



GILMAR DE SOUZA SANTOS JUNIOR

**CLASSIFICAÇÃO DE IMAGENS DO SATÉLITE LANDSAT-8
PARA MAPEAR O USO E COBERTURA DA TERRA NO
ESTADO DE RIVAS E A CIDADE DE NANDAIME,
NICARÁGUA**

**LAVRAS – MG
2023**

GILMAR DE SOUZA SANTOS JUNIOR

**CLASSIFICAÇÃO DE IMAGENS DO SATÉLITE LANDSAT-8 PARA MAPEAR O
USO E COBERTURA DA TERRA NO ESTADO DE RIVAS E A CIDADE DE
NANDAIME, NICARÁGUA**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal de Lavras, como parte
das exigências do Curso de Engenharia
Agrícola, para obtenção do título de Bacharel.

Profa. Dra. Elizabeth Ferreira
Orientadora

**LAVRAS – MG
2023**

**CLASSIFICAÇÃO DE IMAGENS DO SATÉLITE LANDSAT-8 PARA MAPEAR O
USO E COBERTURA DA TERRA NO ESTADO DE RIVAS E A CIDADE DE
NANDAIME, NICARÁGUA**

**LANDSAT-8 SATELLITE IMAGE CLASSIFICATION TO MAP LAND USE AND
COVER IN THE STATE OF RIVAS AND THE CITY OF NANDAIME, NICARAGUA**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal de Lavras, como parte
das exigências do Curso de Engenharia
Agrícola, para obtenção do título de Bacharel.

APROVADO em 10 de março de 2023.

Prof Dr. Sergio Teixeira da Silva
Msc. Gleydson Antônio de oliveira Campos

Profa. Dra. Elizabeth Ferreira
Orientadora

RESUMO

A pesquisa teve como objetivo o mapeamento do uso da terra de uma área que abrange o estado de Rivas e o município de Nandaime, que ficam em torno da usina CASUR, Nicarágua, utilizando técnicas de sensoriamento remoto. A construção dos mapas de uso e ocupação da terra e as suas respectivas análises ocorreram a partir da utilização de 7 imagens do satélite Landsat 8, órbita 16052 de 27 de dezembro de 2020, obtidas no *Earth Explorer* (<http://earthexplorer.usgs.gov>). O processo de classificação foi feito aplicando o algoritmo de árvore de decisão *Random Forest*, através do software QGIS, em que foram coletadas as amostras (cana-de-açúcar; plátano; água; vegetação; pastos; outras culturas; área construída, pântano e afloramento rochoso) referentes as classes de uso e ocupação da terra estabelecidas na área de estudo. A opção pelas referidas classes considerou os elementos mais representativos da área de estudo. Os resultados demonstraram que as classes de uso e cobertura do solo com maior extensão foram as vegetações, com cerca de 62,57% de toda a área de estudo. Conclui-se que o estudo foi eficaz devido à geração de confiabilidade nos resultados na classificação por meio da matriz de confusão e inclusão do intervalo de confiança.

Palavras-chave: Sensoriamento remoto. Uso da terra. Classificação Supervisionada.

ABSTRACT

The research aimed to map the land use of an area covering the state of Rivas and the municipality of Nandaime, which are located around the CASUR plant, in Nicaragua, using remote sensing techniques. The construction of the land use and occupation maps and their respective analyzes took place with 7 images from the Landsat 8 satellite, orbit 16052 of December 27, 2020, obtained in Earth Explorer (<http://earthexplorer.usgs.gov>). The classification process was done by applying the algorithm of, through the QGIS software, in which samples were collected (sugarcane; sycamore; water; vegetation; pastures; other crops; built-up area, swamp, and a rocky outcrop) referring to the classes of land use and occupation established in the study area. The option for these classes is considered the most representative element in the study area. The results demonstrated that land use and land cover classes with the greatest extension were vegetation, with about 62.57% of the entire study area. It is concluded that the study was effective due to the generation of reliability in the results in the classification through the confusion matrix and inclusion of the confidence interval

Keywords: Remote sensing. Land use. Supervised classification.

LISTA DE ILUSTRAÇÕES

Figura 1 — Caminho da radiação eletromagnética.	11
Figura 2 — Assinatura espectral de alvos.	12
Figura 3 — Diferentes camadas de informações em um GIS, empilhadas.	13
Figura 4 — Imagem representativa do Satélite Landsat 8.	13
Figura 5 — Exemplo de Árvore de decisão do Random.	16
Figura 6 — Matriz de Confusão.	17
Figura 7 — Localização da área de estudo.	20
Figura 8 — Características do MDE adquirido.	21
Figura 9 — Imagens englobando área de estudo.	21
Figura 10 — MDE recortado para área de estudo.	22
Figura 11 — Procedimentos realizados para elaboração do mapa de uso e cobertura da terra através da classificação supervisionada.	24
Figura 12 — Teste de acurácia realizado no AcATaMa, um módulo de extensão do Qgis	25
Figura 13 — Mapa de declividade da área de estudo	26
Figura 14 — Mapa de Hipsométrico da área de estudo.	26
Figura 15 — Uso e cobertura da terra no estado de Rivas e a cidade de Nandaime, Nicarágua.	27
Gráfico 1 — Área estimada das classes.	30
Quadro 1 — Classes de uso e ocupação da terra.	23

LISTA DE TABELA

Tabela 1 — Especificações técnicas do sensor OLI Landsat 8... ..	14
Tabela 2 — Matriz de confusão	27
Tabela 3 — Apresenta a matriz de conclusão baseada na área de cada classe.....	28
Tabela 4 — Acurácias do produtor e do usuário, de acordo com a matriz de confusão baseada na área de cada classe.	28
Tabela 5 — Erro padrão da estimativa da área.....	29
Tabela 6 — Área estimada das classes em hectares.....	30

SUMÁRIO

1 INTRODUÇÃO	9
1.1 Justificativa	9
2 OBJETIVOS	10
2.1 Objetivo geral	10
2.2 Objetivos Específicos.....	10
3 REFERENCIAL TEÓRICO	10
3.1 Sensoriamento remoto	10
3.2 Radiação Eletromagnética.....	11
3.3 Comportamento Espectral dos Alvos	12
3.4 O Sistema de Informação Geográfica (SIG)	12
3.5 Sensor OLI / Landsat 8.....	13
3.6 Mosaico e Recorte de Imagens	15
3.7 Uso e cobertura da terra	15
3.8 Classificação de Imagens em sensoriamento remoto	15
3.9 Método de classificação Random Forest	16
3.10 Acurácia de classificação e qualidade de dados	16
3.10.2 Matriz de Confusão composta por erro padrão	17
3.10.3 Acurácia global.....	18
3.10.4 Acurácia do produtor e usuário.....	18
3.10.5 Intervalo de confiança.....	19
4 METODOLOGIA	19
4.1 Caracterização da área de estudo	19
4.2 Relevo e Hipsometria	20
4.3 Download e importação de imagens orbitais	22
4.4 Definição das classes de uso e ocupação da terra	22
4.5 Amostras de treinamento.....	23
4.6 Classificação Supervisionada	23
4.7 Validação.....	24
5 RESULTADOS E DISCUSSÕES	25
6 CONCLUSÃO	31
REFERÊNCIAS.....	31

