

**UFRRJ**

**PRÓ-REITORIA DE EXTENSÃO  
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO,  
LEVANTAMENTO E INTERPRETAÇÃO DE SOLOS**

**TRABALHO DE CONCLUSÃO DE CURSO**

**COMPARAÇÃO DE MÉTODOS DE  
CLASSIFICAÇÃO DE IMAGEM DE CEBERS-4A E  
POTENCIAL APLICAÇÃO PARA DETECÇÃO DE  
FEIÇÕES EROSIVAS NA BACIA DO SANA -RJ**

**Cássio Villani dos Santos**

**2025**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO**  
**PRÓ-REITORIA DE EXTENSÃO**  
**CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO,**  
**LEVANTAMENTO E INTERPRETAÇÃO DE SOLOS**

**COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGEM DE**  
**CEBERS-4A PARA IDENTIFICAÇÃO DE FEIÇÕES EROSIVAS NA**  
**SUB-BACIA HIDROGRÁFICA DO RIO SANA -RJ**

**CÁSSIO VILLANI DOS SANTOS**

*Sob a Supervisão do(a) Professor(a)*  
**Gustavo Granha**

Trabalho de Conclusão de Curso  
submetido como requisito parcial para  
obtenção do título de **Especialista** em  
Geoprocessamento, Levantamento e  
Interpretação de Solos.

Seropédica, RJ  
Junho de 2025



ESPECIALIZAÇÃO  
Geoprocessamento, levantamento e  
interpretação de solos  
UFRRJ - UFPA - UFV - UFPA



Ficha catalográfica elaborada  
com os dados fornecidos pelo(a) autor(a)

V237c

Villani dos Santos, Cássio , 05 de Outubro de 1990-  
Comparação de métodos de classificação de imagem de  
CEBERS-4A: identificação de feições erosivas na sub  
bacia hidrográfica do rio Sana - RJ / Cássio Villani  
dos Santos. - Rio das Ostras, 2025.  
34 f.: il.

Orientador: Gustavo Souto Perdigão Granha.  
Trabalho de conclusão de curso(Graduação). --  
Universidade Federal Rural do Rio de Janeiro,  
Geoprocessamento de Solos, 2025.

1. Geoprocessamento. 2. OBIA. 3. KMEANS. 4. Bacia  
Hidrográfica de Sana. 5. CEBERS 4A. I. Souto Perdigão  
Granha, Gustavo, 19/02/1975-, orient. II Universidade  
Federal Rural do Rio de Janeiro. Geoprocessamento de  
Solos III. Título.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001

É permitida a cópia parcial ou total deste documento, desde que seja citada a fonte.



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
COORDENADORIA DE EDUCAÇÃO A DISTÂNCIA



ATA N° 3647/2025 - CEAD (12.28.01.36)

N° do Protocolo: 23083.040656/2025-54

Seropédica-RJ, 25 de julho de 2025.

#### ATA DE DEFESA

Aos dezessete dias do mês de julho do ano de dois mil e vinte e cinco, às onze horas, através de web conferência, instalou-se a banca examinadora de Trabalho de Conclusão de Curso de Especialização em Geoprocessamento, Levantamento e Interpretação de Solos, do cursista **Cássio Villani dos Santos** sob a orientação do professor **Gustavo Souto Perdigão Granha**. A banca examinadora foi composta pelas professoras/pesquisadoras **Niriele Bruno Rodrigues** e **Mariana Oliveira da Costa**. A defesa do TCC intitulado "**COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGEM DE CEBERS-4A PARA IDENTIFICAÇÃO DE FEIÇÕES EROSIVAS NA SUB-BACIA HIDROGRÁFICA DO RIO SANA -RJ**", foi iniciada às onze horas e teve a duração de vinte minutos de apresentação seguida da avaliação pela banca. O cursista, após avaliado pela banca examinadora obteve o resultado:

(X) APROVADO, devendo o cursista proceder a eventual revisão solicitada pelo supervisor e /ou pela banca, e entregar a versão final em até quinze dias à coordenação do Curso.

( ) NÃO APROVADO.

Seropédica, 17 de julho de 2025.

**Niriele Bruno Rodrigues**

Primeira Examinadora

**Mariana Oliveira da Costa**

Segundo Examinador

**Gustavo Souto Perdigão Granha**

Presidente

**Cássio Villani dos Santos**

Cursista

*(Assinado digitalmente em 25/07/2025 15:46)*

**GUSTAVO SOUTO PERDIGAO GRANHA**

PROFESSOR DO MAGISTERIO SUPERIOR

DeGEOIM (12.28.01.00.00.87)

Matricula: ###524##

*(Assinado digitalmente em 25/07/2025 12:29)*

**NIRIELE BRUNO RODRIGUES**

ASSINANTE EXTERNO

CPF: ###.###.797-##

*(Assinado digitalmente em 25/07/2025 17:20)*

**MARIANA OLIVEIRA DA COSTA**

ASSINANTE EXTERNO

CPF: ###.###.087-##

*(Assinado digitalmente em 29/07/2025 21:02)*

**CÁSSIO VILLANI DOS SANTOS**

DISCENTE

Matricula: 2024#####0

## **DEDICATÓRIA**

Dedico esse trabalho para meu filho Tim que irradiou a felicidade no meu mundo tal qual o Sol ilumina o céu azul profundo. E a minha companheira Fernanda cujo apoio foi indispensável para concluir esse estudo.

## RESUMO

### COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGEM DE CEBERS-4A PARA IDENTIFICAÇÃO DE FEIÇÕES EROSIVAS NA SUB-BACIA HIDROGRÁFICA DO RIO SANA -RJ

**DOS SANTOS, Cássio. Comparação de métodos de classificação de imagem de cebers-4a para identificação de feições erosivas na sub-bacia hidrográfica do rio Sana - RJ. 2025.** Trabalho de Conclusão de Curso (Especialização em Geoprocessamento, Levantamento e Interpretação de Solos). Pró-Reitoria de Extensão, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

Este estudo tem como objetivo avaliar e comparar os resultados da classificação supervisionada e de classificação automática em imagens de CEBERS 4A e sua potencial aplicação no estudo de áreas erodidas no interior da Bacia Hidrográfica do Rio Sana, Distrito de Macaé-RJ. Os resultados obtidos apontaram acurácia de 0,8936 para o método supervisionado OBIA e de 0,837 para o método automático K-means, ambos considerados de excelente desempenho. A elevada precisão é atribuída à predominância das classes pasto e floresta na área de estudo. No entanto, ambos os métodos demonstraram limitações na classificação de áreas urbanas fragmentadas, bem como confusão entre as classes água, sombra e rocha. Destaca-se que o método K-means obteve melhor desempenho na identificação de solo exposto, permitindo reconhecer feições erosivas concentradas principalmente em áreas antropizadas ao longo do curso do Rio Sana, especialmente nas regiões de pastagem.

**Palavras-chave:** Sana. Erosão. Classificação de imagens. OBIA. Kmeans. CEBERS-4A. Geoprocessamento.

## ABSTRACT

### COMPARISON OF IMAGE CLASSIFICATION METHODS USING CEBERS-4A FOR IDENTIFYING EROSION FEATURES IN THE RIO SANA SUB-WATERSHED - RJ

**DOS SANTOS, Cássio. Comparison of image classification methods using CEBERS-4A for identifying erosive features in the Rio Sana sub-watershed - RJ. 2025.** xxp. Trabalho de Conclusão de Curso (Specialization in Geoprocessing, Soil Survey and Interpretation). Pró-Reitoria de Extensão, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

This study aims to evaluate and compare the results of supervised classification and automatic classification in CEBERS 4A images and their potential application in the study of eroded areas within the Sana River Hydrographic Basin, Macaé District-RJ. The obtained results showed an accuracy of 0.8936 for the supervised OBIA method and 0.837 for the automatic K-means method, both considered to have excellent performance. The high precision is attributed to the predominance of pasture and forest classes in the study area. However, both methods demonstrated limitations in classifying fragmented urban areas, as well as confusion between the water, shadow, and rock classes. It is noteworthy that the K-means method achieved better performance in identifying exposed soil, allowing for the recognition of erosive features concentrated mainly in anthropized areas along the course of the Sana River, especially in pasture regions.

Keywords: erosion. image classification. CEBERS-4A. geoprocessing. sub-watershed.

## LISTA DE FIGURAS

<b>Figura 1</b> – Figura 1 - Visualização dos agrupamentos formados pelo algoritmo de classificação não supervisionada <i>Kmeans</i> . .....	9
<b>Figura 2</b> – Mapa hipsométrico da sub bacia do Sana.....	12
<b>Figura 3</b> –Mapa de localização de Sana.....	12
<b>Figura 4</b> – Paisagem montanhosa do Sana.....	13
<b>Figura 5</b> – Relatório do gerador de amostras do plugin AcATaMa.....	19
<b>Figura 6</b> – Mapa de classificação da classificação OBIA.....	21
<b>Figura 7</b> – Comparação entre a imagem orbita e a imagem classificada .....	24
<b>Figura 8</b> – Mapa de classificação pelo método <i>kmeans</i> .....	25
<b>Figura 9</b> –Comparação entre a imagem antes da reclassificação (esquerda) e depois da reclassificação (direita).....	26
<b>Figura 10</b> –Comparação entre as imagens classificadas pelo método <i>kmeans</i> . A imagem superior é a imagem CEBERS, a imagem do meio é a classificação pelo método <i>kmeans</i> com dez classes e a imagem inferior é a imagem com método <i>kmeans</i> após a reclassificação em cinco classes.....	29

## LISTA DE QUADROS

<b>Quadro 1</b> – Fluxograma da metodologia da classificação OBIA.....	14
<b>Quadro 2</b> – Fluxograma da metodologia da classificação <i>Kmeans</i> .....	15
<b>Quadro 3</b> – Características espectrais do CEBERS 4A.....	15
<b>Quadro 4</b> – Conversão das classes no comando “reclassificar por tabela” do Qgis.....	19
<b>Quadro 5</b> – Matriz de confusão da classificação OBIA.....	22
<b>Quadro 6</b> – Matriz de confusão da classificação <i>Kmeans</i> .....	26

## LISTA DE TABELAS

<b>Tabela 1 - Matriz de confusão.....</b>	<b>10</b>
---	-----------

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>1</b>
<b>2. REVISÃO DA LITERATURA.....</b>	<b>3</b>
<b>3. MATERIAL E MÉTODOS.....</b>	<b>11</b>
<b>4. RESULTADOS.....</b>	<b>20</b>
<b>5. CONCLUSÃO E CONSIDERAÇÕES FINAIS.....</b>	<b>30</b>



## 1. INTRODUÇÃO

A erosão do solo, um processo complexo e multifatorial, tem sido intensificado pela atividade e ocupação humana. A urbanização acelerada, o desmatamento indiscriminado, o manejo inadequado do solo e as mudanças climáticas globais contribuem significativamente para a degradação dos solos, com impactos diretos sobre a produção de alimentos, a qualidade da água e a biodiversidade. Segundo a FAO (Organização das Nações Unidas para a Alimentação e Agricultura, 2022), as erosões hídrica e eólica comprometem a segurança alimentar mundial, poluem os recursos hídricos e contribuem para o aumento das emissões de gases de efeito estufa, uma vez que os solos armazenam uma quantidade de carbono superior à soma do carbono presente na vegetação e na atmosfera e, portanto, desempenham um papel fundamental no sequestro e armazenamento de carbono orgânico (MACHADO, 2005).

A perda de solos férteis, além de afetar a agricultura, acarreta o assoreamento de rios e reservatórios, aumentando a vulnerabilidade hídrica, reduzindo sua capacidade de armazenamento, bem como aumentando o risco de inundações. A erosão hídrica é o principal agente de degradação do solo em regiões tropicais e subtropicais, condição na qual encontra-se o Brasil, tal como elucida HERNANI (2021). A remoção de solos férteis não apenas afeta a agricultura, mas também compromete a qualidade e a quantidade de água disponível. Esse cenário é de sobremaneira agravado por características fisiográficas, como o relevo acidentado e o uso inadequado do solo.

