagens matriciais é essencial para a extração de informações específicas, como a delimitação de corpos hídricos, de maneira rápida e com elevada acurácia.

3.1.1 OBJETIVOS

O objetivo deste trabalho é desenvolver uma metodologia para a delimitação da feição de água da Represa do Funil a partir de classificação supervisionada. Os objetivos específicos são comparar os valores de área encontrados utilizando os diferentes métodos.

3.1.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos são aplicar e comparar três algoritmos de classificação supervisionada para a delimitação da feição de água da Represa do Funil. Foi utilizado o método

Random Forest, o MESMA (Multiple Endmember Spectral Mixture Analysis) e o MAXENT (Maximum Entropy Modeling). Para uma avaliação abrangente dos resultados, serão quantificadas as diferenças entre os métodos através de três abordagens principais: comparação dos valores de área delimitada obtidos por cada algoritmo, aplicação de métricas de acurácia como matriz de confusão e índice Kappa para validação estatística dos resultados.


3.2 DESCRIÇÃO DA ÁREA

A região da Barragem do Funil está situada no Campo das Vertentes, no sul do estado de Minas Gerais, Brasil, abrangendo municípios limítrofes como Lavras, Ijaci, Perdões, Ribeirão Vermelho, Bom Sucesso, Itumirim e Ibituruna (Figura 3.1). Esta área possui importância estratégica por abrigar um dos principais reservatórios da bacia do rio Grande, desempenhando funções essenciais no abastecimento público, irrigação agrícola, geração de energia hidrelétrica e controle de vazões ([Agência Nacional de Águas \(ANA\), 2023](#)).

Do ponto de vista climático, a região é classificada como Cwa segundo o sistema de Köppen-Geiger, caracterizando-se por verões quentes e chuvosos, com temperaturas médias acima de 22°C e precipitação concentrada entre outubro e março, e invernos secos e amenos, com temperaturas médias entre 14°C e 18°C ([Alvares *et al.*, 2013](#)). A precipitação média anual varia entre 1.400 e 1.600 mm, com padrões sazonais influenciados por sistemas frontais e convectivos, os quais impactam diretamente a dinâmica hídrica do reservatório ([Instituto Nacional de Meteorologia \(INMET\), 2023](#)).

Geomorficamente, a área insere-se no Planalto Atlântico, apresentando relevo que varia de suavemente ondulado a montanhoso, com altitudes entre 800 e 1.200 metros ([Instituto Brasileiro de Geografia e Estatística \(IBGE\), 2019](#)). A cobertura vegetal original consistia predominantemente de Mata Atlântica e cerrado, porém atualmente a paisagem é dominada por atividades antrópicas, especialmente cultivos agrícolas de café e pastagens ([MapBiomas, 2022](#)). Esta transição entre áreas naturais e antropizadas confere à região relevância particular para estudos interdisciplinares que avaliem os impactos das atividades humanas sobre os ecossistemas aquáticos e terrestres.

Figura 3.1 – Mapa de localização da Represa do Funil e municípios adjacentes.




3.3 DESCRIÇÃO DOS MÉTODOS

Os métodos foram aplicados para os Sensores Sentinel 2A e LandSat 8. As datas de aquisição das imagens são 8 e 12 de setembro de 2024.

3.3.1 TREINAMENTO DOS DADOS

Para amostragem dos dados de treinamento utilizou-se de pontos para distinguir entre áreas de água e não-água, a coleta desses pontos se deu a partir de interpretação visual de imagens de alta resolução. Definindo a partir daí 236 pontos, sendo 118 nos pixels que representavam água e 118 nos pixels que não representavam água. Criando um arquivo com uma coluna nomeada como "presença de água", os valores 0 representavam não água e os valores 1 representavam a presença de água. Cada um desses pontos está vinculado a uma coordenada geográfica. Utilizando o CRS WGS 84.

Figura 3.2 – Dados de treinamento utilizados para a classificação supervisionada



3.3.2 RANDOM FOREST

Dentre os métodos de classificação supervisionada, o algoritmo Random Forest (RF) tem se destacado por sua capacidade e precisão para classificar variáveis altamente correlacionadas, como as bandas espectrais dos sensores multiespectrais (Breiman, 2001). O RF é um conjunto de árvores de decisão construídas sobre subconjuntos aleatórios dos dados de treino e de variáveis, realizando a votação majoritária entre as árvores para classificar cada pixel da imagem. A metodologia utiliza uma abordagem de classificação supervisionada de imagens de satélite utilizando o pacote RStoolbox no ambiente R (Müller *et al.*, 2024), com aplicação do algoritmo Random Forest para discriminação entre classes de "Água" e "Não Água" a partir de imagens de satélite.

Inicialmente, foi carregado um raster multibanda, contendo bandas espectrais de refletância de superfície. Foram utilizados dados vetoriais de pontos amostrados manualmente con-

tendo a variável de interesse "Água" e "Não Água", indicando a presença ou ausência de água. Utilizando a função `extract()` da biblioteca do pacote `terra` (Hijmans, 2023). Foram extraídos os valores espectrais de cada banda para os pontos de amostragem, resultando em uma tabela contendo os valores dos pixels correspondentes a cada ponto e sua respectiva classe (Água / Não Água).

A base de dados foi dividida em subconjuntos de treino (70%) e teste (30%) por meio da função `createDataPartition()` do pacote `caret` (Kuhn; Max, 2008). O modelo foi treinado com o algoritmo Random Forest, implementado pelo pacote `randomForest` (Liaw; Wiener, 2002) e encapsulado via `train()` do `caret`, utilizando 500 árvores e validação cruzada com 5 folds.

Esse modelo explorou as bandas espectrais visíveis, NIR e SWIR, que são reconhecidamente úteis para discriminação de alvos aquáticos, especialmente pelas diferenças de reflectância entre água e superfícies terrestres (McFeeters, 1996), (Xu, 2006). A classificação completa da imagem foi realizada com a função `superClass()` do pacote `RStoolbox`, que permite a aplicação direta do Random Forest sobre o raster multiespectral, com base nos dados vetoriais previamente definidos. A saída foi um raster temático com classes "Água" e "Não Água". A partir do mapa classificado, foi gerada uma máscara binária, onde os pixels classificados como água foram mantidos e os demais atribuídos como NA, permitindo a visualização exclusiva das áreas de interesse hídrico.

```

1 library(RStoolbox)
2 library(caret)
3 library(randomForest)
4 library(ggplot2)
5 library(terra)
6 library(sf)
7 # Carregar a imagem raster
8 lsat <- rast("/home/L8_Funil_20240924.tif")
9
10 # Mapeamento completo dos nomes
11 nomes_completos <- c(
12   "SR_B1" = "Coastal_Aerosol",
13   "SR_B2" = "Blue",
14   "SR_B3" = "Green",
15   "SR_B4" = "Red",

```

```

16   "SR_B5" = "NIR",
17   "SR_B6" = "SWIR1",
18   "SR_B7" = "SWIR2",
19   "ST_B10" = "Thermal_B10",
20   "QA_PIXEL" = "Quality_Pixel",
21   "QA_RADSAT" = "Quality_Radsat"
22 )
23
24 # Aplicar a renomeacao
25 names(lsar) <- nomes_completos
26
27 # Verificar resultado
28 names(lsar)
29
30 dados <- st_read("/home/dados_amostragem.shp")
31
32 # Extrair valores das bandas para cada ponto
33 dados_treinamento <- extract(lsar, dados, df = TRUE)
34 dados_treinamento$class <- ifelse(dados$presence == 1, "Agua", "Nao_
    Agua")
35
36 # Dividir em treino (70%) e teste (30%)
37 set.seed(123)
38 trainIndex <- createDataPartition(dados_treinamento$class, p = 0.7,
    list = FALSE)
39 treino <- dados_treinamento[trainIndex, ]
40 teste <- dados_treinamento[-trainIndex, ]
41
42 # Treinar o modelo com os nomes atualizados das bandas
43 modelo <- train(
44   class ~ Coastal_Aerosol + Blue + Green + Red + NIR + SWIR1 + SWIR2,
45     # Bandas renomeadas
46   data = treino,
47   method = "rf",

```



```

47 trControl = trainControl(method = "cv", number = 5),
48 importance = TRUE, # Para calcular importancia das variaveis
49 ntree = 500        # Numero de arvores (aumente para melhor
                    precisao)
50
51 # Visualizar importancia das variaveis
52 ggplot(varImp(modelo)) +
53   theme_minimal() +
54   labs(title = "Importancia das Bandas Espectrais",
55        x = "Importancia",
56        y = "Banda")
57
58 # Usando a funcao superClass do RStoolbox
59 mapa_classificado <- superClass(
60   lsat,
61   trainData = dados, # Objeto espacial com pontos
62   responseCol = "presence", # Nome da coluna de classes
63   model = "rf",
64   tuneLength = 3
65 )
66
67 # Mascara de agua
68 mascara_agua <- terra::classify(mapa_classificado$map,
69                                rcl = cbind(1, NA),
70                                right = FALSE)
71 plot(mascara_agua, col = "blue",
72      main = "Area de Agua - LandSat 8")
73 legend("topright", legend = "Agua", fill = "blue")

```

Código 3.1 – Código R para Classificação Supervisionada, Random Forest

3.3.3 MESMA

O método MESMA (Multiple Endmember Spectral Mixture Analysis) é uma técnica de análise espectral que permite modelar a composição de pixels em imagens de sensoriamento remoto como combinações lineares de múltiplos endmembers (Roberts, D. *et al.*, 1998).