1 INTRODUÇÃO

Mapeamentos temáticos desempenham um papel importante na geração de informações da superfície terrestre, que são utilizados para fins políticos, científicos e de gestão (STEHMAN, 2009). Fazendo análise dessas informações é possível produzir dados, gerando mapas temáticos que possuem diversas classes, sendo extremamente úteis para gerenciar e acompanhar as dinâmicas e comportamento da área de estudo.

Através da utilização de imagens de satélites é possível realizar uma classificação de uso e cobertura da terra, tendo como ferramenta principal algoritmos de árvore de decisão, que funciona por meio da divisão de um conjunto de dados em subconjuntos, dentre a sua principal vantagem, se destaca a fácil interpretação dos seus resultados, pois a classificação é obtida de forma explícita, simplificando a sua interpretação. Assim, o uso de Sistemas de Informações Geográficas (SIG), tornam-se fundamental na obtenção de informações e registros da área de estudo.

O sensoriamento remoto permite por meio de técnicas, o mapeamento do uso da terra de forma rápida e precisa, permitindo a identificação de áreas e seu monitoramento (ENGELBRECHT; HEINE; MAHEMBE, 2017), além disso, ele possibilita a aquisição de imagens, por meio da energia refletida ou emitida da superfície terrestre.

Com o planejamento territorial é possível obter informações sobre a região, permitindo assim a usina Casur promover ações que visem a ordenação do espaço em torno da área de plantação de cana-de-açúcar, visando melhorias e aumento da produção, além disso, por meio da classificação do uso e cobertura da terra é possível ter um conhecimento geral sobre a região, podendo gerar informações que levam a apontamentos sobre o principal viés econômico da área classificada.

Neste trabalho foi utilizado o algoritmo de árvore de decisão denominado Random Forest. De acordo com Pal (2005), esse é um dos algoritmos mais utilizados para uso e cobertura da terra, pois tem alta capacidade de atingir grandes acurácias.

1.1 Justificativa

O principal problema envolvido neste trabalho é a dificuldade da empresa CASUR é

não possuir um mapeamento de uso e cobertura da terra ao longo das suas áreas de plantio de cana-de-açúcar. A falta desses dados inviabiliza tomadas de decisões em possíveis expansão das suas áreas plantadas.

2 OBJETIVOS

2.1 Objetivo Geral

O objetivo geral deste trabalho foi a criação de um mapa temático analisando a dinâmica do uso e cobertura da terra, para o estado de Rivas e a cidade de Nandaime, na Nicarágua, através de técnicas de Sensoriamento Remoto.

2.2 Objetivo específico

- Realizar a classificação da cobertura da terra a partir de um algoritmo de decisão;
- Gerar mapas temáticos de cobertura da terra da área de estudo;
- Realizar a análise de acurácia da classificação supervisionada;
- Fornecer dados que contribuem para a empresa CASUR, e para a sociedade Nicaraguense.

3 REFERENCIAL TEÓRICO

3.1 Sensoriamento remoto

Dentre as ferramentas que mapeiam a cobertura da terra estão os produtos do sensoriamento remoto, sendo esses, obtidos por sistemas de informações geográficas e plataformas orbitais.


Segundo Jamet (2009) pode definir o sensoriamento remoto como a coleta de dados sem contato físico com o objeto. Enquanto, Rocha (2000) menciona que o sensoriamento remoto, é a utilização de dispositivos a bordo de satélites ou aeronaves, permitindo que haja transmissão de informações, para que se estude o ambiente da superfície da Terra.

Com o passar dos tempos, com o avanço da tecnologia, começaram a surgir sensores mais potentes fazendo com que as imagens obtidas apresentassem resoluções cada vez melhores, isso faz com que seja aumentada sua utilização em diversas áreas do conhecimento, possibilitando o monitoramento em grande escala.

3.2 Radiação Eletromagnética

Segundo Novo (1989), todas as informações obtidas por um sensor são de origem eletromagnética, no processo ocorre a captação pelo sensor das ondas eletromagnéticas sejam elas refletidas ou emitidas por um objeto, sendo essas geradas por fontes como o sol, ou até mesmo fontes artificiais.

Figura 1 — Caminho da radiação eletromagnética.



Fonte: Queiroz (2003).

Os sensores recebem informações resultantes da interação de energia eletromagnética com os objetos, que estão na superfície da terra. Na Figura 1 pode ser verificado esse fenômeno. Os sensores podem ser classificados de acordo com sua resolução espacial, fonte e radiação e sistema de registro, possuindo características próprias como, resolução radiométrica, temporal, espectral e espacial.

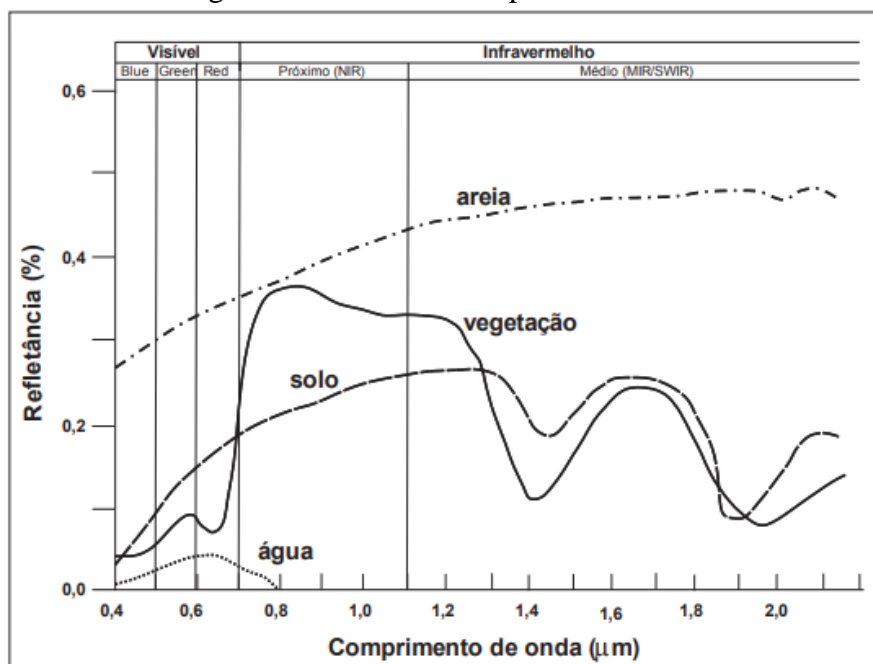
3.3 Comportamento Espectral dos Alvos

Existe uma assinatura espectral para cada alvo presente no ambiente terrestre, isso porque, a radiação solar incidente interage de modo diferente com cada um, ou seja, absorve ou reflete de maneira diferente cada uma das faixas do espectro da luz incidente (GARRIDO, 2014).