Diante da urgência em preservar recursos naturais essenciais, este estudo visa avaliar a potencialidade da detecção de feições erosivas utilizando a classificação de imagens CBERS 4A, por meio da comparação entre diferentes abordagens. No que se refere aos objetivos específicos, destacam-se:

- Identificar a região alvo do estudo através de levantamento bibliográfico e geoprocessamento.
- Classificar imagens de CEBERS-4A.
- Elaborar mapas de uso e cobertura do solo e comparar a acuracidade dos métodos utilizados.
- Discutir a aplicabilidade dos métodos na detecção de áreas de erosão no interior da sub-bacia.

As técnicas de geoprocessamento, bem como o processamento digital de imagens matriciais ou *raster*, oriundas de sensores orbitais que remotamente registram a energia refletida ou emitida pelos elementos da superfície terrestre, em diferentes comprimentos de onda, podem auxiliar nas investigações referentes aos impactos das atividades humanas sobre o meio ambiente, mais especificamente no que se refere à erosão dos solos, bem como no suporte ao monitoramento sistemático das áreas em situação de risco. Ao combinar tais ferramentas com os métodos de modelagem e análise espacial, torna-se possível obter uma visão mais precisa e dinâmica da degradação do solo. Além de mapear a distribuição espacial da erosão, o presente estudo busca endossar a influência de fatores como a pedologia, a geologia, a geomorfologia, o uso do solo e a variação climática na intensificação ou atenuação dos fenômenos no interior da sub-bacia.

A comunidade do Sana depende economicamente do turismo, impulsionado por sua paisagem natural, rios e cachoeiras. No entanto, a expansão urbana e atividades como loteamentos, abertura de estradas e desmatamento intensificam a degradação ambiental,



especialmente pela erosão do solo. Esse fenômeno compromete as nascentes em áreas de maior altitude, essenciais para o abastecimento hídrico local, tornando-se uma preocupação ambiental e socioeconômica.

A erosão é um processo natural de remoção e transporte de sedimentos por agentes como água e vento. Contudo, as atividades antrópicas aceleram esse processo, resultando em impactos significativos, como a degradação da fertilidade do solo, o assoreamento de cursos d'água e o aumento da vulnerabilidade a desastres naturais. Em regiões de relevo acidentado, como o Sana (RJ), a remoção da vegetação associada à urbanização agrava a perda de solo e intensifica os impactos ambientais.

A interação entre estrutura geológica, relevo e clima influencia a suscetibilidade à erosão. Encostas íngremes e fraturas no substrato rochoso favorecem a infiltração da água e o desgaste do solo. Em regiões tropicais, a elevada umidade e as chuvas intensas intensificam a erosão, promovendo a lixiviação de nutrientes e comprometendo a qualidade dos solos, o que afeta diretamente o equilíbrio ecológico e a segurança da população local.

A ocupação desordenada e a impermeabilização do solo em encostas aumentam a instabilidade geotécnica e o risco de deslizamentos, como evidenciado sistematicamente por eventos catastróficos no estado do Rio de Janeiro. A ausência de planejamento adequado e de medidas de conservação do solo agravam esses impactos, tornando essencial a identificação de áreas vulneráveis para a gestão sustentável do território.

O procedimento metodológico inicia-se com um trabalho de gabinete, por meio do levantamento bibliográfico de artigos científicos, dissertações e relatórios técnicos relacionados à erosão do solo, além de estudos calcados nas técnicas de geoprocessamento e sensoriamento remoto. Tal embasamento teórico permite a definição dos parâmetros de análise e a escolha dos dados e técnicas mais adequados para o mapeamento das áreas susceptíveis à erosão na sub-bacia hidrográfica do Sana.

Serão coletados dados bibliográficos, vetoriais e raster a partir de bancos de dados abertos, como os disponibilizados pelo IBGE e pela CPRM, com o objetivo de delimitar a sub-bacia e caracterizar suas propriedades fisiográficas.

Ademais, será realizada uma comparação entre esses dados e as informações provenientes de estudos previamente realizados, visando validar e complementar as análises. Em seguida, a pesquisa converge para a aquisição de dados geoespaciais, incluindo imagens de satélite de alta e média resoluções provenientes de sensores orbitais, tais como o *Landsat 8/9* e *CIBERS-4<sup>a</sup>* entre outros, além de modelos digitais de elevação (MDE) - como o *SRTM (Shuttle Radar Topography Mission)*. As imagens passam por um pré-processamento, que envolve correções geométricas e atmosféricas, garantindo maior precisão na análise.

Para a identificação e classificação das áreas de erosão, aplicam-se técnicas de sensoriamento remoto e processamento digital de imagens, incluindo a composição de bandas espectrais, e algoritmos de classificação supervisionada e não supervisionada. O uso de um Sistema de Informações Geográficas (SIG) possibilita a espacialização dos dados e a realização de análises espaciais avançadas.

As fundamentações teóricas serão discutidas no próximo capítulo, assim como os trabalhos já realizados sobre os processos erosivos na sub-bacia.

## 2. REVISÃO DA LITERATURA



O presente capítulo abordará os estudos mais relevantes sobre a aplicação da análise segmentada por objetos e as diferentes formas de validação dos resultados. Por fim, o capítulo analisará os diferentes métodos de validação de resultados. Antes de apresentar as metodologias e técnicas desenvolvidas no trabalho é necessário elucidar determinados conceitos centrais que serão amplamente utilizados neste trabalho. Dessa forma, será definido primeiramente uma definição de solo e uma definição de erosão de solo, e, posteriormente, como esses mecanismos são compreendidos no contexto das bacias hidrográficas em clima tropical.

## 2.1 O solo e a pedosfera

Segundo SANTOS *et al.*, (2018), o solo é um corpo natural, tridimensional, dinâmico, formado por partes sólidas, líquidas e gasosas, constituído de materiais minerais e orgânicos. Ele ocupa a superfície das extensões continentais da Terra e pode ser afetado por atividades humanas. Os solos apresentam uma organização em camadas ou horizontes, que resultam de processos de formação ao longo do tempo, como intemperismo do substrato rochoso, com influências de fatores como clima, organismos e relevo. Essas camadas refletem as mudanças ocorridas nos materiais originais devido a transformações de matéria e energia. O limite superior do solo é a atmosfera, mas pode ser influenciado pela presença de água ou outros materiais.

A unidade básica de estudo do solo é o *pedon*, que é a representação tridimensional do solo, e seu perfil, que vai da superfície até o material de origem. Os horizontes do solo são usados para a análise de suas propriedades e variabilidade. Em climas tropicais úmidos, como o do Brasil, os processos biológicos e pedogenéticos podem atingir profundidades maiores que 200 cm. Para fins de classificação, o limite inferior do solo é fixado arbitrariamente em 200 cm, exceto em algumas situações específicas, como em solos com camadas espessas de determinados horizontes. Essas profundidades são utilizadas para descrever e classificar os solos de maneira mais precisa. Tal definição do limite inferior do solo é complexa por conta da grande variabilidade de tipos de solo e os diversos fatores pedogenéticos que envolvem sua complexa formação. Normalmente, à medida que se aprofunda, o solo gradualmente dá lugar a uma camada de rocha dura, sedimentos ou materiais saprolíticos que não exibem evidências de atividade biológica. Esse material subjacente, que não é considerado solo, se diferencia pela redução significativa de componentes orgânicos e pelo menor grau de alteração e decomposição dos minerais, apresentando características mais associadas ao substrato rochoso ou ao material original não consolidado. Os limites laterais são os contatos com corpos d'água superficiais, rochas, gelo, áreas com coberturas de materiais detríticos inconsolidados, aterros ou terrenos sob espelhos d'água permanentes (Santos *et al.*, 2018).

A pedosfera é fundamental para diversos ciclos biogeoquímicos e os processos que ocorrem no solo interferem em diversos outros sistemas, como a atmosfera, a biosfera e a hidrosfera. Dessa forma, os processos que interferem no solo, não se reduzem à escala do impacto. Os principais tipos de degradação do solo incluem a perda da camada superficial, que é a forma mais comum e representa uma significativa redução de nutrientes e matéria orgânica essenciais para a fertilidade. Além disso, há a deformação do terreno, que altera a topografia e pode comprometer sua funcionalidade e uso. A perda de nutrientes também é um fator preocupante, pois afeta diretamente a produtividade agrícola. Outro problema é a salinização,



caracterizada pelo acúmulo de sais solúveis na superfície, tornando o solo inadequado para a agricultura. A compactação, por sua vez, reduz a porosidade e a capacidade de infiltração da água, prejudicando seu equilíbrio. A poluição do solo, causada por substâncias químicas, compromete sua qualidade e afeta a saúde das plantas. Por fim, a erosão, especialmente a hídrica, é uma das principais causas da degradação, resultando em perdas expressivas de terra arável.(HERNANI *et al.*,2002)

As forças atuantes no solo, tanto naturais quanto antrópicas causam alterações nas características naturais do solo tendo como possível consequência a erosão. No próximo parágrafo será discutido mais especificamente o conceito de degradação do solo conhecido como erosão.

## 2.2 Erosão e os processos erosivos

A erosão é um processo natural de desgaste e remoção do solo e das rochas, intensificado por atividades humanas como desmatamento e práticas agrícolas inadequadas. O termo tem origem no latim *erodere*, que significa corroer ou desgastar (*rodere* – roer), estando associado à ideia de escavação. Esse fenômeno pode ser identificado na paisagem por marcas de remoção de material, especialmente em regiões sujeitas à ação da água e do vento. No caso da erosão causada pela chuva, o transporte dos sedimentos é chamado de ablação (*ablatio* – transportar para longe) (Marques, 2013). Como consequência, a perda da camada superficial do solo impacta negativamente sua fertilidade, dificultando a capacidade de sustentar a biodiversidade e a agricultura. Segundo Castro *et al.* (2002), a erosão compromete as características químicas (salinidade, pH, CTC) e físicas (permeabilidade, porosidade, textura) do solo, reduzindo sua disponibilidade de água e acelerando processos de degradação ambiental.

No contexto brasileiro, onde os climas tropical e subtropical predominam e as práticas inadequadas de manejo do solo são frequentes, a erosão hídrica é a principal responsável pela degradação dos solos, afetando diretamente a produtividade agrícola e a estabilidade ambiental (Castro *et al.*, 2002). Esse processo ocorre pela ação da água da chuva, que pode remover a camada superficial do solo de diferentes formas: erosão laminar, quando há remoção uniforme de partículas finas; erosão em sulcos, quando a enxurrada forma canais lineares; e erosão em voçorocas, que gera cavidades profundas e largas, tornando-se uma feição erosiva dominante que pode atingir o nível freático e dificultar a recuperação da área. A erosão hídrica pluvial por arrastamento ocorre em três fases: desagregação, transporte e deposição. Na fase de desagregação, o impacto das gotas de chuva e o escoamento superficial quebram as partículas do solo, reduzindo a infiltração de água e tornando-o mais vulnerável à erosão. Quando a intensidade da chuva supera a taxa de infiltração, inicia-se o transporte dos sedimentos, que se mantém enquanto houver energia suficiente no escoamento. Com a diminuição dessa energia, os sedimentos se depositam, finalizando o processo (Marques, 2013).

Além da erosão hídrica, outros tipos também afetam o solo. A erosão eólica, comum em regiões áridas e semiáridas, ocorre pela ação do vento, especialmente em áreas com pouca vegetação, resultando na remoção de partículas do solo e na formação de dunas (Hernani *et al.*, 2002). Já a erosão mecânica está associada a processos físicos, como o congelamento e descongelamento (*frost action*), que desagregam o solo, enquanto a erosão química decorre de



reações químicas que alteram sua composição, muitas vezes agravadas por poluentes e manejo inadequado da terra.