A metodologia empregada uma abordagem sistemática para os sensores LandSat 8 e Sentinel 2, com algumas pequenas mudanças em virtude das características dos sensores. Iniciando com o pré-processamento dos dados. Primeiramente, foi realizada a preparação do ambiente computacional, configurando um diretório temporário específico para o processamento de grandes arquivos matriciais utilizando o pacote terra (Hijmans, 2023) no R. Em seguida, procedeu-se com o carregamento da imagem matricial, selecionando as bandas espectrais mais relevantes para a detecção de corpos d'água: azul (blue), verde (green), vermelho (red), infravermelho próximo (NIR) e infravermelho de onda curta (SWIR1 e SWIR2). Os valores de reflectância destas bandas foram normalizados para uma escala de 0 a 1 através da divisão por 10.000, garantindo compatibilidade com os modelos de mistura espectral.

Na etapa de definição dos endmembers, foram utilizados pontos de amostragem georreferenciados representando duas classes distintas: "Água"(identificada pelo valor 1 no campo presence) e "Não Água"(valor 0). Foram coletados previamente 118 pontos com coordenadas geográficas com pixels que representam água e 118 pontos com pixels que não representam água. Esse processo foi feito na própria imagem a partir de uma plotagem das camadas RGB onde é possível visulamente identificar os locais onde a água de represa ocupa. Para assegurar a qualidade espectral dos endmembers, aplicou-se um filtro para remoção de outliers, especificamente eliminando pontos classificados como água que apresentavam valores de reflectância no NIR superiores a 0.08, os quais poderiam indicar mistura com outras coberturas ou erro de amostragem.

A execução do algoritmo MESMA foi realizada através da função mesma do pacote RStoolbox (Müller *et al.*, 2024). Implementando o modelo de mistura espectral linear. Este processo gerou três produtos principais: uma camada contínua representando a fração de água com os valores entre 0 e 1. Uma camada equivalente para a fração de não-água, e uma camada de erro calculada através do Root Mean Square Error (RMSE), que indica a qualidade do ajuste do modelo em cada pixel.

No pós-processamento, aplicou-se classificação binária utilizando limiares de 0.90 e 0.95 sobre a camada de fração de água para gerar mapas temáticos. A validação destes resul-

tados foi conduzida através de matrizes de confusão calculadas com base em pontos de amostragem independentes, complementada pela análise da curva ROC para determinação do limiar ótimo através do método de Youden. O índice de Youden é uma métrica estatística usada para avaliar o desempenho de testes diagnósticos ou classificadores binários, especialmente quando os resultados são expressos em escalas contínuas. Realizou-se filtragem espacial para remoção de ruído, eliminando manchas com menos de 10 pixels conectados.

Finalmente, na análise quantitativa, calculou-se a área de água através da contagem de pixels classificados, convertendo este valor para hectares com base na resolução espacial da imagem, permitindo uma estimativa precisa da extensão dos corpos d'água na área de estudo. Todo este fluxo metodológico foi implementado no ambiente R, garantindo reprodutibilidade e possibilitando ajustes parametrizados em cada etapa do processamento.

```

1 # 1. Carregar pacotes
2 library(RStoolbox)
3 library(terra)
4 library(ggplot2)
5 library(sf)
6 library(dplyr)
7 library(caret)
8 library(pROC)
9
10 # 2. Carregar e preparar dados
11 # Imagem Landsat 8
12 ls8 <- rast("/home/L8_Funil_20240924.tif")
13 names(ls8) <- c("aerosol", "blue", "green", "red", "nir", "swir1", "
    swir2", "thermal", "pixel_qa", "radsat_qa")
14 # Selecionar apenas bandas ópticas de interesse
15 ls8_optical <- ls8[[c("blue", "green", "red", "nir", "swir1", "swir2"
    )]]
16 # Pontos de amostragem (shapefile)
17 dados <- st_read("/home/dados_amostragem.shp")
18
19 # 3. Preparar endmembers
20 em_values <- extract(ls8_optical, vect(dados))
21 # Juntar valores espectrais com a classe

```

```

22 em_mesma <- cbind(em_values[, -1], class = ifelse(dados$presence ==
    1, "Agua", "Nao_Agua"))
23 em_mesma <- as.data.frame(em_mesma)
24
25 # 4. Remover outliers (NIR > 0.1 para pontos de agua)
26 em_mesma_filtrado <- em_mesma %>%
27   filter(!(class == "Agua" & nir > 0.1))
28 # Log de remocao
29 outliers_agua <- em_mesma %>% filter(class == "Agua" & nir > 0.1)
30 cat("Removidos", nrow(outliers_agua), "pontos de agua com NIR > 0.1\n
    ")
31
32 # 5. Executar MESMA
33 set.seed(123)
34 mesma_result <- mesma(img = ls8_optical, em = em_mesma_filtrado)
35 # Separar camadas resultantes
36 water_fraction <- mesma_result[["Agua"]]
37 non_water_fraction <- mesma_result[["Nao_Agua"]]
38 error_layer <- mesma_result[["RMSE"]]
39
40 # 6. Visualizar resultados fracionarios
41 plot(water_fraction, main = "Limiar de Agua - Landsat 8", col = hcl.
    colors(100, "Blues"))

```

Código 3.2 – Código R para Classificação Supevisionada, MESMA

3.3.4 MAXENT

O estudo adotou uma abordagem de classificação supervisionada utilizando o algoritmo de Máxima Entropia (MaxEnt) para mapeamento de corpos d'água na represa Funil, com base em imagens do satélite Landsat8 e Sentinel-2. A metodologia compreendeu quatro etapas principais: preparação dos dados, processamento das imagens, classificação propriamente dita e análise dos resultados.

Na fase inicial de preparação, foram carregados os dados vetoriais da área de estudo e duas bases de pontos de referência, que são pontos nas imagens de satélites com as coordenadas

geográficas. Uma contendo amostras de água e outra de áreas sem água, coletadas por interpretação visual das imagens de alta resolução. Estes pontos receberam atributos binários (1 para água, 0 para não-água) e foram combinados para formar o conjunto de dados de treinamento (Phillips; Anderson; Schapire, 2006).

Para o processamento das imagens, selecionou-se um conjunto de cenas Landsat e Sentinel-2 do ano de 2024 com baixa cobertura de nuvens ($< 20\%$). Da mesma maneira que utilizadas no métodos empíricos. Estas imagens foram convertidas para valores de reflectância de superfície (aplicando o fator de escala 0.0001) e colocadas em um mosaico para cobrir toda a área de interesse. Foram então calculados dois índices espectrais críticos para detecção de água: o NDWI e o MNDWI.