Nesse sentido, através dessa interação a radiação deixa os alvos e o que chega nos satélites são as suas assinaturas espectrais, pois estes diferentes materiais são caracterizados por refletâncias próprias em cada banda do espectro.

Cada material possui a sua curva típica que é denominada assinatura espectral e que contém um padrão, sendo assim, possível identificar os alvos. A Figura 2 demonstra as formas que os materiais refletem a radiação eletromagnética.

Figura 2 — Assinatura espectral de alvos.



Fonte: Novo (2010).

3.4 O sistema de informação geográfica (SIG)

Segundo Davis e Câmara (2001), Sistema de Informações Geográficas (SIG) é designado para captar informações, realizando um tratamento computacional, tendo essas informações através da localização espacial ou alfanuméricas. O SIG é composto por um software que realiza a coleta, processamento e analisando os dados com o auxílio de operações matemáticas.

Os dados utilizados em um SIG podem ser divididos em dois diferentes grupos, dados gráficos, que descrevem as características da superfície da terra e não gráficos, ou alfanuméricos que descrevem atributos contidos nessas características (ROCHA,2000).


Os dados gráficos e não gráficos são divididos em vetoriais e matriciais (FIGURA3):

- Dados vetoriais: Representam a localização de um objeto do mundo real, sendo

dividido entre pontos, linhas e polígonos;

- Dados matriciais: Representam a associação de valores permitindo que seja reconhecido objetos por meio de uma imagem digital.

Figura 3 — Diferentes camadas de informações em um GIS, empilhadas.



Fonte: National Coastal Data Development Centre (NCDDC), National Oceanic and Atmospheric Administration (NOAA), EUA.

3.5 Sensor OLI / Landsat 8

O Satélite Landsat 8 (FIGURA 4), foi lançado em 2 de novembro de 2013 pela National Aeronautics and Space Administration (NASA), possui 2 sensores: Thermal Infrared Sensor (TIRS), que tem a função de medir a temperatura superficial da terra utilizando duas bandas espectrais na faixa do infravermelho termal, tendo uma resolução de 100 m (NASA, 2020), além do Operational Land Imager (OLI) que contém bandas nas faixas do visível, infravermelho próximo e infravermelho de ondas curtas, tendo uma resolução de 30 m e 15 m.

Figura 4 — Imagem representativa do Satélite Landsat 8



Fonte: Nasa (2013).

Tabela 1- Especificações técnicas do sensor OLI Landsat 8

Nº da banda	Faixa espectral	Sensor	Resolução
1	0.43 - 0.45 (coastal blue)	OLI	30 m
2	0.45 - 0.51 (blue)	OLI	30 m
3	0.53 - 0.59 (green)	OLI	30 m
4	0.64 - 0.67 (red)	OLI	30 m
5	0.85 - 0.88 (NIR)	OLI	30 m
6	1.57 - 1.65 (SWIR-1)	OLI	30 m
7	2.11 - 2.29 (SWIR-2)	OLI	30 m
8	0.50 - 0.68 (PANCROMÁTICA)	OLI	15 m

Fonte: U.S. Geological Survey (USGS).

3.6 Mosaico e Recorte de Imagens

O mosaico de imagens é necessário quando a área de estudo está localizada em uma ou mais cenas de imagens de satélites, fazendo esta operação para juntar em um só arquivo de imagem. O recorte de imagens delimita a região de estudo por meio do uso de máscara. Neste procedimento os pixels que não fazem parte de interesse são desconsiderados e excluídos.

3.7 Uso e cobertura do solo

Segundo Turner (1994), o uso e cobertura da terra podem se entendidos de forma diferente, enquanto cobertura da terra é caracterizado pelos estados físicos, químicos e biológicos da superfície da terra, o termo uso da terra refere-se aos propósitos humanos associados a uma determinada cobertura, como por exemplo, pastagens.

Existem duas formas de ocorrer mudanças no uso e cobertura da terra, conversão de uma classe de uso para outra, como por exemplo vegetação para pastagens, ou mudança dentro da mesma classe, como por exemplo áreas de alguma cultura agrícola específica sendo passado pra outra.

Nesse sentido, os estudos em função do uso e cobertura da terra obteve nos últimos anos um grande auxílio do sensoriamento remoto, tornando importantes ferramentas para o monitoramento de mudanças, conseguindo retratar impactos ocorridos nos elementos naturais, além de auxiliar na gestão territorial.

3.8 Classificação de Imagens em Sensoriamento Remoto

De acordo com Crosta (1999) a classificação de imagens extrai as informações de uma imagem e associa cada pixel a um determinado “rótulo”. Os valores de refletância ou número digitais dos pixels são agrupados em classes que tem valores semelhantes, aplicando regras de decisões que formaram agrupamentos, este processo é baseado em estatística e algoritmos.

A classificação de imagens pode ser efetuada de forma supervisionada e não supervisionada. Na classificação não-supervisionada um algoritmo de agrupamento que realiza a tomada de decisão de quais classes serão separadas e agrupadas em conjuntos. Ao contrário desta a classificação supervisionada necessita-se de amostras de treinamento para cada classe, que é fornecida ao sistema de classificação pelo analista (REDDY, 2008).