Os impactos da erosão do solo são amplos, afetando o meio ambiente, a economia e a sociedade. A perda de fertilidade reduz a produtividade agrícola e compromete a segurança alimentar, podendo levar à escassez de recursos e à migração de populações que dependem da agricultura para subsistência. Além disso, a erosão contribui para a degradação da qualidade da água, pois o transporte de sedimentos e poluentes para rios e lagos afeta ecossistemas aquáticos, aumenta a sedimentação e pode provocar alagamentos. O desmatamento e a perda de biodiversidade são consequências diretas da erosão acelerada pelo uso inadequado do solo, assim como a instabilidade de encostas, que pode resultar em deslizamentos de terra e riscos para infraestruturas e populações vulneráveis. No aspecto climático, a degradação do solo reduz sua capacidade de sequestrar carbono, intensificando as emissões de gases de efeito estufa e agravando as mudanças climáticas (Hernani *et al.*, 2002).

Como destaca Guerra (2007) o clima é um fator de controle do processo erosivo, uma vez que os totais pluviométricos variam em diferentes regiões terrestres, sendo mais elevados nas regiões tropicais. O processo erosivo tende a acelerar à medida que as terras são desmatadas, desprotegendo os solos de sua cobertura vegetal e expondo-os diretamente a meteorização da chuva. Quando as gotas de chuva começam a bater nos solos ocorre o *splash*, ou seja, a ruptura dos agregados através do impacto das gotas, criando crostas e selando o solo. Posteriormente, devido à saturação de água ocorre a formação de poças ou *ponds*. Neste momento, o escoamento supera em grande volume a infiltração, iniciando o escoamento superficial e posteriormente em fluxos lineares formando microrravinas, que evoluem para ravinas maiores e formando novas ravinas.

Dentre os vários parâmetros que podem ser utilizados para medir a Erosividade da chuva a energia cinética ( $K_e$ ) é a mais utilizada como parâmetro para prever a perda de solo sendo que os valores  $5 < K_e < 25$  é entendido como a faixa onde a erosão ocorre mais intensamente para diferentes tipos de climas. A energia cinética é deflagradora da ruptura dos agregados, entendido como outro fator importante no processo erosivo. O teor de matéria orgânica é fundamental para estabilidade dos agregados. Solos com alto teor de silte utilizados na agricultura sem o manejo adequado tornam-se mais erodíveis à medida que perdem matéria orgânica e não há reposição. Dessa forma ocorre a ruptura dos agregados com a diminuição da matéria orgânica tornando os solos mais sujeitos à erosão. (GUERRA, 2007 p.19-20).

Dessa forma, a ruptura dos agregados pode ser entendida como um fator inicial do processo de erosão do solo. A medida em que os agregados se rompem, ocorre a formação de crostas e gretas de contração. A crosta forma uma selagem do solo diminuindo a porosidade e a infiltração gerando o *runoff*, ou seja, o escoamento superficial. Logo, é possível estabelecer que a saturação de água no solo é fundamental para o processo de escoamento superficial, uma vez que os poros podem ficar totalmente preenchidos de água, diminuindo a porosidade, e dependendo do tipo de solo, pode diminuir a sua agregação e resistência ao cisalhamento ou até mesmo o contrário, aumentando a sua agregação, como é o caso dos solos franco-arenosos (GUERRA, 2007 P.26). Ainda segundo autor, o processo de escoamento superficial se inicia com a saturação do solo e a remoção de partículas é causada pela força de cisalhamento do



*runoff* formando microtopografias onde a água irá fluir encosta abaixo primeiramente o escoamento em lençol e se transformando em ravina posteriormente por escoamento de fluxo linear.

### 2.3 Geoprocessamento e Sensoriamento Remoto

Segundo definição de Zaidan (2017), geoprocessamento é um conjunto de técnicas computacionais para coleta, armazenamento, processamento e análise de dados georreferenciados, essencial para os Sistemas de Informação Geográfica (SIGs), que auxiliam no planejamento e gestão territorial. Ele utiliza geotecnologias como sensoriamento remoto, cartografia digital, GPS e aerofotogrametria, sendo amplamente aplicado em áreas como meio ambiente, urbanismo e agricultura. Sua estrutura envolve hardware, software, pessoas especializadas e bancos de dados geográficos, possibilitando a criação de mapas temáticos e o monitoramento ambiental.

A percepção de que o geoprocessamento antecede o advento da computação contribui para a compreensão de sua definição, como nos exemplos dos mapas de a Batalha de Yorktown (1781), onde *overlay* de mapas foram utilizados para fins militares, e talvez no caso mais conhecido no estudo epidemiológico do Dr. John Snow (1854), que através da sobreposição de mapas e a sua correta interpretação, conseguiu erradicar uma epidemia de cólera em Londres (CERDAL & VALDIVIA, 2007). Mas foi na década de 1960 que os primeiros SIGs como conhecemos hoje foram criados. Atualmente, o geoprocessamento é fundamental na tomada de decisões estratégicas e na gestão de recursos, com seu crescimento sendo impulsionado pela demanda por planejamento sustentável e o avanço das tecnologias de sensoriamento remoto, como destaca Zaidan (2017). A qualidade dos produtos espaciais gerados pelos SIGs está estritamente relacionada à fonte de dados selecionadas. Nesse sentido, a aquisição de dados de Sensoriamento Remoto de diferentes fontes é parte integrante das análises ambientais em ambientes computacionais.

Segundo KHORRAM *et al.*, (2016), o Sensoriamento Remoto, no contexto ambiental, refere-se à captura de energia eletromagnética emitida por áreas ou objetos na superfície terrestre, nos oceanos ou na atmosfera. Essa tecnologia permite a identificação e diferenciação desses elementos por meio de sensores instalados em aeronaves ou satélites, possibilitando a observação de grandes áreas geográficas em uma única imagem. Um dos principais benefícios dessa abordagem, especialmente via satélite, é a capacidade de monitoramento contínuo de regiões específicas, permitindo a detecção de mudanças ao longo do tempo. A frequência com que um local é revisitado depende da órbita do satélite, da velocidade de navegação e da largura da faixa observada pelo sensor. Além disso, os dados coletados possuem referência geoespacial, o que possibilita sua integração com outras informações geográficas, como redes de transporte ou densidade populacional. Através de interfaces computacionais é possível analisar o comportamento espectral do alvo e inferir características composicionais que permitem regionalizá-los através de semelhanças e diferenças em termos de comportamento espectral. Além dessas aplicações, o Sensoriamento Remoto tem sido amplamente utilizado no monitoramento de processos geomorfológicos, como a erosão dos solos, permitindo a análise de fatores ambientais que influenciam sua dinâmica. Nesse contexto, a interação entre clima e cobertura do solo desempenha um papel fundamental na intensificação dos processos erosivos.



## 2.5 Classificação de imagens

A classificação de imagem no contexto do geoprocessamento e sensoriamento remoto faz parte do conjunto de técnicas de processamento digital de imagens e pode ser separadas com base na interferência ou não do analista na definição das classes e no modelo que será utilizado para atribuir valor aos dados em análise. Dessa forma, a classificação supervisionada é utilizada quando conhecemos as classes ou temos informações disponíveis sobre as classes e/ou o uso e cobertura do solo e por isso geralmente possui maior grau de exatidão (MACHADO et al., 2022). Na classificação não-supervisionada, os pixels são organizados em grupos com base em suas propriedades, identificadas por meio de análises estatísticas. Esse método é geralmente adotado quando não se possui conhecimento prévio sobre a quantidade ou as características dos alvos existentes na região estudada, ou ainda quando o objetivo é realizar uma análise inicial e exploratória da imagem.

A Análise de Imagens Baseada em Objetos (OBIA), segundo Blaschke (2010), é uma metodologia que trabalha com imagens de sensoriamento remoto segmentando-as em objetos ou regiões que representam unidades significativas do ambiente, em vez de lidar diretamente com pixels isolados. O processo tem início com a segmentação da imagem em áreas homogêneas, utilizando critérios como cor, textura e forma. Esses objetos segmentados servem como base para a etapa de classificação, permitindo a consideração de atributos contextuais, espaciais e espectrais. Essa abordagem visa superar desafios dos métodos convencionais, como a fragmentação causada pela análise pixel a pixel, oferecendo resultados mais coerentes e acurados, especialmente em estudos ambientais e urbanos. A metodologia também permite a integração com Sistemas de Informações Geográficas (SIG), ampliando a capacidade de análise multiescalar e possibilitando o uso de dados complementares para uma interpretação mais completa do território. O método OBIA é amplamente utilizado em diversas áreas, como a identificação de tipos de uso e cobertura da terra, estudos em ambientes urbanos, monitoramento de recursos naturais, agricultura de precisão, planejamento de cidades e manejo de áreas florestais e ambientais. Ele também se mostra eficaz em investigações sobre alterações no uso da terra e processos de degradação ecológica. A abordagem é particularmente vantajosa quando se busca uma interpretação mais precisa e contextualizada de elementos espaciais, como lagos, vegetação, construções e outras feições relevantes para o meio ambiente ou para o espaço urbano. Ao combinar informações espectrais, espaciais e texturais, o OBIA contribui para a geração de dados geográficos detalhados e confiáveis, essenciais para o planejamento e a tomada de decisões.

O avanço das técnicas de sensoriamento remoto tem permitido o desenvolvimento de métodos cada vez mais sofisticados para análise e classificação de imagens. Entre esses métodos, destaca-se o OBIA (Object-Based Image Analysis), que representa uma abordagem inovadora ao priorizar a análise de objetos, e não de pixels isolados, como unidade básica de interpretação (BLASCHKE; LANG; HAY, 2008). Essa mudança de paradigma se mostrou fundamental para melhorar a precisão e a coerência dos resultados em ambientes complexos e heterogêneos.



Ao contrário dos métodos tradicionais pixel a pixel, o OBIA utiliza algoritmos de segmentação para agrupar pixels semelhantes com base em atributos como forma, cor, textura e contexto espacial. Esses agrupamentos formam objetos que melhor representam unidades do mundo real, como corpos d'água, edificações ou áreas de vegetação (DUARTE, 2022). Segundo Blaschke (2010), essa abordagem possibilita uma interpretação mais contextualizada das imagens, já que leva em conta as relações espaciais e padrões visuais, reduzindo significativamente o efeito de "sal e pimenta" comum nas classificações por pixel.

No estudo de Chelotti (2017), por exemplo, a técnica foi aplicada para mapear o uso do solo da bacia hidrográfica do Alto Descoberto, no Distrito Federal, utilizando imagens Landsat 8. O uso de OBIA, aliado a softwares livres, mostrou-se eficaz tanto do ponto de vista técnico quanto econômico, gerando produtos cartográficos com maior detalhamento e confiabilidade. A classificação foi feita por meio de segmentação, seguida de aprendizado supervisionado e avaliação de qualidade utilizando índices como Kappa e Tau, sendo que o índice de Kappa atingiu 68,45%, valor considerado "muito bom" de acordo com a categorização de Landis e Koch (1977).

Além disso, a flexibilidade da abordagem OBIA permite sua integração com diferentes plataformas e ferramentas de geoprocessamento. No trabalho de Penariol e Castanho (2023), a metodologia foi implementada no QGIS, utilizando o plugin *Orfeo ToolBox* (OTB) para segmentação e o *Dzetsaka* para classificação semi-automática. O processo incluiu a configuração de parâmetros do algoritmo *meanshift* e a aplicação de amostras classificadas manualmente, resultando em um mapa de uso e ocupação do solo altamente preciso e com excelente qualidade cartográfica.


Entre as principais vantagens do OBIA destacam-se a redução de erros de classificação, a melhor identificação de classes heterogêneas e a capacidade de lidar com imagens de alta resolução, nas quais a variabilidade espectral interna é mais acentuada (BLASCHKE, 2010). Conforme apontado por Duarte (2022), a técnica também facilita a integração de múltiplas fontes de dados e atributos geográficos, contribuindo para análises multiescalares robustas e consistentes.

A capacidade do OBIA de capturar relações espaciais entre objetos é especialmente valiosa para aplicações em planejamento urbano, monitoramento ambiental e gestão de recursos naturais. Segundo Penariol e Castanho (2023), essa metodologia se torna ainda mais relevante em estudos que exigem elevado nível de detalhamento geográfico, uma vez que permite a extração automatizada de informações espacialmente explícitas, com maior eficiência e economia.