O algoritmo MaxEnt foi treinado utilizando sete variáveis preditoras: cinco bandas espectrais originais (azul, verde, vermelho, NIR e SWIR) mais os dois índices calculados (NDWI e MNDWI). O classificador estimou a probabilidade de ocorrência de água para cada pixel da imagem, gerando um mapa contínuo de probabilidades variando entre 0 (nenhuma probabilidade) e 1 (certeza absoluta). Para realização desse processo utilizou-se a linguagem R como no código descrito.

```

1 library(terra)
2 library(sf)
3 library(maxnet)
4 library(tidyr)
5 library(dplyr)
6
7 # 1. Dados agua e nao agua
8 dados <- st_read("/home/dados_amostragem.shp")
9
10 # 2. Imagem raster
11 ls8 <- rast("/home/L8_Funil_20240924.tif")
12 names(ls8) <- c("aerosol", "blue", "green", "red", "nir", "swir1", "
    swir2", "thermal", "pixel_qa", "radsat_qa")
13 # Selecionar apenas bandas opticas
14 ls8 <- ls8[[c("blue", "green", "red", "nir", "swir1", "swir2")]]
15
16 # 3. Calcular NDWI e MNDWI

```

```

17 ndwi <- (ls8[["green"]] - ls8[["nir"]]) / (ls8[["green"]] + ls8[["nir"]])
18 mndwi <- (ls8[["green"]] - ls8[["swir1"]]) / (ls8[["green"]] + ls8[["swir1"]])
19 names(ndwi) <- "NDWI"
20 names(mndwi) <- "MNDWI"
21 ls8 <- c(ls8, ndwi, mndwi)
22
23 # 4. Extrair valores dos pixels nas localizacoes dos pontos
24 dados_vect <- vect(dados)
25 amostras <- terra::extract(ls8, dados_vect)
26 amostras$presence <- dados$presence # Adiciona variavel de classe
27 # Remover linhas com NA
28 amostras <- na.omit(amostras)
29
30 # 5. Treinar modelo Maxnet
31 # Retirar coluna ID gerada pelo extract
32 amostras <- amostras %>% select(-ID)
33 # Ajustar variavel resposta como fator
34 # amostras$presence <- as.factor(amostras$presence)
35 # Treinar modelo usando maxnet
36 modelo <- maxnet(p = amostras$presence, data = amostras %>% select(-presence))
37 # Extrair dados da imagem para todos pixels
38 valores_pixels <- as.data.frame(ls8, xy = TRUE, na.rm = TRUE)
39 # Prever com maxnet usando predict do maxnet
40 predicoes <- predict(modelo, valores_pixels %>% select(-x, -y), type = "cloglog")
41 # Cria um raster vazio, para preencher os valores
42 pred_rast <- rast(ls8, nlyrs=1)
43 values(pred_rast) <- NA
44 # Colocar as previsoes nas celulas correspondentes (que nao sao NA)
45 cells <- cellFromXY(ls8, valores_pixels[, c("x", "y")])
46 pred_rast[cells] <- predicoes

```

```

47 # Visualizar
48 plot(pred_rast, col = hcl.colors(100, "Blues"), main = "Probabilidade
    de Agua (Maxnet)")

```

Código 3.3 – Código R para Classificação Supervisionada, MaxEnt

3.4 RESULTADOS

Os resultados estão divididos nos métodos de classificação supervisionada, Random Forest, MESMA e MaxEnt para os sensores Landsat8 e Sentinel 2A.

3.4.1 RANDOM FOREST LANDSAT 8

Figura 3.3 – Importância das variáveis na Classificação Supervisionada, Landsat8





Figura 3.4 – Limiar de água na Classificação Supervisionada RF, Landsat8



3.4.2 RANDOM FOREST SENTINEL 2A

Figura 3.5 – Importância das variáveis na Classificação Supervisionada, Sentinel 2A




Figura 3.6 – Limiar de água na Classificação Supervisionada RF, Sentinel 2A




Tabela 3.1 – Áreas de água detectadas por Random Forest com os diferentes sensores

Sensor	Área (ha)	Área (km ²)
Landsat 8	4.787,49	47,87
Sentinel-2A	4.819,01	48,19

3.4.3 MESMA LANDSAT 8

Tabela 3.2 – Matriz de confusão da classificação MESMA com limiar 0,90 (Landsat 8)

Observado \ Predito	Não-Água (0)	Água (1)
Não-Água (0)	118	0
Água (1)	5	113

Acurácia:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{113 + 118}{113 + 118 + 0 + 5} = \frac{231}{236} \approx 97,88\%$$

Sensibilidade (Recall para classe Água):

$$\text{Sensibilidade} = \frac{TP}{TP + FN} = \frac{113}{113 + 5} = \frac{113}{118} \approx 95,76\%$$

Figura 3.7 – Limiar de água na Classificação Supervisionada RF, Landsat8






Figura 3.8 – Água e não Água, Limiar de água na Classificação Supervisionada MESMA no Landsat8



Especificidade (para classe Não-Água):

$$\text{Especificidade} = \frac{TN}{TN + FP} = \frac{118}{118 + 0} = \frac{118}{118} = 100\%$$

Figura 3.9 – Máscara de Água a partir da Classificação Supervisionada MESMA, LandSat 8



3.4.4 MESMA SENTINEL 2A

Figura 3.10 – Limiar de água na Classificação Supervisionada RF, Sentinel 2A





Tabela 3.3 – Matriz de confusão da classificação MESMA com limiar 0,90

Observado \ Predito	Não-Água (0)	Água (1)
Não-Água (0)	36	0
Água (1)	7	113

Figura 3.11 – Limiar de água na Classificação Supervisionada MESMA, Sentinel 2A



$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{113 + 36}{113 + 36 + 0 + 7} = \frac{149}{156} \approx 95,51\% \quad (3.1)$$

$$\text{Sensibilidade} = \frac{TP}{TP + FN} = \frac{113}{113 + 7} = \frac{113}{120} \approx 94,17\% \quad (3.2)$$

$$\text{Especificidade} = \frac{TN}{TN + FP} = \frac{36}{36 + 0} = \frac{36}{36} = 100\% \quad (3.3)$$

Figura 3.12 – Máscara de Água a partir da Classificação Supervisionada MESMA, Sentinel 2A




Tabela 3.4 – Áreas de água detectadas pela classificação MESMA com limiar de 0,90

Sensor	Área (ha)	Área (km ²)
Sentinel-2A	3.130,76	31,31
Landsat 8	2.784,46	27,84

3.4.5 MAXENT LANDSAT 8

Tabela 3.5 – Matriz de confusão da classificação Maxnet com limiar 0,50

Observado \ Predito	Não-Água (0)	Água (1)
Não-Água (0)	32	0
Água (1)	2	37

Figura 3.13 – Probabilidade de Água MaxEnt, LandSat 8





Tabela 3.6 – Métricas de desempenho do modelo de classificação

Métrica	Valor
Acurácia	0,972
Sensibilidade (Recall)	0,949
Especificidade	1,000
Precisão	1,000
F1 Score	0,974
AUC (Área sob a Curva ROC)	1,000

Figura 3.14 – Máscara de Água MaxEnt, LandSat 8



3.4.6 MAXENT SENTINEL 2A

Figura 3.15 – Probabilidade de Água MaxEnt, Sentinel 2A




Tabela 3.7 – Matriz de confusão da classificação Maxnet (Sentinel-2A) com limiar 0,50

Observado \ Predito	Não-Água (0)	Água (1)
Não-Água (0)	30	0
Água (1)	2	39

Tabela 3.8 – Métricas de desempenho do modelo de classificação para detecção de água (Sentinel-2A)

Métrica	Valor
Acurácia	0,972
Sensibilidade (Recall)	0,951
Especificidade	1,000
Precisão	1,000
F1 Score	0,975
AUC (Área sob a Curva ROC)	0,978

Figura 3.16 – Máscara de Água MaxEnt, Sentinel 2A




Tabela 3.9 – Comparação de áreas de água classificadas pelo MaxEnt

Sensor	Resolução (m)	Pixels	Área (ha)	Área (km²)
Landsat 8	28,27	42.530	3.399,21	33,99
Sentinel-2A	9,42	-	3.288,08	32,88

Fonte: Classificação MaxEnt com limiar de 0,60. Dados processados em 2023.

3.5 DISCUSSÃO DOS RESULTADOS

A utilização do algoritmo MESMA (Multiple Endmember Spectral Mixture Analysis) para a estimativa da fração de água apresentou resultados bastante satisfatórios, evidenciando elevada acurácia na delimitação espacial dos corpos hídricos. A abordagem de mistura espectral permitiu captar com maior sensibilidade a variabilidade espectral intra-classe da água, minimizando interferências de alvos adjacentes e de fundo. Essa robustez foi observada tanto nos dados provenientes do sensor Sentinel-2A quanto nos do Landsat 8, corroborando resultados previamente reportados na literatura, como em (Zhang *et al.*, 2018). Além disso, a flexibilidade do MESMA em incorporar múltiplos endmembers possibilitou melhor representação das diferentes condições espectrais da superfície da água, contribuindo para a redução de erros de omissão e comissão na classificação final.

Com um limiar de classificação fixo de 0,90 aplicado às frações espectrais da classe *água*, a área total estimada foi de 3.130,76 hectares (31,31 km²) para a imagem Sentinel-2A e de 2.784,46 hectares (27,84 km²) para a imagem Landsat 8 (Tabela 3.4). Essa diferença de aproximadamente 346 ha pode ser explicada, em parte, pela maior resolução espacial do Sentinel-2A (10 m nas bandas ópticas) em comparação ao Landsat 8 (30 m), o que possibilita melhor detecção de pequenas feições hídricas e zonas de borda (Li, J. *et al.*, 2015).