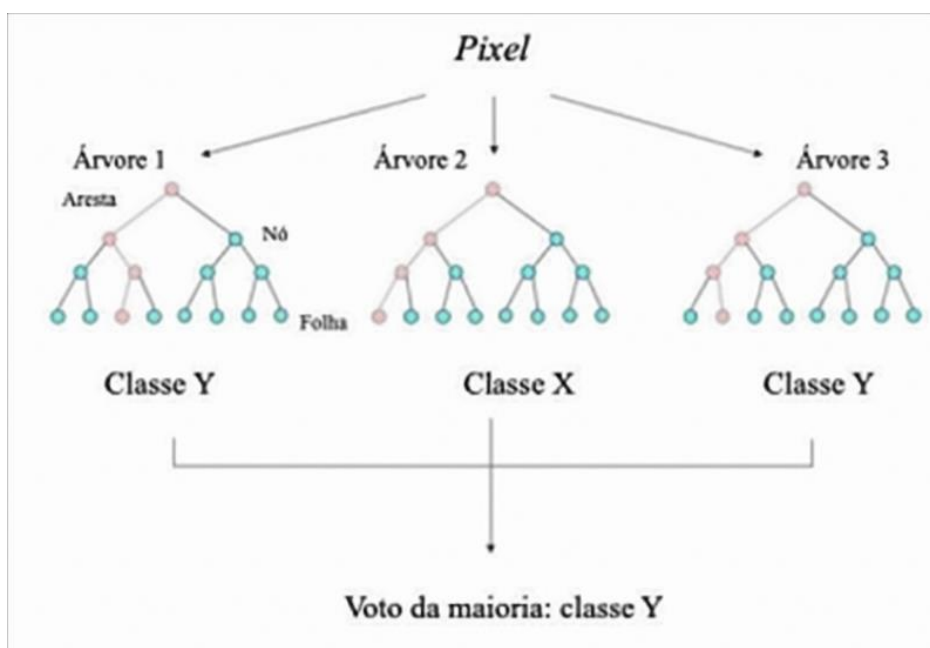
3.9 Método de classificação Random Forest

O algoritmo de árvore de decisão Random Forest ou florestas aleatória, proposto por Breiman (2001), combina várias árvores de decisão (FIGURA 5) por meio de conjuntos de atributos escolhidos aleatoriamente em detrimento ao conjunto original, para produzir classificações precisas (NETO,2014), ou seja, são selecionados atributos dentro de algumas amostras, sendo a quebra desses dados e a formação de novos subconjuntos que originam a árvore de decisão. Segundo Dantas (2015) cada conjunto de árvores é passado por um meio

de votação denominado *bagging*, que elege a classificação mais votada.

Segundo Gouveia (2021) na classificação de imagens digitais o RF testa cada brilho de cada pixel em cada banda espectral nos “nós de decisão” presentes nas diversas árvores de decisão, sendo que os intervalos característicos das classes aprendidos durante o treinamento orientem o modelo final. Esse algoritmo é um classificador amplamente utilizado com dados de sensoriamento remoto.

Figura 5 — Exemplo de Árvore de decisão do Random



Fonte: Adaptado de Firmin (2019).

3.10 Acurácia de classificação e qualidade de dados

A análise de acurácia é feita pela comparação entre a classificação produzida e uma referência. A comparação dos dois dados se faz por meio de distribuição de pontos amostrais, seguindo um método estatístico para distribuição das amostras (FOODY,2002). A aquisição de dado de referência na análise estatística é necessária, para isso esses dados são obtidos por meio de pontos coletados em imagens de satélites, em solo ou por fotografia aérea.

3.10.1 Matriz de confusão

A matriz de confusão é um modo eficaz de representação da acurácia, nela compara-se os dados de referência, representados normalmente pelas colunas com os dados classificados, normalmente representados pelas linhas. Assumindo que n_{ij} representa o número de amostras atribuídas na classe i ($i = 1, 2, 3, \dots, k$) no conjunto de dados de classificação j ($j = 1, 2, 3, \dots, k$) no conjunto de dados de referência. Temos que n_{ii} representa os elementos classificados corretamente (frequência observada na diagonal), n_{i+} representa os elementos classificados para uma categoria i (coluna marginal), e n_{+i} representa o total de elementos de referência amostrados para uma categoria i .

Figura 6 — Matriz de Confusão

		j = Colunas (Referência)			Total de Linhas n_{i+}
		1	2	k	
i = Linhas (Classificação)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Total de Colunas n_{+j}		n_{+1}	n_{+2}	n_{+k}	n

Fonte: Adaptado de Congalton & Green (1999).

3.10.2 Matriz de confusão composta por erro padrão

Quando a matriz de confusão não incorpora o erro padrão com base na área total de cada classe, essas estimativas podem ser distorcidas, esses fatores afetam a precisão total de área representada pelas classes. Essa matriz inclui uma proporção de área para cada classe com base na sua área. Para isso, tem -se que encontrar o peso do estrato, representado pela equação 1.

$$Wi = \frac{A_c}{A_t} \quad (1)$$

Onde: Wi = Peso do estrato A_c = Área de cada classe em hectares; A_t = Área total de todas as classes em hectares.

O cálculo da proporção da área para cada classe é pela equação 2:

$$Wn = Wi * \frac{n_i}{n_s} \quad (2)$$

n_i = Valor do ponto de referência na linha da matriz de confusão para cada; n_s = Valor da soma do ponto de referência de cada classe da matriz de confusão.

É necessário calcular o erro padrão para cada classe, para posteriormente seja calculado o intervalo de confiança, como foi utilizado o tipo de amostragem aleatória estratificada, a equação é:

$$EP = \sqrt{\sum_{i=1}^n \frac{Wi * Wn_{ij} - Wn_{ij}^2}{n_{i+} - 1}} \quad (3)$$

Onde EP = Erro padrão; Wi = Peso do estrato de cada uma das classes; Wn_{ij} = Valor da proporção de cada linha e coluna da matriz de confusão; n_{i+} = representa o número de pontos de referência atribuídos em uma classe i ;

3.10.3 Acurácia global

A acurácia global tem como principal objetivo medir o percentual entre os dados de classificação e referência, por meio da soma da diagonal principal da matriz dividindo o valor pelo total de amostras Story e Congalton (1986).

$$AG = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (4)$$

Onde: que n_{ii} = representa os elementos classificados corretamente (frequência observada na diagonal), n = Total de amostras.

3.10.4 Acurácia do produtor e usuário

A acurácia do produtor identifica a probabilidade de uma classe ser classificada com

relação aos pontos de referência, além disso, está relacionada com os erros de omissão que relaciona dados de classes que deveriam ser detectados, mais por algum motivo foram omitidos da classificação. Pode-se ser calculado por:

$$Ap = \frac{n_{ii}}{\sum n_{i+}} \quad (5)$$

Onde: n_{ii} = Elementos da diagonal principal da matriz de confusão; n_{i+} = Soma da linha da matriz de confusão para cada classe temática.