Em síntese, a análise orientada a objetos vem se consolidando como uma das abordagens mais promissoras para o processamento de imagens de sensoriamento remoto. Conforme Blaschke, Lang e Hay (2008), o OBIA representa não apenas um avanço técnico, mas também uma mudança conceitual na forma como os dados geoespaciais são interpretados. Sua aplicação tem demonstrado resultados superiores aos métodos convencionais, especialmente em contextos em que a complexidade espacial e a variabilidade das classes de uso do solo exigem soluções mais robustas e adaptáveis.



O método *Kmeans* por sua vez é uma ferramenta automatizada de classificação baseada no aprendizado de máquina não supervisionado. Segundo Folini (2022) O algoritmo *Kmeans* é amplamente utilizado em classificações não supervisionadas por sua eficiência em agrupar dados com base em similaridades estatísticas. Trata-se de um método de clusterização particional que organiza os dados em K grupos, de forma a minimizar a soma das distâncias quadradas entre os pontos de dados e os centróides dos respectivos grupos (**figura 1**). Essa abordagem visa otimizar a homogeneidade interna dos agrupamentos, permitindo a segmentação de imagens com base em características espectrais similares.



**Figura 1** - Visualização dos agrupamentos formados pelo algoritmo de classificação não supervisionada K-means. Os pontos pretos representam os dados de entrada (pixels ou amostras espectrais), enquanto os pontos verdes indicam os centróides dos clusters. As linhas vermelhas conectam cada ponto ao seu respectivo centróide, indicando a atribuição de classe com base na mínima distância.

### 3.6 Validação da acurácia: Índice de Kappa e o plugin AcATaMa.

O índice Kappa é amplamente utilizado para medir o grau de concordância entre os dados observados em campo e os apresentados no mapa temático. Sua principal vantagem é considerar todos os elementos presentes na matriz de confusão (**tabela 1**) no momento do cálculo do coeficiente. A matriz de confusão, por sua vez, é uma tabela quadrada composta por linhas e colunas que indicam a quantidade de amostras atribuídas a uma determinada classe pelo classificador, em comparação com a classe real verificada em campo (DUARTE, 2022).

**Tabela 1** - Matriz de confusão.



Classifier	Ground Truth Classes				Total
	1	2	...	k	
1	$p_{11}$	$p_{12}$	...	$p_{1k}$	$p_{1\cdot}$
2	$p_{21}$	$p_{22}$	...	$p_{2k}$	$p_{2\cdot}$
...					
k	$p_{k1}$	$p_{k2}$	...	$p_{kk}$	$p_{k\cdot}$
Total	$p_{\cdot 1}$	$p_{\cdot 2}$	...	$p_{\cdot k}$	1

Fonte: FRITZGERALD & LEES (1994).

O índice de Kappa é obtido a partir da fórmula

$$\hat{K} = \frac{p_o - p_e}{1 - p_e}$$

Cálculo de  $P_o$  (concordância observada) obtém a partir da soma dos valores da diagonal principal da matriz de confusão, que representam os acertos do modelo:

$$p_o = \sum_{i=1}^k p_{ii}$$

Cálculo de  $P_e$  (concordância esperada ao acaso): multiplicam-se os totais reais (linhas) e preditos (colunas) de cada classe e somam-se os produtos:

$$P_e = \frac{1}{N^2} \sum (linha_i \times coluna_i)$$

O resultado indica a concordância entre a concordância observada e a concordância esperada ao acaso feita pelo classificador conforme pode ser observado na **tabela 2** abaixo.

**Tabela 2-** Grau de exatidão da classificação de acordo com o valor do Índice Kappa.

Valor do Kappa	Força da Concordância
< 0,2	Pobre
0,21 - 0,40	Fraca
0,41 - 0,60	Moderada
0,61 - 0,80	Boa
0,81 - 1,00	Muito boa

Fonte: DUARTE (2022), p. 49.

O AcATaMa (sigla para *Accuracy Assessment of Thematic Maps*) segundo informação dos desenvolvedores (SMBYC – IDEAM, SEDATA) é um plugin completo e avançado do QGIS voltado para avaliação da acurácia de mapas temáticos. Ele oferece suporte abrangente para amostragem, definição de respostas e estimativas dentro de uma estrutura de inferência baseada em desenho amostral. Seu principal objetivo é fornecer ferramentas que permitam aos usuários seguir diretrizes internacionais e boas práticas na elaboração de planos amostrais,



estimativas de áreas de categorias de uso da terra e mudanças, bem como na avaliação da acurácia de mapas.

O plugin pode ser utilizado na avaliação de qualquer mapa temático em diversas áreas, como sensoriamento remoto, uso e cobertura da terra, monitoramento ambiental, planejamento urbano, florestal, agricultura, entre outras. Além disso, módulos como os de amostragem e rotulagem podem ser usados de forma independente em diferentes contextos.

O aplicativo foi desenvolvido pelo Grupo do Sistema de Monitoramento Florestal e de Carbono para a validação de mapas únicos de Uso e Cobertura da Terra (LUC). Ele consiste em um conjunto de ferramentas que guiam o usuário através de uma série de etapas: (a) desenho amostral (estratificado ou simples); (b) classificação da amostra; e (c) cálculo da matriz de confusão e estatísticas de acurácia. Na etapa de classificação da amostra, a unidade espacial é um pixel (ou pontos no formato GeoPackage ou shapefile), o que não é muito conveniente para aqueles que preferem usar uma unidade espacial diferente, como grupos de pixels ou polígonos. Nesta etapa (classificação), um conjunto de ferramentas é habilitado para dar zoom em cada uma das amostras, e quatro janelas são criadas para exibir imagens de interesse. Uma tabela de atributos editável também é criada para classificar as amostras (CASTILLO-SANTIAGO *et al.*, 2022)


### 3. MATERIAL E MÉTODOS (OU PROCEDIMENTOS METODOLÓGICOS)

O estudo tem como foco a Sub-Bacia Hidrográfica do Sana (**figura 2**) 6º distrito do município de Macaé (**figura 3**), no Norte do Fluminense. Sana se localiza à 160 quilômetros do Rio de Janeiro.

A ocupação humana da região Norte Fluminense segue a dinâmica da ocupação litorânea e está diretamente ligada aos ciclos econômicos descritos por Furtado (2007) que impulsionaram a formação do território nacional. Integrante da Floresta Atlântica, o Norte Fluminense passou por intensas transformações durante os períodos de exploração da Cana-de-Açúcar (séculos XVI XVII) e do Café (séculos XIX e XX). Nos últimos decênios, a urbanização e o turismo na região se tornaram o principal fator de transformação da paisagem e do uso do solo (JERONYMO & DA SILVA, 2011)


A sub-bacia do Sana é um vale fluvial no interior da Bacia Hidrográfica do Rio Macaé (Ordem 3). O relevo montanhoso é composto de encostas com diferentes tipos de coberturas, mas que variam principalmente entre a Floresta Ombrófila Densa da Serra do Mar e trechos de pastos, solos expostos e afloramentos rochosos (Gerald, 2012, MAGALHÃES *et al.*, 2022). O relevo varia entre 200 metros de altitude próximos da entrada do município, alcançando cotas de até 1820 metros de altitude, segundo dados de STRM. Apesar de trechos com altos índices

de desmatamento, ainda é possível notar a presença da floresta atlântica parcialmente preservada sobretudo no topo dos morros como pode ser observado na **figura 4**.



**Figura 2** - Mapa hipsométrico da sub-bacia do Sana.

Fonte: SILVA *et al* (2012).



**Figura 3** -Mapa de localização do distrito de Sana e da Bacia Hidrográfica de Sana

Fonte: autor.



**Figura 4-** Paisagem montanhosa do Sana.

**Fonte:** Disponível em: [www.freepik.com.br](http://www.freepik.com.br) Acesso em: 13 jun 2025.

A geologia da sub-bacia hidrográfica do Sana, é descrita pelo alinhamento estrutural na direção NE-SW, formada por gnaisses da unidade São Fidelis com idade proterozóica na porção Oeste e Norte da bacia e cortados pela intrusão do granito Sana de idade Cambriana. O Granito Sana é um granitóide pós-tectônico predominantemente leucocrático datado do Pré-Cambriano Superior que possui coloração cinza clara esbranquiçada a branca, granulação fina a média e textura microfanerítica, com a presença de biotita e muscovita (SILVA,2009). Os depósitos colúvio-aluvionar de idade Cenozóica ocorrem em maior quantidade na superfície fluvial do Rio Sana e em menores quantidades na porção Oeste (GERALDES, 2012)

Na região podem ser identificados três tipos de coberturas, “in situ” ou transportadas, que sobrepõe e escondem o substrato rochoso: Aluviões, Seqüência de Blocos e Matacões, e Solos Residuais quaternários (GERALDES, 2012). Os solos da bacia hidrográfica são predominantemente rasos, com os principais tipos sendo Solos Litólicos álicos, Cambissolos álicos, Argissolos Amarelos, Latossolos Vermelho-Amarelos e Neossolos Flúvico (Embrapa, 2000; MAGALHÃES *et al* 2002).

A geomorfologia da bacia do Sana está associada ao domínio tectônico dos Cinturões Móveis Neoproterozóicos, na região das Escarpas e Reversos da Serra do Mar, sendo a parte mais ao Sul da unidade Serra dos Órgãos (DANTAS, 2001). A modelagem do relevo é de dissecação estrutural, processo de modelagem do relevo causado pela interação entre agentes erosivos e as estruturas geológicas subjacentes, como camadas de rochas, falhas e dobras, resultando em topos aguçados (GERALDES,2012)

A região apresenta dois climas principais e um microclima, segundo Köppen. O clima quente e úmido de baixada litorânea, próximo ao tipo AW, tem temperaturas médias anuais de 22,1°C a 22,9°C, com chuvas concentradas no verão e estiagem no inverno. Já o clima quente

e úmido com estação seca pouco pronunciada (Am), típico da Serra do Mar, é um clima de transição com 2.000 mm de precipitação anual e uma estação seca ainda presente. O microclima, classificado como Cfa, ocorre na área serrana devido à altitude elevada (806m), vegetação densa de floresta tropical e proximidade do oceano, gerando neblina densa por condensação noturna da umidade liberada pela vegetação e resfriada pelos ventos marítimos (GERALDES, 2012). Ocasionalmente por conta da rugosidade da superfície existe a intercorrência de chuvas orográficas (MOREIRA E POLIANOV, 2019)

A vegetação da região é marcada por uma cobertura variada, incluindo gramíneas, arbustos e matas, com áreas originalmente cobertas por floresta tropical. No entanto, extensos desmatamentos ocorreram para uso da madeira na construção, mobiliário e produção de carvão vegetal, que consomiram mais de 90% da madeira. Parte das áreas desmatadas é destinada à agricultura, principalmente de mamão e citros. As encostas e baixadas são cobertas por pastagens de gramíneas, com vegetação uniforme e pouca diversidade associada. Restam núcleos isolados de matas virgens, principalmente em encostas íngremes, e áreas de capoeiras e capoeirões, compostas por espécies arbóreas de porte menor e vegetação secundária (GERALDES, 2012) Em relação à cobertura e uso do solo, observa-se áreas de florestas e ocupações em áreas florestais e manejo de pastagens (IBGE, 2022).

A metodologia do trabalho consiste na aquisição de imagens de sensores remotos de domínio público, no pré-processamento, segmentação e classificação das imagens para identificação de feições erosivas seguindo o procedimento metodológico semelhante de Hossu & Pons (2023) e adaptados para as características locais. Com objetivo de comparar qual tipos de classificação seria mais apropriada para o reconhecimento de feições erosivas, as imagens do Cebers-4a foram classificadas de duas formas diferentes: a partir da classificação supervisionada e classificação não supervisionada. Os **quadros 1** e **2** mostram o resumo da metodologia realizada no trabalho.