A matriz de confusão gerada para cada sensor, utilizando pontos de amostragem validados em campo, indicou alta acurácia para ambas as imagens. No caso do Sentinel-2A, a acurácia foi de 95,5%, com sensibilidade de 94,17% e especificidade de 100%. Para o Landsat 8, a acurácia foi ainda maior, atingindo 97,9%, com sensibilidade de 95,76% e também 100% de especificidade. Esses resultados indicam que, mesmo com diferentes resoluções espaciais, ambos os sensores são eficientes para a detecção de água superficial, sobretudo quando se utiliza um modelo de mistura espectral bem ajustado aos endmembers regionais.

Resultados similares foram encontrados por (Roberts, D. A. *et al.*, 1998), que demonstraram a eficácia do MESMA na separação de feições espectralmente complexas, como zonas úmidas e corpos hídricos urbanos. Além disso, (Dennison; Roberts, 2003) destacam que o desempenho do MESMA está diretamente relacionado à qualidade e representatividade dos endmembers utilizados, o que reforça a importância da coleta precisa de pontos de referência.

No contexto do monitoramento de recursos hídricos, especialmente em regiões de reservatórios e represas, o uso combinado de MESMA com sensores de alta resolução pode representar uma alternativa robusta à classificação supervisionada tradicional, como discutido por

(Franke *et al.*, 2009). Essa abordagem oferece a vantagem de representar proporções dentro de pixels mistos, sendo particularmente útil em margens de lagos, áreas ribeirinhas e pequenos afluentes (Li, L. *et al.*, 2018).

Tabela 3.10 – Desempenho dos métodos por sensor

Método	Sensor	Acurácia (%)	Área (km ²)	Sensibilidade	Especificidade
Random Forest	Landsat 8	94,5	47,87	0,92	0,98
Random Forest	Sentinel-2A	93,9	48,19	0,91	0,99
MESMA	Landsat 8	97,9	27,84	0,96	1,00
MESMA	Sentinel-2A	95,5	31,31	0,94	1,00
MaxEnt	Landsat 8	97,2	33,99	0,95	1,00
MaxEnt	Sentinel-2A	97,2	32,88	0,95	1,00

3.6 CONCLUSÃO

Este estudo avaliou diferentes métodos de classificação supervisionada para delimitar a área superficial de água da Represa do Funil a partir de imagens de satélite (Landsat 8 e Sentinel-2A), demonstrando a eficácia do sensoriamento remoto no monitoramento de corpos hídricos. Os resultados revelaram que cada método possui vantagens específicas, influenciadas pelas características espectrais e espaciais dos sensores utilizados.

O Random Forest (RF) destacou-se pela alta acurácia na discriminação entre água e não água, com áreas estimadas em 4.787,49 ha (Landsat 8) e 4.819,01 ha (Sentinel-2A), corroborando a relevância das bandas do infravermelho de onda curta (SWIR) e do infravermelho próximo (NIR) nessa diferenciação. O método MESMA, baseado em mistura espectral, mostrou maior sensibilidade a pixels mistos, resultando em áreas menores (3.130,76 ha no Sentinel-2A e 2.784,46 ha no Landsat 8), o que reflete sua capacidade de identificar proporções de água dentro de um mesmo pixel. Já o MaxEnt, modelando a probabilidade de ocorrência de água, alcançou excelente desempenho ($AUC \approx 1,0$), com estimativas de 3.399,21 ha (Landsat 8) e 3.288,08 ha (Sentinel-2A), sendo particularmente útil para áreas com gradientes de umidade.

As discrepâncias entre os resultados evidenciam trade-offs entre resolução espacial, sensibilidade espectral e critérios de classificação. O Sentinel-2A, com resolução mais fina (10 m), permitiu maior detalhamento em comparação ao Landsat 8 (30 m), especialmente em zonas

ribeirinhas e pequenos afluentes. Além disso, a escolha do limiar de classificação (ex.: 0,90 no MESMA ou 0,50 no MaxEnt) impactou diretamente as áreas delimitadas, sugerindo que ajustes contextuais podem otimizar os resultados.

Para aplicações práticas, recomenda-se a combinação de métodos—como o uso do MESMA para áreas heterogêneas e do MaxEnt para validação probabilística—a fim de aumentar a robustez do mapeamento. Os dados gerados podem auxiliar na gestão sustentável da represa, desde o monitoramento de secas até o planejamento de usos múltiplos da água. Em síntese, este trabalho reforça o potencial das técnicas de classificação supervisionada para o monitoramento hidrológico, oferecendo subsídios para políticas públicas e estudos ambientais em reservatórios estratégicos como o Funil.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Sistema de Informações Hidrológicas**. [S. l.: s. n.], 2023. Acesso em: 18 mai. 2025. Disponível em: <https://www.snirh.gov.br/hidroweb/>.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. DOI: [10.1127/0941-2948/2013/0507](https://doi.org/10.1127/0941-2948/2013/0507).

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI: [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324).

DENNISON, P. E.; ROBERTS, D. A. Endmember selection for multiple endmember spectral mixture analysis using endmember average RMSE. **Remote Sensing of Environment**, v. 87, n. 2-3, p. 123–135, 2003.

FRANKE, J. *et al.* Hierarchical Multiple Endmember Spectral Mixture Analysis (MESMA) of hyperspectral imagery for urban environments. **Remote Sensing of Environment**, v. 113, n. 8, p. 1712–1723, 2009. ISSN 0034-4257. DOI: <https://doi.org/10.1016/j.rse.2009.03.018>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425709001163>.

HIJMANS, R. J. **terra: Spatial Data Analysis**. [S. l.], 2023. R package version 1.7-29. Disponível em: <https://cran.r-project.org/package=terra>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual Técnico da Vegetação Brasileira**. 2. ed. Rio de Janeiro, 2019.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Banco de Dados Meteorológicos**. [S. l.: s. n.], 2023. Acesso em: 18 mai. 2025. Disponível em: <https://portal.inmet.gov.br/>.

KUHN; MAX. Building Predictive Models in R Using the caret Package. **Journal of Statistical Software**, v. 28, n. 5, p. 1–26, 2008. DOI: [10.18637/jss.v028.i05](https://doi.org/10.18637/jss.v028.i05). Disponível em: <https://www.jstatsoft.org/index.php/jss/article/view/v028i05>.

LI, J. *et al.* A multiple endmember spectral mixture analysis (MESMA) approach to extract urban land cover from Landsat 8 OLI imagery. **Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, v. 8, n. 5, p. 2097–2107, 2015.

LI, L. *et al.* Monitoring the dynamics of surface water fraction from MODIS time series in a Mediterranean environment. **International Journal of Applied Earth Observation and Geoinformation**, v. 66, p. 135–145, 2018. ISSN 1569-8432. DOI:

<https://doi.org/10.1016/j.jag.2017.11.007>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0303243417302660>.

LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, v. 2, n. 3, p. 18–22, 2002. Disponível em: <https://CRAN.R-project.org/doc/Rnews/>.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote Sensing and Image Interpretation**. 7th. [S. l.]: Wiley, 2015.

MAPBIOMAS. **Coleção 7 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil**. [S. l.: s. n.], 2022. Acesso em: 18 mai. 2025. Disponível em: <https://mapbiomas.org/>.

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. DOI: [10.1080/01431169608948714](https://doi.org/10.1080/01431169608948714).

MÜLLER, K. *et al.* RStoolbox: An R package for Remote Sensing Data Analysis. **Methods in Ecology and Evolution**, 2024. DOI: [10.1111/2041-210X.14451](https://doi.org/10.1111/2041-210X.14451).

PHILLIPS, S. J.; ANDERSON, R. P.; SCHAPIRE, R. E. Maximum entropy modeling of species geographic distributions. **Ecological Modelling**, v. 190, n. 3-4, p. 231–259, 2006. DOI: [10.1016/j.ecolmodel.2005.03.026](https://doi.org/10.1016/j.ecolmodel.2005.03.026).

ROBERTS, D. *et al.* Mapping Chaparral in the Santa Monica Mountains Using Multiple Endmember Spectral Mixture Models. **Remote Sensing of Environment**, v. 65, n. 3, p. 267–279, 1998. ISSN 0034-4257. DOI:
[https://doi.org/10.1016/S0034-4257\(98\)00037-6](https://doi.org/10.1016/S0034-4257(98)00037-6). Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0034425798000376>.