A acurácia do usuário identifica a probabilidade de uma classe classificada representar a mesma em campo, além disso, está relacionada ao erro de comissão que informa a quantidade de classificações relacionadas com resultados falsos positivos. Pode-se ser calculado por:

$$Au = \frac{n_{ii}}{\sum n_{+i}} \quad (6)$$

Onde: n_{ii} = Elementos da diagonal principal da matriz de confusão; n_{+i} = Soma da coluna da matriz de confusão para cada classe temática.

3.10.5 Intervalo de confiança

O intervalo de confiança pode ser definido como a determinação de um limite inferior e superior, onde o valor verdadeiro de interesse irá variar de acordo com um nível de significância estabelecido por Cochran (1999). Neste trabalho o valor de interesse é a área das classes temáticas classificadas.

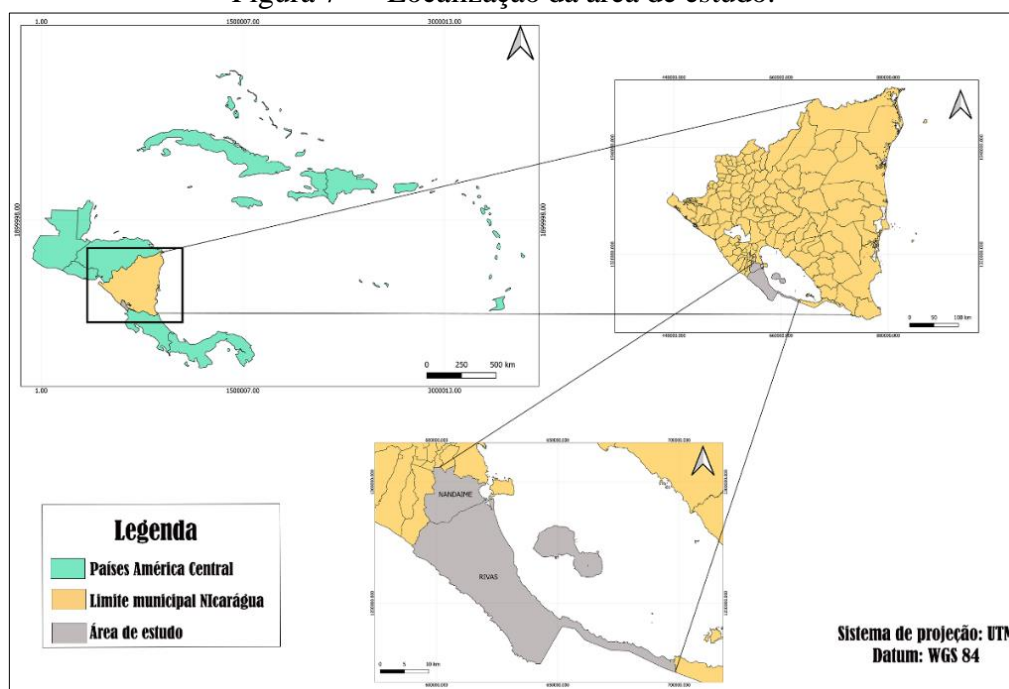
4 METODOLOGIA

4.1 Caracterização da área de estudo

A área de estudo em questão é o departamento de Rivas e a cidade de Nandaime na Nicarágua. O departamento de Rivas está localizado na região do Pacífico Sul da

Nicarágua, limitada ao norte pelos departamentos de Granada e Carazo, ao sul pela Costa Rica, a leste pelo Lago Cocibolca e a oeste com o Oceano Pacífico, possui uma área de 21.618.200 Hectares, o que equivale a 1,7% do território nacional, sua população é de 174.589 habitantes que representam 3% da população do país, 64% da população é rural. A cidade de Nandaime se localiza no estado de Granada e se limita com o departamento de Rivas ao Sul, possui uma área de 37.185 Hectares.

Figura 7 — Localização da área de estudo.



Fonte: Autor (2022).

4.2 Relevo e Hipsometria

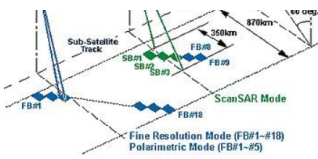
Os dados referentes ao Relevo e Hipsometria foram obtidos por meio de MDE's (modelos digitais de elevação), uma vez que, cada pixel contém um atributo do valor de elevação do terreno em relação a um referencial.

A configuração morfológica do local é importante para caracterizar as formas e o que está contido na superfície. O relevo pode restringir o uso da terra devido sua forma, prejudicando o processo rural e urbano, neste sentido, foi adquirido 4 imagens de MDE's.

O MDE's foi adquirido por meio de imagens do sensor PALSAR do satélite ALOS (Advanced Land Observing Satellite), sendo este lançado em 2006 pela missão da agência de exploração aeroespacial japonesa (Japan Aerospace Exploration Agency-JAXA). Estes MDE's foram adquiridos gratuitamente, já corrigidos e projetados no sistema UTM WG,

com uma resolução de 12 metros. A Figura 8 representa as características do material adquirido, a Figura 9 e 10 representam a exportação destas imagens para o software QGIS, e o recorte feito com base na área de estudo, respectivamente.

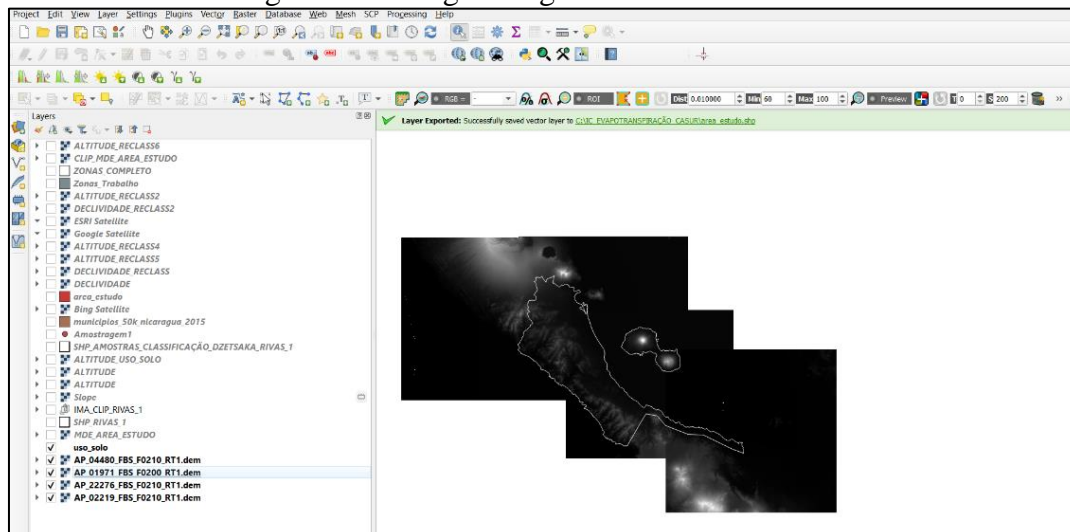
Figura 8 — Características do MDE adquirido



	Resolução fina		ScanSAR	Polarimétrico
Modo de feixe	FBS, DSN	FBD	WB1, WB2	PLR
Frequência central	Banda L (1,27 GHz)			
Polarização	HH ou VV	HH+HV ou VV+VH	HH ou VV	HH+HV+VV+VH
Resolução espacial	10 m	20 m	100 m	30 m
Largura da faixa	70 km	70 km	250-350km	30 km
Ângulo fora do nadir	34,3° (padrão)		27,1° (padrão)	21,5° (padrão)

Fonte: Autor (2022).