**Quadro 1** – Fluxograma da metodologia da classificação OBIA

<b>Etapa</b>	<b>Subetapa</b>
<b>1. Aquisição da Imagem</b>	1.1 Acesso ao Catálogos do INPE e aquisição das imagens mais recentes
<b>2. Pré-processamento</b>	2.1 Reprojeter
	2.2 Recortar máscara
	2.3 Fusão das bandas cromáticas
	2.4 Fusão da banda Pancromática (CEBERS-4A)
	2.5 Escolha da composição RGB
	2.6 Ajustes adicionais de brilho e saturação
<b>3. Método OBIA</b>	3.1 Segmentação (OTB)
	3.2 Geração dos campos estatísticos: média, mediana e desvio padrão
	3.3 Selecionar as classes
	3.4 Coleta dos pixels de referência de cada classe
	3.5 Criar arquivo para amostras selecionadas (com campos estatísticos)
	3.6 Treinamento do classificador de vetores OTB (Train Vector Classifier)
	3.7 Geração do modelo (.txt)
	3.8 Classificação do vetor (Vector Classifier)
<b>4. Pós-processamento</b>	4.1 Dissolver vetores classificados
	4.2 Rasterizar os vetores classificados

	4.3 Filtro Majoritário/Minoritário
<b>5. Acurácia</b>	5.1 Rasterização das amostras selecionadas
	5.2 Geração do índice de Kappa

Fonte: Autor.

#### Quadro 2– Fluxograma da metodologia da classificação Kmeans

Etapa	Subetapa
<b>1. Seleção da imagem</b>	1.1 Utilização da imagem pré-processada da etapa anterior
<b>3. Método KMEANS</b>	3.1 classificação automática kmens (OTB)
<b>4. pós-processamento</b>	4.1 filtro majoritário minoritário
<b>5. Acurácia</b>	5.1 Geração de amostras pelo método de amostras estratificadas no AcATaMa
	5.2 Classificação das amostras
	5.3 Reclassificação pela tabela de classes
	5.3 geração de dados de acurácia

Fonte:-Autor.

Os dados da área foram coletados a partir de imagens de CEBERS4A WPM, (resolução de 2 metros no sensor pancromático), domínio público e adquiridas a partir dos sistemas de Catálogo de Imagens do INPE (Instituto de Pesquisas Espaciais). As imagens mais recentes disponíveis sem cobertura de nuvens foi de agosto de 2024. O **quadro 3** abaixo mostra as características dos sensores:

#### Quadro 3- Características espectrais do CEBERS 4A

Característica	Câmera WPM	Câmera MUX	Câmera WFI
Bandas Espectrais	0,45-0,52 $\mu$ m (B)	0,45-0,52 $\mu$ m (B)	0,45-0,52 $\mu$ m (B)
	0,52-0,59 $\mu$ m (G)	0,52-0,59 $\mu$ m (G)	0,52-0,59 $\mu$ m (G)
	0,63-0,69 $\mu$ m (R)	0,63-0,69 $\mu$ m (R)	0,63-0,69 $\mu$ m (R)
	0,77-0,89 $\mu$ m (NIR)	0,77-0,89 $\mu$ m (NIR)	0,77-0,89 $\mu$ m (NIR)
	0,45-0,90 $\mu$ m (PAN)		
Resolução	2 m (pancromática)	16,5 m	55 m
	8 m (multiespectral)		
Largura da Faixa Imageada	92 km	95 km	684 km
Visada Lateral de Espelho	não	não	não
Revisita	31 dias	31 dias	5 dias
Quantização	10 bits	8 bits	10 bits

Fonte: INPE. Disponível em <https://data.inpe.br/geonetwork/srv/api/records/fb195ebd-7664-41f3-93e6-941b9b9dbb26>. Acesso em 14 de jun de 2026.



Os dados de localização do distrito de Sana foram obtidos a partir do georreferenciamento do mapa da hidrografia de Macaé disponível no Plano Diretor Municipal (MACAÉ, 2006) e com o uso de dados da malha municipal disponível no site do IBGE.

Os dados vetoriais referentes à sub-bacia hidrográfica do Sana foram obtidos no SAGA, a partir do Modelo Digital de Elevação- MDE através do sistema TOPODATA do INPE. Os passos para a geração das subacias hidrográficas no SAGA em ambiente do QGIS foram: *Terrain Analysis*, *Fill Sinks* (Wang & Liu), *Channels Network and Drainage Basis*. O resultado gerado foi comparado visualmente com os dados da literatura sobre a sub-bacia do Sana para verificação da qualidade do dado espacial gerado e ilustrado na figura 1..

Na etapa de pré-processamento, foram realizados diversos procedimentos essenciais à preparação dos dados. As imagens foram primeiramente reprojatadas para um sistema de referência espacial EPSG:31983, compatível com a área de estudo, seguida pelo recorte com uma máscara delimitando os limites espaciais de interesse. A máscara foi obtida a partir dos dados vetoriais gerados na delimitação da área de estudo. Posteriormente, houve a fusão das bandas cromáticas, integrando as faixas espectrais visíveis (vermelho, verde e azul), e a fusão com a banda pancromática, que conferiu maior nitidez espacial (resolução de 1.99 metros por pixel) à composição final. A escolha da composição 3-2-1 foi definida conforme a melhor representação visual dos elementos temáticos presentes na paisagem. Além disso, ajustes de brilho e saturação foram aplicados para aprimorar a visualização dos alvos e facilitar a interpretação visual dos dados.

A método utilizado para a classificação supervisionada foi a Análise de Imagens Baseada em Objetos (OBIA) e a classificação não-supervisionada *kmeans* ambos os procedimentos realizados a partir do *Orfeo Toolbox* no Quantum GIS versão 3.40 e a exatidão da classificação foi mensurada a partir do Índice de Kappa para as imagens com classificação supervisionada e do plugin AcATaMa para as imagens não-supervisionadas, ambas as ferramentas executáveis no Qgis.

A classificação baseada em objetos foi conduzida a partir da segmentação da imagem, utilizando o OTB para dividir o raster em regiões homogêneas com base em critérios espectrais, espaciais e texturais. A cada segmento foram atribuídos atributos estatísticos derivados das zonas que compõem os objetos. Neste estudo, utilizou-se o algoritmo *Zonal Statistics*, disponível no software QGIS, para extrair informações espectrais de cada segmento em todas as bandas do sensor CBERS 4A WPM. A extração seguiu o trabalho de Gonçalves et al., (2024) adaptando-se ao contexto da pesquisa. As estatísticas consideradas foram: (1) soma dos valores dos pixels (*sum*); (2) média dos valores (*mean*); (3) mediana (*median*); (4) desvio padrão (*standard deviation*); (5) variância dos valores (*variance*); (6) valor mínimo (*min*); e (7) valor máximo (*max*).

Em seguida, foram definidas as classes temáticas de interesse, de acordo com os padrões de uso e cobertura do solo presentes na área por inspeção visual dos elementos que se destacaram na imagem. Nesta etapa as classes foram definidas de acordo com os tipos de uso e cobertura do solo que mais se destacavam a partir de uma análise visual da imagem. As classes escolhidas foram:



1. Floresta
2. Pasto
3. Solo
4. Urbano
5. Água
6. Rocha
7. Sombra

Foram então coletados pixels de referência representativos de cada classe, utilizados para compor um arquivo de amostras que incluía, além das classes atribuídas, os atributos estatísticos calculados em cada banda.

Com as amostras devidamente organizadas, foi realizado o treinamento do classificador vetorial por meio da ferramenta "*Train Vector Classifier*" do OTB, e o classificador selecionado foi o "*Random Forrest*", o que gerou um modelo de classificação no formato .txt. Esse modelo foi então utilizado para classificar todos os segmentos da imagem por meio da ferramenta "*Vector Classifier*", produzindo o mapa temático com as classes de uso e cobertura da terra.

Após a classificação, procedeu-se ao pós-processamento dos dados. Os vetores classificados foram dissolvidos para unir polígonos contíguos pertencentes à mesma classe, reduzindo a fragmentação dos resultados. Em seguida, os vetores foram rasterizados, convertendo novamente o dado para o formato matricial, e foi aplicado um filtro majoritário-minoritário a partir da ferramenta *SAGA majority/Minority filter* com o objetivo de suavizar ruídos e pequenos pontos residuais da classificação.

Por fim, foi realizada a avaliação da acurácia da classificação. As amostras utilizadas no treinamento foram rasterizadas para permitir a comparação com o produto classificado. Com base nessa comparação, foi calculado o índice *Kappa*, que mensura o grau de concordância entre a classificação e os dados de referência, servindo como parâmetro para avaliar a confiabilidade do mapeamento produzido.

Para melhor compreensão do resultado valor de Kappa obtido pela ferramenta de processamento no Qgis e pelo *plugin* AcATaMa foram calculados manualmente a partir da fórmula de FITZGERALD & LEES (1994) e da matriz de confusão.

A segunda abordagem metodológica adotada neste estudo consistiu na classificação automática da imagem por meio do algoritmo *K-means*, uma técnica não supervisionada amplamente utilizada na análise de dados de sensoriamento remoto pela facilidade do uso. As imagens CEBERS4-A escolhidas foram as mesmas utilizadas na classificação supervisionada OBIA.

O pré-processamento das imagens seguiu os mesmos critérios descritos anteriormente. As imagens foram reprojetaadas para um sistema de coordenadas apropriado, e posteriormente recortadas com base na máscara delimitadora da área de estudo. Realizou-se também a fusão das bandas cromáticas. Em seguida, foi escolhida uma composição RGB 321 com falsa cor semelhante ao real, que se mostrou a mais adequada para a realce dos alvos de interesse, sendo

aplicados ainda ajustes de brilho e saturação para facilitar a interpretação visual e a posterior classificação.

A classificação propriamente dita foi realizada com a ferramenta de classificação K-means disponibilizada no Orfeo Toolbox, dentro do ambiente QGIS. Por se tratar de um método não supervisionado, o algoritmo agrupa os pixels da imagem com base em similaridades espectrais, formando agrupamentos (ou "clusters") sem a necessidade de treinamento prévio com amostras de referência. Esses agrupamentos são posteriormente interpretados e associados a classes temáticas conforme sua correspondência com os padrões visuais identificáveis na imagem.

Diversas configurações de imagem foram utilizadas. Aquela que se mostrou mais adequada foi a organização em dez classes, training set size (5000), maximum of iteration (1000), sampler type (Random). Os outros itens foram deixados com a configuração padrão.

Após a obtenção da imagem classificada em 10 classes foi executado um processo de pós-processamento, com a aplicação de um filtro majoritário-minoritário. Esse filtro tem a função de eliminar pequenas manchas ou ruídos isolados, promovendo uma classificação mais homogênea e coerente com a paisagem real.