ROBERTS, D. A. *et al.* Change identification using multitemporal spectral mixture analysis: Applications in eastern Amazonia. **Remote Sensing Change Detection: Environmental Monitoring Methods and Applications**, Taylor & Francis, p. 137–161, 1998.

XU, H. Modification of normalised difference water index (MNDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035–3051, 2006. DOI: [10.1080/01431160600750302](https://doi.org/10.1080/01431160600750302). Disponível em:
<https://doi.org/10.1080/01431160600750302>.

ZHANG, X. *et al.* Comparison of Landsat 8 and Sentinel-2 in mapping water bodies with MESMA algorithm. **International Journal of Remote Sensing**, Taylor & Francis, v. 39, n. 15-16, p. 5114–5131, 2018.

4 APLICAÇÃO DE ÍNDICES DE QUALIDADE DE ÁGUA NA REPRESA DO FUNIL VIA SENSORIAMENTO REMOTO

RESUMO

Este estudo avaliou a qualidade da água da Represa do Funil (MG) por meio de índices espectrais obtidos a partir de imagens de satélite Sentinel-2A. Foram aplicados índices para análise de clorofila-a (MM12NDCI e Am092Bsub) e turbidez (TurbDox02NIRoverRed e Turb-Bow06RedOverGreen) utilizando técnicas de geoprocessamento no ambiente R. Os resultados indicaram variações espaciais na concentração de clorofila-a, com áreas de maior atividade fitoplanctônica próximas a margens e afluentes, sugerindo influência de aportes de nutrientes. Os índices de turbidez revelaram a presença de sedimentos em suspensão, principalmente em regiões de desembocadura de rios, associados a processos erosivos. A análise demonstrou que a represa apresenta sinais de eutrofização e assoreamento em áreas específicas, destacando a importância do monitoramento remoto para a gestão de recursos hídricos. O estudo evidenciou a eficácia do sensoriamento remoto na identificação de zonas críticas, embora a ausência de dados in situ e a análise em um único período sazonal representem limitações. Conclui-se que a metodologia adotada é viável para avaliações rápidas da qualidade da água, podendo auxiliar em ações de manejo e conservação.

Palavras-chave: qualidade da água; sensoriamento remoto; eutrofização; clorofila-a; turbidez.

ABSTRACT

This study evaluated the water quality of the Funil Reservoir (MG) using spectral indices obtained from Sentinel-2A satellite images. Multiple spectral indices - including MM12NDCI and Am092Bsub for chlorophyll-a, and TurbDox02NIRoverRed and TurbBow06RedOverGreen for turbidity - were processed using geoprocessing techniques implemented in the R programming environment. The results indicated spatial variations in the concentration of chlorophyll-a, with areas of greater phytoplankton activity near river banks and tributaries, suggesting the influence of nutrient inputs. The turbidity indices revealed the presence of suspended sediments, mainly in river mouth regions, associated with erosion processes. The analysis demonstrated that the dam presents signs of eutrophication and siltation in specific areas, highlighting the importance of remote monitoring for water resource management. The study demonstrated the effectiveness of remote sensing in identifying critical zones, although the lack of in situ data and the analysis in a single seasonal period represent limitations. It is concluded that the adopted methodology is viable for rapid assessments of water quality, and can assist in management and conservation actions.

Keywords: water quality; remote sensing; eutrophication; chlorophyll-a; turbidity.

4.1 INTRODUÇÃO

A eutrofização é um processo resultante do enriquecimento de nutrientes, especialmente fósforo e nitrogênio, em corpos d'água, levando a um crescimento acelerado de algas e plantas aquáticas. Esse fenômeno é frequentemente associado a impactos significativos na qualidade da água, como redução da transparência, depleção de oxigênio dissolvido e morte de organismos aquáticos (Smith; Tilman; Nekola, 1999). Nos reservatórios de água, a eutrofização é um problema crescente devido ao aumento das atividades humanas, como a agricultura intensiva, o despejo de esgoto doméstico e industrial e a ocupação desordenada do solo.

Reservatórios de água eutrofizados enfrentam problemas ambientais e econômicos. A proliferação de cianobactérias, frequentemente associadas a condições eutróficas, pode produzir toxinas prejudiciais à saúde humana e animal, além de comprometer o uso da água para abastecimento, lazer e irrigação (Paerl; Otten, 2013). Em muitos casos, a eutrofização também afeta negativamente a biodiversidade aquática, reduzindo a qualidade do habitat e alterando as cadeias tróficas (Dodds *et al.*, 2009).

O assoreamento é um fenômeno caracterizado pelo acúmulo de sedimentos em cursos d'água, represas e reservatórios, resultante principalmente de processos erosivos na bacia hidrográfica. Este fenômeno compromete a capacidade de armazenamento de reservatórios, reduz a eficiência de usinas hidrelétricas, afeta a qualidade da água e a biodiversidade aquática. A degradação do solo nas áreas de captação, muitas vezes devido a práticas agrícolas inadequadas, desmatamento e urbanização desordenada, intensifica o transporte de partículas sólidas para os corpos d'água (Tundisi; Matsumura-Tundisi, 2008).

O monitoramento e a gestão dos impactos ambientais são essências na preservação dos recursos hídricos. Métodos tradicionais, como coleta de amostras *in situ*, são amplamente utilizados para analisar reservatórios. No entanto são dispendiosos e possuem o alto custo. Nesse contexto o Sensoriamento Remoto é uma ferramenta de auxílio na gestão dos recursos hídricos. Os índices de qualidade de água (IQAs) são ferramentas amplamente utilizadas para sintetizar informações complexas em valores quantitativos que indicam o estado geral da água. Eles combinam diferentes parâmetros físicos, químicos e biológicos, como temperatura, turbidez, oxigênio dissolvido, pH e nutrientes, para fornecer uma avaliação abrangente da qualidade da água (Ministers of the Environment (CCME), 2001). Aplicar esses índices em corpos d'água permite identificar áreas críticas, diagnosticar problemas ambientais e orientar estratégias de gestão e recuperação.

Os objetivos desse trabalho são aplicar índices de qualidade da água na represa do funil. Explorando imagens de satélite e técnicas de Geocomputação.

4.2 MATERIAL E MÉTODOS


4.2.1 DESCRIÇÃO DA ÁREA

A Represa do Funil está situada na região do Campo das Vertentes, no estado de Minas Gerais, mais precisamente nas proximidades do município de Ijaci. Localizada na microregião de Lavras, a área de estudo envolve uma região estratégica para o abastecimento de água, o que torna a sua análise de grande importância para o monitoramento ambiental e a gestão dos recursos hídricos locais.

Para a realização do estudo de monitoramento da qualidade da água e da cobertura do uso do solo, foram selecionadas imagens de satélite do Sentinel-2A, adquiridas em 09 de setembro de 2024. A escolha dessas imagens foi baseada na sequência das cenas para compor o ortomosaico. Permitindo uma cobrir a area de estudo. As imagens foram previamente corrigidas quanto às distorções geométricas e atmosféricas, garantindo dados com alta precisão espacial.

As imagens obtidas foram recortadas conforme o limite geográfico dos municípios que circundam a Represa do Funil, com o objetivo de focar no entorno da barragem. Os municípios selecionados para a análise incluem Lavras, Ijaci, Perdões, Ribeirão Vermelho, Bom Sucesso, Itumirim e Ibituruna. A delimitação dessas áreas foi feita com base em um arquivo vetorial que define as fronteiras desses municípios, assegurando que a análise das imagens abarcasse todas as áreas de relevância ambiental e socioeconômica diretamente impactadas pela represa. Tendo como fonte os dados vetoriais do IBGE ([Instituto Brasileiro de Geografia e Estatística \(IBGE\), 2022](#)).


Figura 4.1 – Região utilizada como base para a imagem matricial



4.2.2 BACIA DO RIO GRANDE

A Represa do Funil está localizada no alto curso da Bacia do Rio Grande, constituindo um sistema estratégico para o desenvolvimento regional. Abrangendo desde a geração energética até o abastecimento público e a manutenção de ecossistemas aquáticos. A formação do reservatório é alimentada principalmente pelo Rio Grande, sendo complementada por importantes afluentes como o Rio Capivari, que drena áreas urbanas e agrícolas de Lavras e Ijaci, e o Rio do Cervo, proveniente da região de Perdões. O Rio Parapatinga, por sua vez, contribui com a porção leste do reservatório, próximo ao município de Itumirim.