Figura 9 — Imagens englobando área de estudo.



Fonte: Autor (2022).

Figura 10 — MDE recortado para área de estudo



Fonte: Autor (2022).

4.3 Download e importação de imagens orbitais

A construção do uso e ocupação da terra e suas análises ocorreram a partir da utilização das imagens do satélite LANDSAT 8, sensor OLI, órbita 16052, de 27 de dezembro de 2020, na página do *Earth Explorer* (<http://earthexplorer.usgs.gov>), sendo selecionada, pois possuía maior nitidez e menor quantidade de nuvens.

4.4 Definição das classes de uso e ocupação da terra

O processo de classificação das imagens realizou-se por meio da utilização do *software QGIS*, onde foram escolhidas as classes e coletadas amostras referentes as classes de uso e ocupação da terra estabelecidas na área de estudo, que estão representadas na Quadro 1.

Quadro 1-Classes de uso e ocupação da terra

Classe	Descrição
Vegetação	Áreas de cobertura vegetal de características naturais, compostas principalmente pela mata ciliar, coberturas arbóreas, além de bosques latifoliados;
Água	Espelhos d'água das lagoas ou de rios, o que não incluem áreas alagadas temporárias, que está representada com a classe pântano.
Pastos	Consistem naquelas áreas com o cultivo de pastagem onde ocorre a prática da pecuária extensiva, além de pastagem degradadas, onde não ocorrem muitos cuidados com a vegetação, podendo conter gramíneas até a presença de arbustos ou algumas árvores de maior porte.
Zona Construída	Áreas construídas para ocupação urbana e aglomerados, estradas e rodovias, além de solos preparados para construção civil em áreas urbanas ou rural.
Cana-de-açúcar:	Áreas que contém essa cultura, sua maior parte se encontra nas propriedades da usina Casur.
Plátano	Áreas que se tem plantações dessa fruta, depois da Cana-de-açúcar é a principal cultura em área produzida na região.
Outros Cultivos	Áreas que representam culturas que não estão contidas nessas classes, tais como: limão e trigo.
Pântano	Áreas alagadas temporárias, lagunas e reentrâncias costeiras, em encontros de águas de rios e mar.
Afloramento Rochoso	: Áreas com exposição de rochas na superfície da Terra.

Fonte: Autor (2022).

4.5 Amostras de treinamento

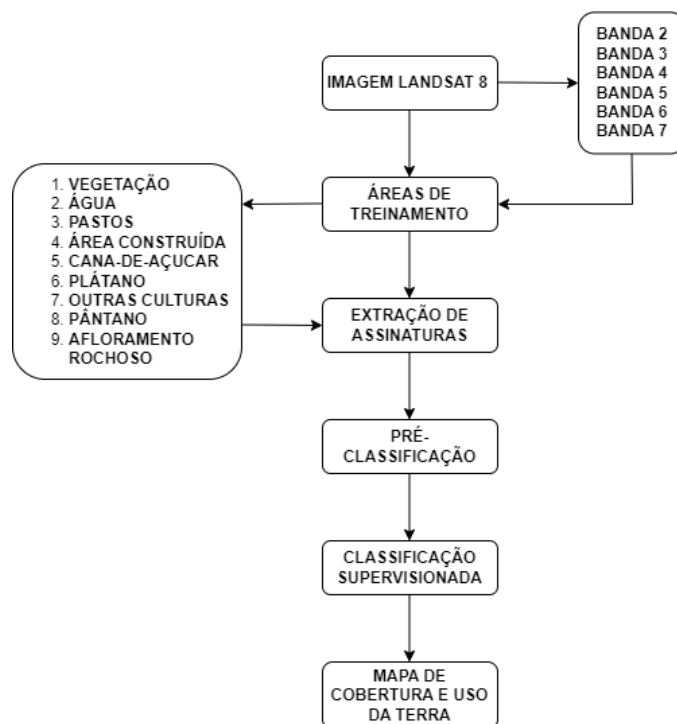
Para realizar as amostras das classes foi criado um vetor, e dentro deste realizou-se em cada polígono as amostras, sendo que para cada classe houve uma coleta de aproximadamente 50 amostras. O procedimento para classificação da imagem ocorreu mediante o uso do plugin disponibilizado pelo *QGIS 3.4* conhecido como *Dzetsaka Classification Tool*, as imagens de satélite, já em composições RGB, e o vetor que foi criado com as amostras, onde continha as informações das classes selecionadas de forma manual, o processamento do algoritmo.

4.6 Classificação Supervisionada

Posteriormente para realizar a etapa de classificação selecionou-se a opção de classificação supervisionada através do algoritmo de árvore de decisão *Randon Forest*. Assim, sendo gerada a imagem raster que indica de forma separada as áreas do mapa que correspondem a cada classe do uso e ocupação do solo no qual foi indicado anteriormente. Após a classificação viu-se a necessidade de realizar uma etapa de suavização do raster de classificação, esta etapa foi feita por meio de uma ferramenta que está dentro do plugin *SCP (semi automatic classification plugin)*, gerando um novo raster, estando as informações mais organizadas, após isso, aplicou-se a ferramenta de convenção de raster para vetor, facilitando

assim o manuseio das informações e análises. Na Figura 11 está esquematizado um fluxograma de pesquisa que representa as etapas para realizar a classificação.

Figura 11 — Procedimentos realizados para elaboração do mapa de uso e cobertura da terra através da classificação supervisionada.



Fonte: Autor (2022).