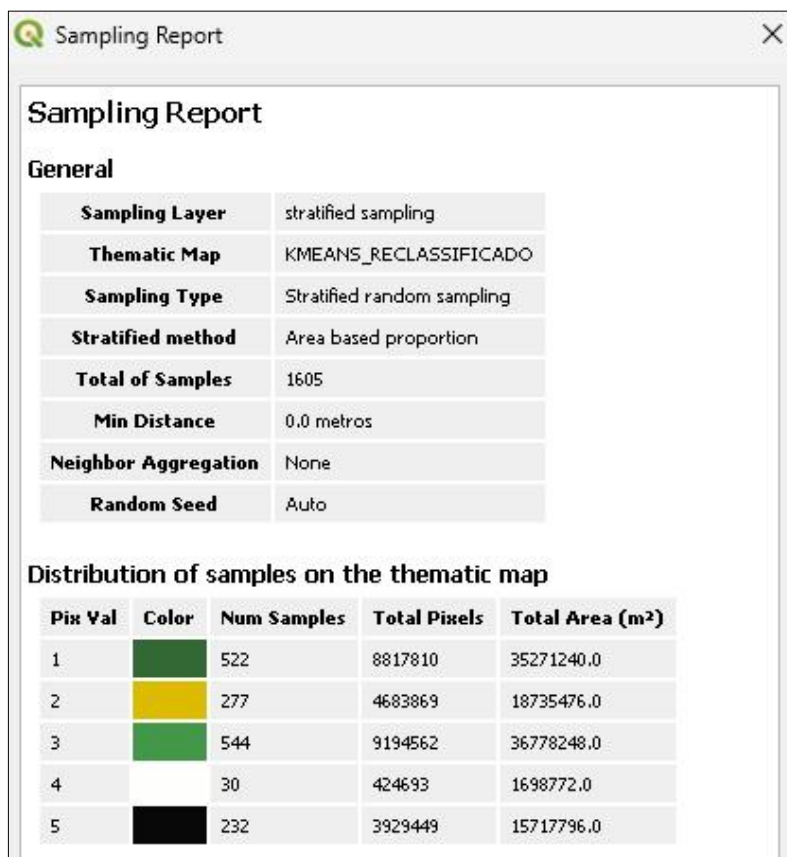
A etapa de teste de acuracidade da imagem obtida pelo *Kmeans* seguiu um caminho distinto, uma vez que não foram geradas amostras que pudessem comparar com a imagem classificada a fim de obter uma matriz de confusão. Logo, essa classificação foi conduzida de forma supervisionada utilizando o plugin AcATaMa, disponível no QGIS. Inicialmente, foi gerado um conjunto de amostras por meio do método de amostragem estratificada, garantindo a representação proporcional de todas as classes identificadas com o total de 1605 amostras distribuídas proporcionalmente de acordo com a quantidade de pixels por classe contabilizadas de forma automatizada pelo programa .

A amostragem dividida em 10 classes geraria um número de amostras muito grande para serem classificadas manualmente. Dessa forma foi realizada uma reclassificação utilizando a tabela raster onde as classes semelhantes foram organizadas em uma única classe e renumeradas, pois o AcATaMa classifica como nula as amostras cujo rótulo é igual à zero. A tabela 4 mostra a tabulação realizada para reclassificar o raster. A **figura 5** mostra o resultado da geração de amostras por estratificação e o **quadro 4** mostra a reclassificação das classes.

Os critérios adotados para a reclassificação foram baseados na configuração da classificação OBIA, composta por sete classes, com ênfase nas feições mais expressivas visualmente. O objetivo foi aproximar o resultado da classificação não supervisionada (K-means) daquele obtido pelo método OBIA, permitindo uma comparação mais coerente entre ambos. Para isso, realizou-se uma inspeção visual detalhada das classes geradas, identificando correspondências temáticas entre as duas classificações.

Como exemplo, a classe "pasto" na classificação *Kmeans* estava fragmentada em três grupos distintos, os quais apresentavam similaridade espectral e visual. Essas três classes foram agrupadas em uma única categoria na reclassificação, consolidando a interpretação temática. De forma geral, a reclassificação promoveu ajustes pontuais em algumas classes secundárias que, embora inicialmente interpretadas como feições distintas pelo algoritmo, revelaram-se

variações resultantes de diferenças de iluminação na cena, especialmente entre áreas de sombra e luz solar direta.








**Sampling Report**

**General**

<b>Sampling Layer</b>	stratified sampling
<b>Thematic Map</b>	KMEANS_RECLASSIFICADO
<b>Sampling Type</b>	Stratified random sampling
<b>Stratified method</b>	Area based proportion
<b>Total of Samples</b>	1605
<b>Min Distance</b>	0.0 metros
<b>Neighbor Aggregation</b>	None
<b>Random Seed</b>	Auto

**Distribution of samples on the thematic map**

Pix Val	Color	Num Samples	Total Pixels	Total Area (m <sup>2</sup> )
1		522	8817810	35271240.0
2		277	4683869	18735476.0
3		544	9194562	36778248.0
4		30	424693	1698772.0
5		232	3929449	15717796.0

**Figura 5-** Relatório do gerador de amostras do plugin AcATaMa.

Fonte: Autor.

**Quadro 4** – Conversão das classes no comando “reclassificar por tabela” do Qgis.

	Mínimo	Máximo	Valor
1	0	0	1
2	2	2	2
3	3	3	3
4	4	4	4
5	5	5	3
6	6	6	1
7	7	7	2
8	8	8	5
9	9	9	3

Fonte - Autor

Dessa forma o raster foi reclassificado em 5 classes identificadas visualmente como

1. Floresta com sombra
2. Pasto
3. Floresta clara
4. Solo, rocha e urbano
5. Sombra e Água.

A amostragem estratificada gerou um total de 1605 amostras proporcionalmente distribuídas de acordo com a quantidade de pixels.

Em seguida, as amostras foram classificadas manualmente com base na interpretação visual no ambiente de classificação do aplicativo. A classificação das amostras gerou um arquivo de pontos com as amostras classificadas e estas amostras foram utilizadas para gerar o índice de Kappa a partir da construção de uma matriz de confusão obtida a partir da tabela do arquivo de pontos no Qgis e organizada manualmente para melhor controle do resultado.

## 4. RESULTADOS

### 4.1 Resultado da Classificação OBIA

A partir dos procedimentos descritos no capítulo anterior foi gerado mapa de classificação pelo método OBIA (**figura 5**) e uma tabela com a matriz de confusão (**quadro 5**), onde foi calculado o índice de Kappa (A imagem foi resultado da rasterização da imagem com os vetores classificados. A diferença entre a imagem orbital, a camada com os vetores classificados e a imagem raster composta a partir da rasterização pode ser consultada **no anexo I**).

Para avaliar a concordância entre os valores classificados pelo modelo e os valores reais, foi utilizado o índice Kappa de Cohen ( $\kappa$ ) (Fitzgerald & Lees, 1994). Esse índice considera tanto a concordância observada quanto a que seria esperada ao acaso. A fórmula é a seguinte:

$$\kappa = \frac{(Po - Pe)}{(1 - Pe)}$$

Cálculo de **Po** (concordância observada) - Somam-se os valores da diagonal principal da matriz de confusão, que representam os acertos do modelo:


$$\text{Total de acertos} = (22.244 + 432.216 + 4.632 + 3.281 + 7.079 + 33.171 + 372.847) = \mathbf{875.470}$$

$$\text{Total de amostras} = \mathbf{934.707}$$

$$Po = \frac{875.470}{934.707} \approx \mathbf{0,9366}$$

Cálculo de **Pe** (concordância esperada ao acaso): -Multiplicam-se os totais reais (linhas) e preditos (colunas) de cada classe e somam-se os produtos:

$$\text{Soma dos produtos} = (557.672.400 + 209.973.616.935 + 74.319.306 + 24.499.320 + 64.819.425 + 3.206.642.025 + 139.255.014.420) = 352.156.583.831$$



**Figura 6-** Mapa de classificação da classificação OBIA.

Fonte: autor.

**Quadro 5** - Matriz de confusão da classificação OBIA

classes	1-floresta	2-pasto	3-solo	4-urbano	5-água	6-rocha	7-sombra	total
1-floresta	<b>22244</b>	73	0	0	0	505	0	22822
2-pasto	305	<b>432216</b>	2545	1033	498	34452	36	471085
3-solo	0	2902	<b>4632</b>	1468	0	456	0	9458
4-urbano	0	59	380	<b>3281</b>	0	0	0	3720
5-água	38	364	0	173	<b>7079</b>	330	143	8127
6-rocha	1833	9997	300	626	398	<b>33171</b>	0	46325
7-sombra	0	0	0	0	0	323	<b>372847</b>	373170
<b>total</b>	24420	445611	7857	6581	7975	69237	373026	<b>934707</b>

Fonte -Autor

Total de amostras ao quadrado =  $(934.707)^2 = 873.672.106.449$

$$P_o = \frac{352.156.583.831}{873.672.106.449} \approx 0,4033$$

Cálculo do índice Kappa:

$$\kappa = \frac{(P_o - P_e)}{(1 - P_e)}$$

$$\kappa = \frac{(0,9366 - 0,4033)}{(1 - 0,4033)}$$

$$\kappa = \frac{(0,5333)}{(0,5967)}$$

$$k \approx 0,8936$$

Portanto, o coeficiente Kappa ( $\kappa$ ) é aproximadamente 0,8936, o que indica uma concordância muito alta entre a classificação feita pelo modelo e os dados reais.

A matriz de confusão apresentada resume os resultados de uma classificação supervisionada de uso e cobertura da terra, com base em sete classes temáticas: floresta, pasto, solo, urbano, água, rocha e sombra. As linhas representam os dados de referência (considerados corretos), enquanto as colunas indicam os dados classificados pelo algoritmo. Os valores na diagonal principal da tabela (destacados em negrito) correspondem aos acertos, ou seja, aos pixels corretamente classificados em cada classe.

A classe "pasto" apresentou o melhor desempenho absoluto, com 432.216 pixels corretamente classificados, seguida por "sombra", com 372.847 acertos, e "floresta", com 22.244. Esses resultados sugerem que o classificador teve um bom desempenho geral, especialmente nas classes com maior quantidade de pixels. A classe "sombra", por exemplo, apresentou tanto uma elevada acurácia do usuário quanto do produtor, com poucos erros de omissão e comissão. Já a classe "urbano", com apenas 3.720 pixels no total, foi a menor do conjunto e, por isso, mais vulnerável a desequilíbrios e erros estatísticos.

A fragmentação das manchas urbanas e a dificuldade de coletar segmentos isolados de estruturas urbanas contribuiu para a baixa amostragem afetando a classificação.

Algumas confusões entre classes, no entanto, chamam atenção. A classe "rocha" foi frequentemente confundida com "pasto" (9.997 pixels) e, em menor escala, com "floresta" (1.833), o que pode estar relacionado à semelhança espectral entre rochas expostas e áreas de vegetação rala. A classe "solo" também apresentou sobreposição com "pasto" (2.902 pixels) e "urbano" (1.468), indicando dificuldades do classificador em distinguir áreas expostas de solo das demais superfícies com cobertura irregular ou baixa reflectância. A confusão entre as classes "solo" e "urbano" também já eram esperadas devido às características dos telhados de arquitetura colonial com diferentes graus de reflectância, ora mais claros e parecidos com a classe "solo".

Um caso clássico de confusão também foi observado entre as classes "água" e "sombra". Embora a maioria dos pixels tenha sido corretamente classificada, houve 143 pixels de água identificados como sombra, e 323 pixels de sombra rotulados como água. Essa troca é comum em imagens ópticas, uma vez que corpos d'água escuros e sombras em relevo ou vegetação densa podem apresentar assinaturas espectrais semelhantes.


A classe "rocha" houve a maior número de amostras classificadas incorretamente. Foram 69237 pixels totais na coluna que representa os dados do classificador. Subtraindo o somatório da coluna do classificador menos os pixels classificados corretamente obtemos o maior valor entre todas as classes que pode ser considerado falso positivo, ou seja  $69237 - 33171 = 36.066$  pixels classificados incorretamente.

Porém, quando observamos a distribuição desses pixels classificados incorretamente no mapa, surge uma nova classe que não esperada: a sombra da floresta, dando o aspecto visual de relevo ao mapa através da configuração de cores claras e escuras.

Esse resultado pode ser considerado um ruído, uma vez que não representa uma classe em si, mas sim a resposta da classificação à diferença de iluminação da imagem, o que pode ser um fator limitante para o uso da metodologia em áreas de estudo com as características semelhantes.

No total, a classe "pasto" foi a mais representativa do conjunto de dados, com 471.085 pixels, seguida por "sombra" (373.170) e "rocha" (46.325). Esse desequilíbrio entre classes pode influenciar as métricas de avaliação, favorecendo as classes mais abundantes e dificultando a correta classificação das menos representadas. Na **figura 6** é possível observar a semelhanças entre a imagem orbital e a imagem classificada.


Esses resultados evidenciam a complexidade envolvida na classificação automática de imagens em áreas com elevada heterogeneidade espectral e grande variação de iluminação. A ocorrência de confusões entre classes com assinaturas espectrais similares, especialmente em regiões de sombra e onde as manchas urbanas estão parcialmente cobertos por vegetação, reforça a importância de estratégias complementares de correção radiométrica e segmentação contextual. Além disso, o desequilíbrio na representação das classes e a fragmentação das manchas urbanas podem indicar o limite do algoritmo quando se trata de pixels isolados e com pouca representatividade, necessitando de maior refinamento nos algoritmos de classificação, especialmente em áreas urbanas e de transição.