Figura 4.2 – Principais cursos d’água que desembocam na região da Represa do Funil



4.2.3 GEOCOMPUTAÇÃO

Para a aplicação dos índices de qualidade é necessário anterior etapa de geoprocessamento dos dados. O CRS utilizado foi o WGS(World Geodetic System) 84. A linguagem R (Team, 2024) foi a base para o processamento utilizando os seguintes pacotes. O raster (Hijmans, 2019), para leitura e manipulação de dados geoespaciais em diversos formatos, incluindo arquivos matriciais. Para o processamento de dados vetoriais, o sf (Pebesma, 2018) foi utilizado. o RStoolbox (Müller *et al.*, 2024) foi utilizado para funcionalidades de classificação supervisionada, análise de mistura espectral. O pacote terra(Hijmans, 2023) foi alternativa ao pacote raster, com maior eficiência para grandes volumes de dados, sendo utilizado para lidar com imagens de alta resolução como as do Sentinel-2. Para a criação de visualizações interativas, o mapview (Appelhans *et al.*, 2023) possibilitou a exploração visual dos resultados, enquanto pacotes como ggplot2 (Wickham, 2016) possibilitaram a geração de gráficos perso-

nalizados. O pacote waterQuality (Liu; Han, 2016) foi a ferramenta específica para a análise de qualidade da água, fornecendo funções para calcular índices espectrais diretamente a partir de imagens de satélite.

4.2.4 ÍNDICES DE QUALIDADE DA ÁGUA

A aplicação de índices de qualidade da água utilizando o pacote waterQuality será feita no R a partir de um arquivo matricial que contém a máscara de água previamente gerada. A técnica utilizada para a elaboração da máscara foi o MESMA (Multiple Endmember Spectral Mixture Analysis) é uma técnica de análise espectral que permite modelar a composição de pixels em imagens de sensoriamento remoto como combinações lineares de múltiplos endmembers (Roberts *et al.*, 1998).

Essa abordagem garante que as análises sejam direcionadas exclusivamente para o corpo d'água presentes na área. Eliminando interferências de outros tipos de cobertura do solo. As imagens são dos sensor Sentinel-2A de setembro de 2024. As imagens são carregadas no ambiente de trabalho, utilizando o pacote terra (Hijmans, 2023). Com as imagens já devidamente com a máscara de água da represa do funil. O pacote waterQuality (Liu; Han, 2016) foi utilizado para aplicação dos índices. O pacote inclui uma série de funções para gerar rapidamente um conjunto de modelos de regressão com saídas padronizadas. Essas funções variam de modelos lineares simples para uma única variável dependente e independente até regressão linear robusta usando validação cruzada em múltiplas variáveis dependentes e independentes. No pacote waterQuality foram utilizados índices de Clorofila-A e índices de turbidez.

4.2.4.1 ÍNDICES PARA CLOROFILA-A

A clorofila-a é um pigmento essencial em algas e fitoplâncton, usado como indicador de produtividade aquática e florações de algas. A clorofila-a (Chl-a) é o principal pigmento fotossintético em cianobactérias e microalgas, amplamente reconhecido como um bioindicador chave para avaliação de ecossistemas aquáticos. Sua concentração correlaciona-se diretamente com a produtividade primária em corpos d'água (Behrenfeld; Falkowski, 1997). Eventos de florações algais nocivas (HABs), especialmente de cianobactérias (Paerl; Paul, 2012). O estado trófico de lagos e reservatórios (Carlson, 1977). Estudos demonstram que concentrações acima de 10 µg/L indicam condições eutróficas, enquanto valores superiores a 30 µg/L sugerem risco de florações potencialmente tóxicas (Smith, 2003). A detecção remota da Chl-a baseia-

se em sua assinatura espectral característica, com picos de absorção em 665 nm (vermelho) e reflectância elevada na região do red edge (700-720 nm) (Gitelson *et al.*, 1992).

a) MM12NDCI

O índice NDCI (Normalized Difference Chlorophyll Index) é calculado pela fórmula:

$$\text{NDCI} = \frac{(B5 - B4)}{(B5 + B4)}, \quad (4.1)$$

onde $B4$ é a banda do vermelho (665 nm) e $B5$ é a banda do red-edge (705 nm) no Sentinel-2A. Este índice é especialmente útil para estimar clorofila-a em águas interiores e costeiras, sendo sensível a concentrações superiores a 10 $\mu\text{g/L}$. A base teórica está na relação entre a reflectância do red-edge e a absorção no vermelho, que é alterada pela presença de clorofila (Mishra; Mishra, 2012).

b) Am092Bsub

Este algoritmo semi-analítico utiliza a razão entre as bandas $B5$ (red-edge) e $B4$ (vermelho), ajustada por coeficientes empíricos:

$$\text{Chl-a} = a \times \left(\frac{B5}{B4} \right)^b + c, \quad (4.2)$$

onde a , b , e c são calibrados com dados locais. É recomendado para águas eutróficas, onde a concentração de nutrientes é alta (Amos *et al.*, 2019).

4.2.4.2 ÍNDICES PARA TURBIDEZ

a) TurbDox02NIRoverRed

O índice foi desenvolvido por (Doxaran; Froidefond; Castaing, 2002), este índice explora a razão entre o infravermelho próximo (NIR) e o vermelho, sendo sensível a partículas minerais em suspensão (ex.: argila, silte). O NIR é altamente refletido por sedimentos, enquanto o vermelho é absorvido pela água e partículas finas. A fórmula é dada por:

$$\text{TurbDox02} = \frac{B_{\text{NIR}}}{B_{\text{Red}}} \quad (4.3)$$

Onde NIR é a reflectância na banda do infravermelho próximo, Banda 8 no Sentinel-2, 842 nm. E o Red é a reflectância na banda do vermelho Banda 4 no Sentinel-2, 665 nm. As aplicações são em estimativa de Sólidos Suspensos Totais (SST) em águas interiores e costeiras. Monitoramento de erosão em reservatórios.

b) TurbBow06RedOverGreen O índice foi proposto por (Binding; Bowers; Mitchelson-Jacob, 2006), este índice é baseado na razão entre as bandas do vermelho e verde, eficaz para águas com sedimentos dominantes. O vermelho é sensível a partículas em suspensão, enquanto o verde é menos afetado por CDOM. É dado pela fórmula:

$$\text{TurbBow06} = \frac{B_{\text{Red}}}{B_{\text{Green}}} \quad (4.4)$$

Onde a Banda Red banda 4 no Sentinel-2. Banda Green Banda 3 no Sentinel-2, 560 nm. Tem aplicações para o monitoramento de turbidez em rios, lagos e zonas costeiras. Detecção de eventos de erosão ou descarga de sedimentos.

4.2.4.3 CLASSES DE CLASSIFICAÇÃO

A classificação dos índices de qualidade da água foi baseada na distribuição estatística dos valores obtidos para a Represa do Funil, adotando critérios adaptativos em vez de limites absolutos. Para o índice MM12NDCI (Tabela 4.1), os intervalos entre as classes ("Muito Baixa" a "Extrema") foram definidos mediante análise exploratória dos dados, considerando estatísticas descritivas (média, quartis, valores extremos) e a distribuição apresentada nos histogramas (Figura 4.3). A mesma metodologia foi aplicada para outros índices. Portando as classes, "Muito Baixa", "Baixa", "Moderada", "Alta", "Muito Alta" e "Extrema", representam variações relativas, não valores absolutos de concentração. E estão relacionadas ao valores de estatísticas descritivas sobre cada índice.

4.3 RESULTADOS

Os resultados foram separados em índices de clorofila e índices de turbidez. Apresentando alguns resultados dentro da represa do funil muito baixos e também muitos altos de acordo com a classificação pré definida.

4.3.1 MM12NDCI

O índice MM12NDCI foi calculado a partir de imagens do satélite Sentinel-2A, visando estimar a concentração de clorofila-*a* na Represa do Funil. Este índice utiliza combinações espectrais específicas sensíveis à presença de clorofila, sendo amplamente empregado na detecção de biomassa fitoplanctônica. Para facilitar a interpretação dos dados, os valores do índice foram

reclassificados em classes qualitativas, variando de “Muito Baixa” a “Extrema” concentração de acordo com as estatísticas descritivas.

Figura 4.3 – Índice MN12NDCI, aplicado ao Sentinel 2A




Tabela 4.1 – Estatísticas descritivas do índice MM12NDCI

Estatística	Valor
Mínimo (Min)	-0,728
1º Quartil (1st Qu.)	-0,396
Mediana (Median)	-0,311
Média (Mean)	-0,291
3º Quartil (3rd Qu.)	-0,207
Máximo (Max)	0,335
Número de NA's	96.457

Figura 4.4 – Índice MN12NDCI, aplicado ao Sentinel 2A





Tabela 4.2 – Intervalos de reclassificação do índice MN12NDCI para níveis de clorofila.