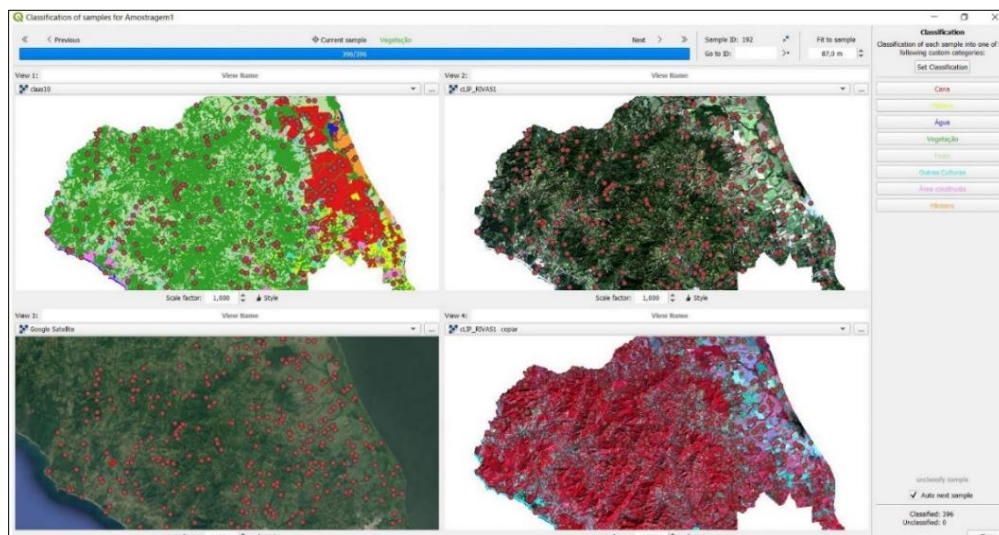
4.7 Validação

Os dados de referência deste trabalho foram obtidos pelo *software QGIS*, utilizou-se da plugin *AcATaMa - Accuracy Assessment of Thematic Maps*. Foi seguido as etapas de validação do plugin, selecionando a imagem na qual seriam analisados a acurácia. Foi escolhida a amostragem aleatória estratificada, na opção: proporção baseada em área. O número de pontos e o tamanho da amostra para cada classe são calculados pelo tamanho da área de cada uma automaticamente.

Foram geradas 396 amostras divididas entre as 9 classes temáticas deste estudo, sendo interpretadas com o auxílio de imagens do *Google Earth Pro*, este processo necessita de uma validação manual das amostras, podendo ser observado na Figura 12, no qual a partir disso

pode-se gerar as informações de acurácia do mapa de classificação.

Figura 12 — Teste de acurácia realizado no AcATaMa, um módulo de extensão do Qgis.




Fonte: *Software QGIS (2022)*.

5 RESULTADOS E DISCUSSÕES


As Figuras 13 e 14 são representados os mapas de declividade e relevo respectivamente, é possível perceber que o relevo baixo é característico da região de estudo, é justamente onde se encontram a maioria das áreas agricultáveis, como exemplo, a cultura de cana-de-açúcar da usina CASUR. O mapa de altitude tem em grande parte áreas de até 150 metros de altitude a nível do mar, sendo as grandes altitudes localizadas na ilha Ometepe.

Figura 13 — Mapa de declividade da área de estudo.



Fonte: *Software QGIS (2022).*

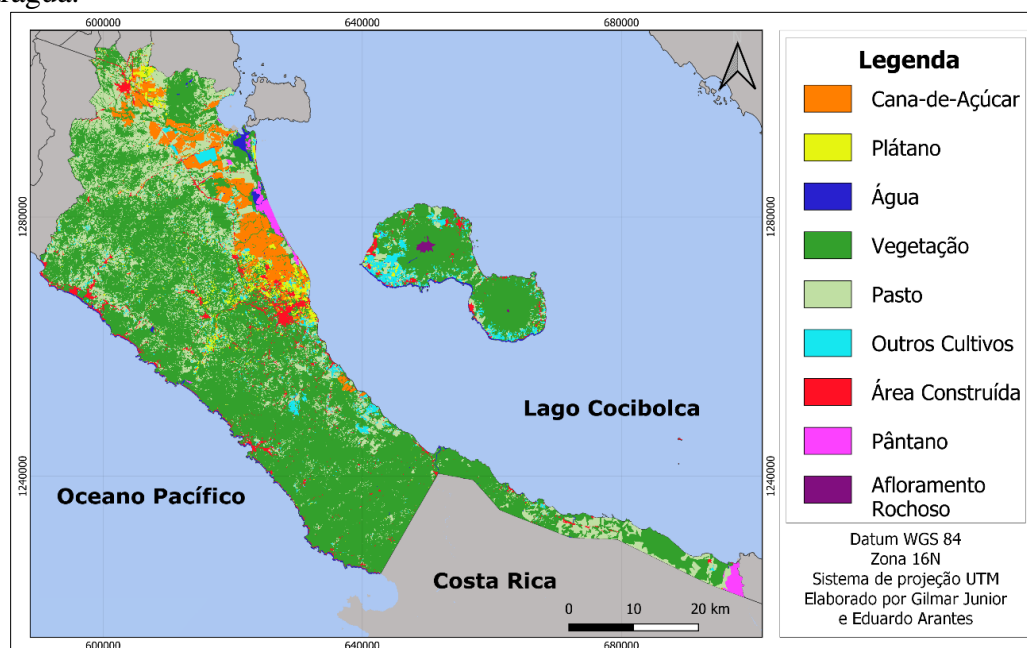
Figura 14 — Mapa de Hipsométrico da área de estudo.



Fonte: *Software QGIS (2022).*

Foi gerado o mapa de uso e cobertura da terra para o departamento de Rivas e da cidade de Nandaime representado pela Figura 15.

Figura 15 — Uso e cobertura da terra no estado de Rivas e a cidade de Nandaime, Nicarágua.



Fonte: Do Autor (2022).

Uma vez realizado o processamento dos dados obteve a seguinte matriz de confusão, representada pela Tabela 2.

Tabela 2- Matriz de confusão.

	Cana-de-açúcar	Plátano	Água	Vegetação	Pasto	Outros Cultivos	Área Construída	Pântano	Afloramento Rochoso	Pontos Referência
Cana-de-açúcar	124	0	0	8	3	3	4	0	0	142
Plátano	2	73	0	11	7	1	2	0	0	96
Água	0	0	33	1	0	0	0	1	0	35
Vegetação	2	3	0	465	43	6	3	0	0	522
Pasto	3	3	0	51	195	14	3	0	0	269
Outros Cultivos	3	2	3	9	19	44	1	0	0	81
Área Construída	0	2	2	15	7	7	63	0	0	96
Pântano	0	1	0	3	2	1	0	28	0	35
Afloramento Rochoso	0	0	2	0	0	0	0	0	3	5
TOTAL	134	84	40	563	276	76	76	29	3	1281

Fonte: Do Autor (2022).