**Figura 7** – Comparação entre a imagem orbital (esquerda) e a imagem classificada (direita).  
**Fonte:** Autor.


#### 4.2 Resultado da Classificação Kmeans

A **figura 7** mostra o resultado da classificação não-supervisionada pelo método kmeans. Após diversos testes com diferentes configurações, a que pareceu mais adequada para a imagem CEBERS 4a foi: *number of classes (10)*, *training set size (5000)*, *maximum number of interation (1000)*, *sampler type (random)* *outuput pixel type (int)*. A imagem classificada apresenta mais classes, porém, as organizações dessas classes não responderam às classes reais que poderia ser esperada numa classificação supervisionada. Observa-se, por exemplo, que a classe “pasto” foi dividida de acordo com a diferença de luz. Dessa forma, nota-se dois tipos de classe “pasto”, um pasto “claro” e uma “sombra no pasto”. Houve também a divisão da floresta em floresta “clara” e floresta “sombra”, semelhante ao que houve na classificação supervisionada. Esse resultado já era esperado uma vez que que a classificação estatística não é capaz de perceber aspectos que um classificador consegue inferir ao conduzir uma classificação supervisionada. A reclassificação de dez para cinco classes gerou diferenças principalmente nas classes pasto e floresta. A comparação entre as imagens pode ser verificada na **figura 8**.



**Figura 8** – Mapa de classificação pelo método kmeans.

Fonte: Autor.



**Figura 9.** Comparação entre a imagem antes da reclassificação (esquerda) e depois da reclassificação (direita).

Fonte: Autor.

Em relação à matriz de confusão (**quadro 6**) o índice Kappa foi obtido a partir da seguinte operação:

**Quadro 6.** Matriz de confusão da classificação Kmeans

Classe Real \ Predita	1 (floresta_sombra)	2 (pasto)	3 (floresta)	4 (urbano_solo_rocha)	5 (sombra_agua)	Total
1 (floresta_sombra)	495	0	22	0	23	540
2 (pasto)	7	237	53	18	1	316
3 (floresta)	9	24	462	1	0	496
4 (urbano_solo_rocha)	0	15	3	11	0	29
5 (sombra_agua)	11	1	4	0	208	224
Total	522	277	544	30	232	1605

Fonte: Autor.

O valor de Kappa foi obtido calculando:

$$\kappa = \frac{(Po - Pe)}{(1 - Pe)}$$

#### Cálculo de Po (concordância observada):

Somam-se os valores da **diagonal principal da matriz de confusão**, que representam os acertos do modelo:

$$\text{Total de acertos} = 495 + 237 + 462 + 11 + 208 = 1413$$

$$\text{Total de amostras} = 1605$$

$$Po = \frac{1413}{1605} \approx 0,8807$$

#### Cálculo de Pe (concordância esperada ao acaso):

Multiplicam-se os totais reais (linhas) e preditos (colunas) de cada classe e somam-se os produtos:

$$\text{Soma dos produtos} = 281.880 + 87.532 + 269.824 + 870 + 51.968 = 691.074$$

$$\text{Total de amostras ao quadrado} = (1605)^2 = 2.576.025$$

Logo,

$$Pe = \frac{691.074}{2.576.025} \approx 0,2682$$

Cálculo do índice Kappa:

$$k = \frac{(0,8807 - 0,2682)}{(1 - 0,2682)} \approx \mathbf{0,837}$$

O índice calculado mostra um excelente resultado de classificação, o que pode ser notado em níveis proporção de amostragem. A diferença mais notável é que quando une as diferentes classes de pasto, a classe “solo” se destaca.

A classe que teve o maior número de amostras classificada corretamente foi a classe “floresta sombra” com 495 amostras classificadas corretamente, seguida da classe 3 “floresta” e “pasto” com 237 amostras. A classe onde houve o maior número de classificação incorreta foi a classe “urbano, solo e rocha” com menos da metade das amostras classificadas corretamente. A classe “floresta” apresentou o maior valor de falso verdadeiro, e proporcionalmente foi a classe que mais atribuiu valores incorretos, sobretudo nas classes “floresta sombra” e “pasto”.

Apesar da generalização de classes do classificador automático ter omitido as classes “água” e “urbano”, a classificação geral da imagem é satisfatória para além do valor de Kappa atribuído ao estudo, mas também pela delimitação de determinadas feições que são essenciais para o estudo da área e observadas também na imagem gerada pela classificação supervisionada, gerando resultados distintos, porém, semelhantes nas classes mais representativas..



### 4.3 Identificação de feições erosivas entre os diferentes tipos de classificação

Em ambas as imagens a classe “solo” (onde espera-se encontrar as feições erosivas) possui pixels classificados incorretamente como “pasto”. Na classificação OBIA, das 9458 pixels (100%) selecionados pelo operador 4632 pixels (48,96%) foram classificados corretamente, 2902 (30,68%) foram classificados como pasto e 1468 pixels (15,53%) foram classificados como urbano.

Já para a classificação *kmeans* das 29 amostras reais (100%), 11 foram classificadas corretamente (37,93%) 15 amostras foram classificadas como “pasto”(51,72%) e 3 amostras (10,34%) foram classificadas como “floresta”.

Isso mostra baixa acuracidade da classe “solo” em ambas as classificações, porém em relação à detecção de manchas erosivas, ou seja, a identificação de feições classificadas como “solo” a partir da inspeção visual das imagens, tais feições são facilmente detectadas e há uma relação significativa em ambas as imagens com a classe “pasto” e secundariamente com a classe “urbano”, Embora a classificação OBIA tenha detectado pontualmente a classe “urbano” numa classe distinta de “solo”, a detecção visual de feições erosivas e solo exposto é mais facilmente realizada classificação *kmeans*, como é possível verificar na **figura 9**.

Apesar da baixa acuracidade mostrada pela matriz de confusão, a inspeção visual da imagem mostra claramente as áreas de solo exposto. Enquanto estradas possuem formas lineares e contínuas, as marcas de erosão e as propriedades onde o solo está exposto, seja para construção civil seja para preparação para o cultivo se apresentam como manchas descontínuas pelo espaço.



Com o apoio das imagens do satélite CEBERS-4A e da plataforma *Google Earth*, acessada por meio do plugin *Quick Map Service* no ambiente QGIS, foi possível identificar com clareza diversas feições erosivas distribuídas ao longo da área de estudo. A análise visual dessas feições, em sobreposição com a imagem classificada, evidenciou uma forte correlação entre as áreas de pasto sobre encostas e os locais de ocorrência da erosão. Tal padrão já era esperado, especialmente ao se considerar o histórico de ocupação do território, caracterizado por uso intensivo do solo nas proximidades da rede de drenagem.

A continuidade do uso econômico da terra, embora parcialmente voltado à agricultura, está fortemente marcada pela presença de pastagens. Essas áreas de pasto apresentam diferentes graus de degradação, com sinais visíveis de processos erosivos, resultado de práticas extensivas e, muitas vezes, mal manejadas. Além disso, como apontado no levantamento bibliográfico, a urbanização acelerada na região — impulsionada por projetos de loteamento — tem contribuído significativamente para a degradação do solo. Muitos desses loteamentos, inclusive, ocorrem próximos aos corpos d'água, com destaque para o entorno do rio Sana, o principal afluente da sub-bacia, ampliando os riscos de erosão e degradação ambiental.

Observou-se ainda a presença de solo exposto em áreas de desmatamento recente, geralmente adjacentes a novas construções, o que reforça o papel da expansão urbana desordenada como fator agravante. Essas áreas contribuem não apenas para o aumento da suscetibilidade à erosão, mas também podem influenciar diretamente na qualidade da água e na dinâmica dos cursos d'água da bacia hidrográfica. Nesse contexto, propõe-se que estudos futuros sejam direcionados



à análise da ocorrência de assoreamento nos canais pluviais, já que a elevada presença de feições erosivas nas margens dos rios pode estar relacionada ao aumento do carregamento de sedimentos, comprometendo o equilíbrio hidrológico da região.





**Figura 10** – Comparação entre as imagens classificadas pelo método kmeans. A imagem superior é a imagem CEBERS, a imagem do meio é a classificação pelo método kmeans com dez classes e a imagem inferior é a imagem com método kmeans após a reclassificação em cinco classes.

**Fonte:** autor.

## 5.0 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Ambas as classificações mostraram resultados satisfatórios de acurácia e geraram boas classificações de cobertura de solo, sobretudo em escala de exploração. As maiores classes “floresta” e “pasto” são as mais representativas espacialmente e por isso apresentam os melhores índices de acuracidade. As demais classes foram ofuscadas por causa da fragmentação de suas áreas, das características do relevo montanhoso, da diferença de iluminação na imagem, além de semelhanças entre as classes, como “urbano” / “solo” e “sombra” / “água. Correções na iluminação da imagem podem gerar melhores índices de acuracidade, porém não deve ser o suficiente para melhorar o resultado geral de omissões e confusão entre as classes.

O processo de filtragem na etapa de pós-classificação pode ser útil para a visualização da imagem, porém, podem esconder feições menos representativas.

Estudos comparativos que embasaram o presente trabalho mostram que a classificação OBIA funciona bem em imagens fragmentadas como áreas densamente urbanizadas, porém com uma escala maior e relevo relativamente plano. Para a distinção de tipos de vegetação, como por exemplo diferentes biomas ou feições naturais a classificação OBIA se mostrou eficiente, porém, no presente estudo onde há uma grande fragmentação da mancha urbana, muitas dessas casas entre árvores, e sombra de árvores. mostrou que o algoritmo, ao menos nas configurações testadas não foi capaz de distinguir causando uma forte confusão entre as classes.

Há a possibilidade de fusão de imagens classificadas, o que pode melhorar a classificação final, adicionando as vantagens de cada um dos tipos de classificação: melhor distinção entre as classes (OBIA) e melhor visualização das feições (kmeans).

Em relação à interpretação de uma classe minoritária específica como a classe “solo”, nota-se que as feições erosivas estão localizadas dentro das áreas de pasto, ou seja, áreas de desmatamento e essas regiões ocorrem sobretudo ao longo da drenagem principal da sub-bacia. O desmatamento seguido da urbanização ao longo do Rio Sana, portanto, é apontado como o principal responsável pelas feições erosivas encontradas ao longo da sub-bacia.

A análise geral sugere que, embora o classificador tenha se saído bem, especialmente nas classes com maior número de amostras, há espaço para melhorias. Seria recomendável realizar ajustes mais finos nas classes com características espectrais próximas, como pasto, solo e rocha. O uso de índices espectrais específicos — como o NDVI para vegetação ou o NDBI para áreas urbanas — poderia ajudar a refinar a distinção entre classes confusas. Além disso, a coleta de dados em campo nas áreas mais problemáticas e o aumento da amostragem para classes minoritárias poderiam contribuir para um desempenho ainda mais preciso nas próximas etapas de classificação.



Uma sugestão para a classificação da mancha urbana seria selecionar os trechos das áreas urbanas e realizando a classificação numa escala maior de mais detalhes e posteriormente fundir a imagem classificada com outra feita para uma classificação geral de menor escala.

Estudos posteriores podem utilizar essa metodologia para quantificar as áreas de erosão por meio de uma etapa posterior de seleção das feições e por meio de análise multicritério determinar os demais fatores condicionantes da erosão.