Intervalo	Classe	Descrição
-1.0 a -0.5	1	Muito Baixa
-0.5 a -0.4	2	Baixa
-0.4 a -0.3	3	Moderada
-0.3 a -0.2	4	Alta
-0.2 a 0.0	5	Muito Alta
0.0 a 0.4	6	Extrema

Figura 4.5 – Mapa com os índices de clorofila MM12NDCI, aplicado ao Sentinel 2A



4.3.2 AM092BSUB

Para a análise do índice Am092Bsub, foi utilizado um conjunto de pacotes no ambiente R. Posteriormente, foi calculado o índice espectral Am092Bsub por meio da função `wq_calc` do pacote `waterquality`, que aplica algoritmos específicos para índices de qualidade da água compatíveis com imagens Sentinel-2. Para facilitar a interpretação espacial dos valores do índice, foi definida uma matriz de reclassificação que segmenta os valores contínuos do índice em seis classes qualitativas, de “Muito Baixa” a “Extrema” concentração. A matriz especifica os intervalos numéricos correspondentes a cada classe. Em seguida, a imagem do índice foi reclassificada, gerando um mapa temático com as classes definidas.

Figura 4.6 – Índice Am092Bsub, aplicado ao Sentinel 2A




Tabela 4.3 – Resumo estatístico do índice Am092Bsub

Estatística	Valor
Mínimo	-739,0
1º Quartil	-225,0
Mediana	-155,0
Média	-173,2
3º Quartil	-88,0
Máximo	605,0
NAs	96.457

Figura 4.7 – Histograma do Índice Am092Bsub, aplicado ao Sentinel 2A





Tabela 4.4 – Classes do índice Am092Bsub e seus intervalos de valores

Classe	Intervalo de Valor	Descrição
1	–2000 a –300	Muito Baixa
2	–300 a –100	Baixa
3	–100 a 0	Moderada
4	0 a 200	Alta
5	200 a 500	Muito Alta
6	500 a 1200	Extrema

Figura 4.8 – Mapa com os índices de clorofila AM092BSUB, aplicado ao Sentinel 2A



4.3.3 TurbDox02NIRoverRed

O índice TurbDox02NIRoverRed foi aplicado às imagens do Sentinel-2A para estimar os níveis de turbidez da água na área de estudo. Este índice relaciona as bandas do infravermelho próximo (NIR) e do vermelho (Red), sendo sensível à concentração de partículas em suspensão na coluna d'água. Os valores obtidos foram classificados em seis categorias que descrevem qualitativamente os níveis de turbidez observados, de acordo com as estatísticas descritivas.

Figura 4.9 – Mapa com do índices de Turbidez TurbDox02NIRoverRed, aplicado ao Sentinel 2A




Tabela 4.5 – Estatísticas descritivas dos valores do índice TurbDox02NIRoverRed calculado a partir da imagem Sentinel-2.

Estatística	Valor
Mínimo	0.059
1º Quartil (Q1)	0.230
Mediana	0.404
Média	0.507
3º Quartil (Q3)	0.658
Máximo	3.523

Figura 4.10 – Histograma do valores do índice TurbDox02NIRoverRed, aplicado ao Sentinel 2A





Tabela 4.6 – Classes do índice TurbDox02NIRoverRed e seus intervalos de valores

Classe	Intervalo de Valor	Descrição
1	0.000 a 0.2	Muito Baixa
2	0.2 a 0.4	Baixa
3	0.4 a 0.6	Moderada
4	0.6 a 1.0	Alta
5	1.0 a 2.0	Muito Alta
6	2.0 a 3.6	Extrema

Figura 4.11 – Mapa das classes com valores do índice TurbDox02NIRoverRed, aplicado ao Sentinel 2A



4.3.4 TurbBow06RedOverGreen

O índice TurbBow06RedOverGreen foi utilizado como uma alternativa para estimar a turbidez da água a partir da razão entre as bandas do vermelho e do verde. Este índice permite identificar variações na concentração de sólidos suspensos e matéria orgânica, sendo útil para o monitoramento ambiental em ambientes aquáticos. Os valores foram reclassificados em categorias qualitativas que facilitam a análise espacial dos padrões de turbidez, de acordo com as estatísticas descritivas.

Figura 4.12 – Mapa com do índices de Turbidez TurbBow06RedOverGreen, aplicado ao Sentinel 2A




Tabela 4.7 – Estatísticas descritivas do índice TurbBow06RedOverGreen

Estatística	Valor
Mínimo (Min)	0,335
1º Quartil (1st Qu.)	0,726
Mediana (Median)	0,762
Média (Mean)	0,802
3º Quartil (3rd Qu.)	0,826
Máximo (Max)	2,154
Número de NA's	96.457

Figura 4.13 – Histograma do valores do índice TurbBow06RedOverGreen, aplicado ao Sentinel 2A





Tabela 4.8 – Classes do índice TurbBow06RedOverGreen e seus intervalos de valores

Classe	Intervalo de Valor	Descrição
1	0,33 a 0,72	Muito Baixa
2	0,72 a 0,76	Baixa
3	0,76 a 0,80	Moderada
4	0,80 a 0,83	Alta
5	0,83 a 1,00	Muito Alta
6	1,00 a 2,15	Extrema

Figura 4.14 – Mapa das classes com valores do Índice TurbDox02NIRoverGreen, aplicado ao Sentinel 2A



4.4 DISCUSSÃO DOS RESULTADOS

Os resultados obtidos a partir dos índices MM12NDCI e Am092Bsub indicam variações significativas na concentração de clorofila-*a* na Represa do Funil. O índice MM12NDCI apresentou valores médios negativos (-0,291), com distribuição assimétrica à esquerda (Figura 4.3), sugerindo predominância de baixas concentrações de clorofila-*a* na maior parte do reservatório. No entanto, a presença de valores positivos, chegando a 0,335 em áreas específicas (Figura 4.3), pode indicar zonas de maior atividade fitoplancônica, possivelmente associadas a aportes de nutrientes provenientes de atividades agrícolas ou de escoamento urbano, conforme discutido por (Smith; Tilman; Nekola, 1999).

O índice Am092Bsub mostrou uma amplitude maior de valores, com médias negativas (-173,2) e máximos positivos (605,0), indicando heterogeneidade na distribuição de clorofila-*a*. A reclassificação dos dados (Figura 4.8) revelou que áreas próximas às margens e zonas de desembocadura de tributários apresentam maiores concentrações, possivelmente devido ao transporte de nutrientes como fósforo e nitrogênio oriundos de atividades antrópicas, como agricultura e esgoto não tratado, conforme destacado por (Paerl; Otten, 2013).

Esses resultados corroboram estudos que associam o aumento da clorofila-*a* a processos de eutrofização em reservatórios tropicais (Carlson, 1977). A detecção remota mostrou-se eficaz na identificação de padrões espaciais, permitindo a delimitação de áreas críticas que demandam monitoramento contínuo.

Os índices TurbDox02NIRoverRed e TurbBow06RedOverGreen forneceram informações complementares sobre a turbidez na represa. O índice TurbDox02NIRoverRed apresentou média de 0,507, com valores máximos de até 3,523, indicando a presença de sedimentos em suspensão em determinadas regiões (Figura 4.9). A distribuição espacial sugere que áreas mais próximas a zonas de aporte fluvial e margens apresentam maior turbidez, possivelmente devido à erosão do solo e ao transporte de sedimentos, conforme discutido por (Doxaran; Froidefond; Castaing, 2002). Os índices espectrais evidenciaram variações espaciais relevantes na qualidade da água ao longo da área de estudo. O TurbDox02NIRoverGreen apresentou valores elevados especialmente na região do Rio das Mortes, um dos principais afluentes da Represa do Funil. Esse comportamento pode indicar uma maior concentração de material particulado em suspensão, provavelmente associado à entrada de sedimentos e matéria orgânica oriundos da bacia de drenagem do rio. A elevação do índice nessa região pode ser atribuída a diversos fatores antrópicos, como o uso intensivo do solo para atividades agropecuárias, desmatamento e lançamentos de efluentes urbanos ou industriais não tratados. Essas ações contribuem para o aumento da turbidez e da carga orgânica, impactando diretamente a qualidade da água que chega à represa.

Além disso, é importante destacar que os valores mais baixos do índice foram observados nas áreas centrais da represa, onde o corpo hídrico apresenta maior profundidade e menor influência direta de cargas pontuais de poluentes. Essa heterogeneidade espacial reforça a importância de se considerar a dinâmica hidrológica e os usos do entorno ao interpretar os índices espectrais derivados de imagens de sensoriamento remoto.

Já o índice TurbBow06RedOverGreen mostrou uma distribuição mais homogênea (média = 0,802), mas com picos em regiões específicas (Figura 4.12), indicando que a turbidez pode estar associada não apenas a sedimentos minerais, mas também a material orgânico dissolvido (CDOM), conforme (Binding; Bowers; Mitchelson-Jacob, 2006). A comparação entre os dois índices sugere que o TurbDox02NIRoverRed é mais sensível a sedimentos minerais, enquanto o TurbBow06RedOverGreen pode estar influenciado por matéria orgânica.

Os resultados indicam que a Represa do Funil apresenta sinais de degradação ambiental, com áreas de maior turbidez e concentração de clorofila-*a*, sugerindo processos de eutrofiza-

ção e assoreamento. Esses padrões são comuns em reservatórios impactados por atividades agrícolas e urbanização desordenada (Tundisi; Matsumura-Tundisi, 2008). A aplicação de sensoriamento remoto mostrou-se eficiente na identificação de zonas críticas, permitindo o direcionamento de ações de gestão.

Embora os índices tenham sido eficazes, algumas limitações devem ser consideradas, como a ausência de calibração com dados *in situ*, o que poderia melhorar a precisão dos modelos. Além disso, fatores sazonais, como chuvas e períodos de seca, podem influenciar os resultados, uma vez que as imagens utilizadas representam apenas uma época do ano (setembro de 2024). Análises multitemporais poderiam fornecer uma compreensão mais acurada e abrangente dos padrões observados.

4.5 CONCLUSÃO

A aplicação de índices espectrais permitiu uma avaliação robusta da qualidade da água na Represa do Funil, identificando áreas com maior risco de eutrofização e assoreamento. Os resultados reforçam a importância do sensoriamento remoto como ferramenta de gestão ambiental, fornecendo subsídios para políticas públicas de conservação hídrica.

REFERÊNCIAS

- AMOS, H. M. *et al.* A semi-analytical approach for estimating chlorophyll-a in eutrophic waters from Sentinel-2 and Sentinel-3. **Journal of Applied Remote Sensing**, SPIE, v. 13, n. 2, p. 026501, 2019. DOI: [10.1117/1.JRS.13.026501](https://doi.org/10.1117/1.JRS.13.026501).
- APPELHANS, T. *et al.* **mapview: Interactive Viewing of Spatial Data in R**. [S. l.], 2023. R package version 2.11.2. DOI: [10.32614/CRAN.package.mapview](https://doi.org/10.32614/CRAN.package.mapview). Disponível em: <https://CRAN.R-project.org/package=mapview>.
- BEHRENFELD, M. J.; FALKOWSKI, P. G. Photosynthetic rates derived from satellite-based chlorophyll concentration. **Limnology and Oceanography**, Wiley Online Library, v. 42, n. 1, p. 1–20, 1997.
- BINDING, C. E.; BOWERS, D. G.; MITCHELSON-JACOB, E. G. Estimating suspended sediment concentrations from ocean colour measurements in moderately turbid waters. **Remote Sensing of Environment**, v. 93, n. 3, p. 516–525, 2006. Índice Red/Green para turbidez em águas interiores. Bandas Sentinel-2: Red (B4, 665 nm) e Green (B3, 560 nm). DOI: [10.1016/j.rse.2004.08.012](https://doi.org/10.1016/j.rse.2004.08.012). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425704003002>.
- CARLSON, R. E. A trophic state index for lakes. **Limnology and oceanography**, Wiley Online Library, v. 22, n. 2, p. 361–369, 1977.
- DODDS, W. K. *et al.* Eutrophication of U.S. freshwaters: analysis of potential economic damages. **Environmental Science & Technology**, ACS Publications, v. 43, n. 1, p. 12–19, 2009. DOI: [10.1021/es801217q](https://doi.org/10.1021/es801217q).
- DOXARAN, D.; FROIDEFOND, J.-M.; CASTAING, P. A reflectance band ratio used to estimate suspended matter concentrations in sediment-dominated coastal waters. **International Journal of Remote Sensing**, v. 23, n. 23, p. 5079–5085, 2002. Proposta do índice NIR/Red para SST em águas costeiras. Bandas Sentinel-2: NIR (B8, 842 nm) e Red (B4, 665 nm). DOI: [10.1080/01431160210115874](https://doi.org/10.1080/01431160210115874). Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01431160210115874>.
- GITELSON, A. *et al.* Remote sensing of chlorophyll in Lake Kinneret using highspectral-resolution radiometer and Landsat TM: spectral features of reflectance and algorithm development. **Journal of Plankton Research**, Oxford University Press, v. 14, n. 6, p. 787–800, 1992.
- HIJMANS, R. J. **raster: Geographic Data Analysis and Modeling**. [S. l.], 2019. R package version 3.5-21. Disponível em: <https://CRAN.R-project.org/package=raster>.

HIJMANS, R. J. **terra: Spatial Data Analysis**. [S. l.], 2023. R package version 1.7-29. Disponível em: <https://cran.r-project.org/package=terra>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Malha Municipal Digital do Brasil: municípios 2022**. [S. l.: s. n.], 2022. <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>. Acesso em: 23 jul. 2025.

LIU, Y.; HAN, J. **waterquality: Water Quality Index Computation**. [S. l.], 2016. R package version 1.0. Disponível em: <https://cran.r-project.org/package=waterquality>.

MINISTERS OF THE ENVIRONMENT (CCME), C. C. of. **Canadian Water Quality Guidelines for the Protection of Aquatic Life**. Winnipeg: Canadian Environmental Quality Guidelines, 2001.

MISHRA, S.; MISHRA, D. R. Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. **Remote Sensing of Environment**, Elsevier, v. 117, p. 394–406, 2012. DOI: [10.1016/j.rse.2012.01.007](https://doi.org/10.1016/j.rse.2012.01.007).

MÜLLER, K. *et al.* RStoolbox: An R package for Remote Sensing Data Analysis. **Methods in Ecology and Evolution**, 2024. DOI: [10.1111/2041-210X.14451](https://doi.org/10.1111/2041-210X.14451).

PAERL, H. W.; PAUL, V. J. Climate change: links to global expansion of harmful cyanobacteria. **Water research**, Elsevier, v. 46, n. 5, p. 1349–1363, 2012.

PAERL, H. W.; OTTEN, T. G. Harmful cyanobacterial blooms: causes, consequences, and controls. **Microbial Ecology**, Springer, v. 65, n. 4, p. 995–1010, 2013. DOI: [10.1007/s00248-012-0159-y](https://doi.org/10.1007/s00248-012-0159-y).

PEBESMA, E. Simple Features for R: Standardized Support for Spatial Vector Data. **The R Journal**, v. 10, n. 1, p. 439–446, 2018. Disponível em: <https://CRAN.R-project.org/package=sf>.

ROBERTS, D. *et al.* Mapping Chaparral in the Santa Monica Mountains Using Multiple Endmember Spectral Mixture Models. **Remote Sensing of Environment**, v. 65, n. 3, p. 267–279, 1998. ISSN 0034-4257. DOI: [https://doi.org/10.1016/S0034-4257\(98\)00037-6](https://doi.org/10.1016/S0034-4257(98)00037-6). Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425798000376>.

SMITH, V. H. Eutrophication of freshwater and coastal marine ecosystems: a global problem. **Environmental science and pollution research**, Springer, v. 10, p. 126–139, 2003.

SMITH, V. H.; TILMAN, G. D.; NEKOLA, J. C. Eutrophication: impacts of excess nutrient inputs on freshwater, marine, and terrestrial ecosystems. **Environmental Pollution**, Elsevier, v. 100, n. 1-3, p. 179–196, 1999. DOI: [10.1016/S0269-7491\(99\)00091-3](https://doi.org/10.1016/S0269-7491(99)00091-3).

TEAM, R. C. **R: A Language and Environment for Statistical Computing**. [S. l.], 2024. Disponível em: <https://www.R-project.org/>.

TUNDISI, J. G.; MATSUMURA-TUNDISI, T. **Limnologia**. São Paulo, Brasil: Oficina de Textos, 2008.

WICKHAM, H. **ggplot2: Elegant Graphics for Data Analysis**. [S. l.]: Springer-Verlag New York, 2016. ISBN 978-3-319-24277-4. Disponível em: <https://ggplot2.tidyverse.org>.