## 6.0 REFERÊNCIAS BIBLIOGRÁFICAS

- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2-16, 2010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271609000884>. Acesso em: 21 ago. 2024.
- BLASCHKE, T.; LANG, S.; HAY, G. J. (ed.). **Object Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications**. Heidelberg; Berlin; New York: Springer, 2008.
- CARVALHO FILHO, A. de; LUMBRERAS, J. F.; SANTOS, R. D. dos. **Os solos do Estado do Rio de Janeiro**. Brasília, DF: CPRM, 2000. 36 p. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/175008/1/Os-solos-do-Estado-do-RJ-2000.pdf>. Acesso em: 25 jan. 2025.
- CASTILLO-SANTIAGO, Miguel Ángel; MONDRAGÓN-VÁZQUEZ, Edith; DOMÍNGUEZ-VERA, Roberto. Sample data for thematic accuracy assessment in QGIS. Land use cover datasets and validation tools, p. 85, 2022.
- CASTRO, U. N. de; NEVES, S. R. de A.; SILVA, L. F. T. C. da; MENDES, S. P.; GUERRA, A. J. T. Mapeamento de feições erosivas e cicatrizes de escorregamento por unidades de relevo na sub-bacia do rio Sana (Macaé–RJ). **Revista de Geografia**, v. especial VIII SINAGEO, n. 3, 2010.
- CERDA L., J.; VALDIVIA, G. John Snow, the cholera epidemic and the foundation of modern epidemiology. **Revista chilena de infectología**, v. 24, n. 4, p. 331-334, 2007. Disponível em: <[www.sochinf.cl](http://www.sochinf.cl)>. Acesso em: 11 fev. 2025.
- CHELOTTI, G. B. Mapeamento de uso do solo da bacia hidrográfica do Alto Descoberto, no Distrito Federal, por meio de classificação orientada a objetos com base em imagem do satélite Landsat 8 e softwares livres. **Revista Brasileira de Geomática**, Curitiba, v. 5, n. 1, p. 172–185, abr./jun. 2017. Disponível em: <https://periodicos.utfpr.edu.br/rbgeo>. Acesso em: [completar data de acesso].
- CORRÊA, C.M.G; DEDECEK, R.A. Erosão real e estimada através da rusle em estradas de uso florestais, em condições de relevo plano a suave ondulado. **FLORESTA**, v. 39, n. 2, p. 381-391, 2009.
- CORREIA, Rui et al. Processamento de imagem para sistemas de informações geográficas (PI2GIS) - Uma ferramenta de aprendizado para QGIS. **Ciências da Educação**, v. 8, n. 2, p. 83, 2018.
- DANTAS, M. E. Estudo geoambiental do Estado do Rio de Janeiro. **CPRM-Serviço Geológico do Brasil**, 2001. 19 p. + mapa color. Disponível em: <rel\_proj\_rj\_geoambiental.pdf>. Acesso em: 11 fev. 2025.



- DANTAS, M. E. Geomorfologia do Estado do Rio de Janeiro. Brasília: **CPRM**, 2001. Mapa. CD-ROM. (Estudo Geoambiental do Estado do Rio de Janeiro).
- DE LUCA G. et al. Object-based land cover classification of cork oak woodlands using UAV imagery and orfeo toolbox. **Remote Sensing**, 11(10):1238, 2019.
- DUARTE, P. G. S. Métodos de Machine Learning Aplicados à Classificação do Uso e Ocupação do Solo na Microbacia do Lago Igapó na Cidade de Londrina/PR. 2022. **Trabalho de pesquisa (Mestrado em Engenharia Ambiental)** – Universidade Tecnológica Federal do Paraná, Londrina, 2022.
- EMBRAPA. Os solos do Estado do Rio de Janeiro. Rio de Janeiro: **Embrapa Solos**, 2000. 79 p. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1090208/1/OssolosdoEstadodoRJ2000.pdf>. Acesso em: 28 jan. 2025.
- FAO – Organização das Nações Unidas para a Alimentação e a Agricultura. Solos saudáveis para as pessoas e para o planeta: FAO pede reversão da degradação do solo. 2022. Disponível em: <https://www.fao.org/brasil/noticias/detail-events/es/c/1472352/>. Acesso em: 9 mar. 2025.
- FITZGERALD, R. W.; LEES, B. G. Assessing the classification accuracy of multisource remote sensing data. **Remote Sensing of Environment**, v. 47, n. 3, p. 362-368, 1994.
- FOLINI, A.; LENZI, E.; BIRAGHI, C. A. Cluster Analysis: a Comprehensive and Versatile Qgis Plugin for Pattern Recognition in Geospatial Data. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 48, p. 151-157, 2022.
- FURTADO, C. Formação econômica do Brasil. 1. ed. São Paulo: Companhia das Letras, 2007. 352 p.
- GERALDES, M. C.; SILVA, L. C. da (Org.). Geologia e recursos minerais da folha Casimiro de Abreu SF.23-Z-B-I, estado do Rio de Janeiro: escala 1:100.000. Belo Horizonte: **CPRM**, 2012. p. 37-39.
- GONÇALVES, Willian Lima; RIBEIRO, Gustavo Siqueira; IMAI, Nilton Nobuhiro. Avaliação de segmentações por métricas espectrais extraídas de imagens multiespectrais do sensor CBERS 4A WPM. **Revista Brasileira de Cartografia**, v. 13, n. 2, p. 108, 2024. Disponível em: <https://doi.org/10.23900/2359-1552v13n2-108-2024>. Acesso em: 08 jun. 2025.
- GRIZONNET, M., MICHEL, J., POUGHON. Orfeo ToolBox: open source processing of remote sensing images. **Open geospatial data, software and standards**, 2, 15 (2017). <https://doi.org/10.1186/s40965-017-0031-6>
- HERNANI, L. C. et al. A erosão e seu impacto. Brasília: **EMBRAPA**, 2002. 14 p. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1124240/a-erosao-e-seu-impacto>. Acesso em: 10 fev. 2025.
- HOSSU, Alex; PONS, Nívea. Inventário de feições erosivas e monitoramento de sua evolução em imagens de satélite CBERS-4A, LANDSAT-8 e SENTINEL-2. 2023.
- JERONYMO, C. A. L.; DA SILVA, J. A. F. Proposta de manejo de paisagem na APA do Sana (Macaé-RJ). **Boletim do Observatório Ambiental Alberto Ribeiro Lamego**, v. 5, n. 2, p. 173-201, 2011.
- KHORRAM, S. et al. Principles of Applied Remote Sensing. Cham: Springer, 2016. 307 p.

MACHADO, Pablo Pin et al. Geoprocessamento aplicado a área de meio ambiente: um estudo de caso baseado em processamento digital de imagens e sensoriamento remoto. **Brazilian Journal of Development**, v. 8, n. 4, p. 23819-23836, 2022.

MACHADO, Pedro LO de A. Carbono do solo e a mitigação da mudança climática global. **Química Nova**, v. 28, p. 329-334, 2005. Disponível em: <https://www.scielo.br/j/qn/a/CB6Dn3MwxgLYNcdmwjYmvZF/?format=pdf>. Acesso em: 3 fev. 2025.

MARQUES, V. S. Erosão hídrica em microbacia utilizando geotecnologias. 2013. 160 f. Tese (Doutorado em Agronomia - Ciência do Solo) - UFRRJ, Seropédica, 2013. Disponível em: <[www.exemplo.com](http://www.exemplo.com)>. Acesso em: 11 fev. 2025.

MCINERNEY, D.; KEMPENEERS, P. Orfeo Toolbox. In: Open Source Geospatial Tools. **Springer**, Cham, 2015. [https://doi.org/10.1007/978-3-319-01824-9\\_13](https://doi.org/10.1007/978-3-319-01824-9_13)

MOREIRA, R. F.; POLIVANOV, H. Determinação dos Parâmetros de Erodibilidade de um Talude de Corte na Sub-Bacia Rio Sana (Macaé, RJ, Brasil). **Anuário do Instituto de Geociências**, v. 42, n. 1, p. 682-694, 2019.

PENARIOL, R. Z.; CASTANHO, R. B. Análise do uso e ocupação do solo do município de Tanabi-SP, no ano de 2020. 2023.

SANTOS, Humberto Gonçalves. dos *et al.* Sistema Brasileiro de Classificação de Solos. 5. ed. rev. e ampl. Brasília, DF: **Embrapa**, 2018. 356 p. Disponível em: <https://www.embrapa.br>. Acesso em: 10 fev. 2025.

SILVA, F. F. et al. O processo erosivo em topossequência de uma encosta situada no alto curso da bacia do rio Sana, Macaé/RJ. 2009.

SILVA, L. F. et al. Degradação ambiental em áreas destinadas à pecuária na sub-bacia hidrográfica do rio Sana, Macaé–RJ. **Revista de Geografia (UFPE)**, v. 29, n. 1, p. 45-59, 2012.

SMBByC – IDEAM. AcATaMa: QGIS plugin for Accuracy Assessment of Thematic Maps. [S.l.]: SMBByC, [2025]. Disponível em: <https://smbyc.github.io/AcATaMa/>. Acesso em: 08 jun. 2025.

SOUZA, F. R. C. de; PAULA, D. P. de. Análise de perda do solo por erosão na bacia hidrográfica do Rio Coreaú (Ceará-Brasil). **Revista Brasileira de Geomorfologia**, v. 20, n. 3, 2019. Disponível em: <https://rbg.emnuvens.com.br/rbg/article/view/1393>. Acesso em: 2 fev. 2025.

WINGE, M. et al. **Glossário Geológico Ilustrado**. Disponível em: <https://sigep.eco.br/glossario/>. Acesso em: 28 jan. 2025.

ZAIDAN, T. R. Geoprocessamento Conceitos e Definições. Juiz de Fora. **Revista de Geografia**, v.7 n.2. 7p. 2017. Disponível em: [https://www.researchgate.net/publication/334651493\\_GEOPROCESSAMENTO\\_CONCEITOS\\_E\\_DEFINICOES](https://www.researchgate.net/publication/334651493_GEOPROCESSAMENTO_CONCEITOS_E_DEFINICOES). Acesso em 02 de jun de 2025.



ATA N° 3647/2025 - CEAD (12.28.01.36)

N° do Protocolo: 23083.040656/2025-54

Seropédica-RJ, 25 de julho de 2025.

#### ATA DE DEFESA

Aos dezessete dias do mês de julho do ano de dois mil e vinte e cinco, às onze horas, através de web conferência, instalou-se a banca examinadora de Trabalho de Conclusão de Curso de Especialização em Geoprocessamento, Levantamento e Interpretação de Solos, do cursista **Cássio Villani dos Santos** sob a orientação do professor **Gustavo Souto Perdigão Granha**. A banca examinadora foi composta pelas professoras/pesquisadoras **Niriele Bruno Rodrigues** e **Mariana Oliveira da Costa**. A defesa do TCC intitulado "**COMPARAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO DE IMAGEM DE CEBERS-4A PARA IDENTIFICAÇÃO DE FEIÇÕES EROSIVAS NA SUB-BACIA HIDROGRÁFICA DO RIO SANA -RJ**", foi iniciada às onze horas e teve a duração de vinte minutos de apresentação seguida da avaliação pela banca. O cursista, após avaliado pela banca examinadora obteve o resultado:

(X) APROVADO, devendo o cursista proceder a eventual revisão solicitada pelo supervisor e /ou pela banca, e entregar a versão final em até quinze dias à coordenação do Curso.

( ) NÃO APROVADO.

Seropédica, 17 de julho de 2025.

**Niriele Bruno Rodrigues**

Primeira Examinadora

**Mariana Oliveira da Costa**

Segundo Examinador

**Gustavo Souto Perdigão Granha**

Presidente

**Cássio Villani dos Santos**

Cursista

*(Assinado digitalmente em 25/07/2025 15:46)*

**GUSTAVO SOUTO PERDIGAO GRANHA**

PROFESSOR DO MAGISTERIO SUPERIOR

DeGEOIM (12.28.01.00.00.87)

Matricula: ###524##

*(Assinado digitalmente em 25/07/2025 12:29)*

**NIRIELE BRUNO RODRIGUES**

ASSINANTE EXTERNO

CPF: ###.###.797-##

*(Assinado digitalmente em 25/07/2025 17:20)*

**MARIANA OLIVEIRA DA COSTA**

ASSINANTE EXTERNO

CPF: ###.###.087-##

*(Assinado digitalmente em 29/07/2025 21:02)*

**CÁSSIO VILLANI DOS SANTOS**

DISCENTE

Matricula: 2024#####0