Como podemos observar na matriz de confusão, das 1281 amostras de testes 1028 amostras foram classificadas corretamente. As 3 classes com maior confusão foram

Vegetação com 98 obtidas, sendo 51 em pastagem, 11 em plátano, 1 em água, 9 em outros cultivos, 15 em área construída e 3 em pântano, Pasto com 81 amostras obtidas, sendo 3 em cana-de-açúcar, 7 em plátano, 43 em vegetação, 19 em outros cultivos, 7 em área construída, e 2 em pântano, outros cultivos com 32 amostras, sendo 3 em cana-de-açúcar, 1 em plátano, 6 em vegetação, 14 pasto, 7 em área construída e 1 em pântano.

Tabela 3- Apresenta a matriz de confusão baseada na área de cada classe.

	CA	PL	AG	VG	PA	OC	AC	PN	AR	TP
CA	0,04526	0,00000	0,00000	0,00292	0,00109	0,00109	0,00146	0,00000	0,00000	0,0518
PL	0,00055	0,01991	0,00000	0,00300	0,00191	0,00027	0,00055	0,00000	0,00000	0,0262
AG	0,00000	0,00000	0,00856	0,00026	0,00000	0,00000	0,00000	0,00026	0,00000	0,0091
VG	0,00245	0,00367	0,00000	0,56950	0,05266	0,00735	0,00367	0,00000	0,00000	0,6393
PA	0,00221	0,00221	0,00000	0,03755	0,14358	0,01031	0,00221	0,00000	0,00000	0,1981
OC	0,00138	0,00092	0,00138	0,00414	0,00873	0,02023	0,00046	0,00000	0,00000	0,0372
AC	0,00000	0,00062	0,00062	0,00467	0,00218	0,00218	0,01960	0,00000	0,00000	0,0299
PN	0,00000	0,00021	0,00000	0,00062	0,00041	0,00021	0,00000	0,00578	0,00000	0,0072
AR	0,00000	0,00000	0,00048	0,00000	0,00000	0,00000	0,00000	0,00000	0,00072	0,0012
TPA	0,05184	0,02754	0,01104	0,62266	0,21057	0,04163	0,02795	0,00604	0,00072	1,0000

Nota: CA: Cana-de-açúcar; PL: Plátano; AG: Água; VG: Vegetação; PA: Pasto; OC: Outros Cultivos; AC: Área Construída; PN: Pântano; AR: Afloramento Rochoso; TPA: Total da proporção da área.

Fonte: Do Autor (2021).

Tabela 4- Acurácias do produtor e do usuário, de acordo com a matriz de confusão baseada na área de cada classe.

CLASSE	Acurácia do usuário	Acurácia do produtor
Cana-de-açúcar	87,32%	87,30%
Plátano	76,04%	72,29%
Água	94,29%	77,50%
Vegetação	89,08%	91,46%
Pasto	72,49%	68,18%
Outros Cultivos	54,32%	48,58%
Zona Construída	65,63%	70,13%
Pântano	80,00%	95,71%
Afloramento Rochoso	60,00%	100,00%
Acurácia global	83,30%	

Fonte: Do autor (2022).

A partir das matrizes de confusão geradas foram calculados para cada uma das classes individualmente os valores de acurácia do produtor e acurácia do usuário, e o valor de acurácia global. A classe que apresentou menor acurácias do produtor foi a classe outros cultivos, por ser uma classe que pode ser confundida com pasto e vegetação. Pode se destacar também a classe pasto, confundida com as classes vegetação e outros cultivos, pois depende muito do tipo e idade do plantio (outros cultivos). Já a classe que teve a menor acurácia do usuário foi outros cultivos, pois o modelo especificamente nessa área pode confundir com

pastos. A classificação de imagens Landsat por meio da utilização do algoritmo de aprendizagem de máquina *Random Forest* permitiu resultados considerados excelentes para acurácia global, após análises dos resultados mostrados na Tabela 4 foi possível verificar que a acurácia global obteve um valor de 83,3 %, este valor se mostra como uma acurácia alta por levar em conta todas as classes e isso mostra que as classes com maior predominância e menor ocorrência de erro alavancaram os índices.

Tabela 5- Erro padrão da estimativa da área

CLASSE	Erro padrão da estimativa da área
Cana-de-açúcar	0,002735
Plátano	0,002840
Água	0,001014
Vegetação	0,010182
Pasto	0,009654
Outros Cultivos	0,004646
Zona Construída	0,003016
Pântano	0,000560
Afloramento Rochoso	0,000295
TOTAL	0,03494

Fonte: Do autor (2022).

A Tabela 5 representa o erro padrão da estimativa da área individualmente de cada classe, este valor foi multiplicado pela área total em hectares para todas as áreas de cada classe, além disso, calculou-se o intervalo de confiança de 95%, multiplicando o valor de 1,96 em cada erro padrão da área calculado anteriormente, gerando assim um intervalo de confiança onde os valores das áreas das classes, ou seja, o resultado está dentro do intervalo de confiança em 95 das 100 amostras realizadas. Os valores para cada classe de uso e ocupação da terra estão apresentados na Tabela 6.


Tabela 6- Área estimada das classes em hectares.

Classes	Área Estimada das Classes (ha)	Intervalo com 95% de confiança (ha)	Porcentagem das Classes (%)
Cana-de-açúcar	13.251,22	1.370,47	5,18%
Plátano	7.040,25	1.422,67	2,75%
Água	2.822,18	507,84	1,10%
Vegetação	159.162,69	5.101,5	62,27%
Pasto	53.825,57	4.836,8	21,06%
Outros Cultivos	10.642,63	2.327,4	4,16%
Zona Construída	7.144,08	1.510,9	2,79%
Pântano	1.544,35	280,3	0,60%
Afloramento Rochoso	185	148	0,07%
TOTAL	25.5618,0		100,00%

Fonte: Do autor (2022).

Gráfico 1- Área estimada das classes.

Área estimada das classes (%)



Fonte: Do autor (2022).

Realizado o procedimento de classificação, foi possível analisar e quantificar a ocupação e uso da terra na área de estudo, estes resultados estão contidos na Tabela 6. A classe de uso e cobertura da terra com maior extensão na área de estudo foi vegetação, com cerca de 62,57% de toda a área de estudo, percebe-se que essa classe esta presente na maior parte no sul do estado de Rivas, e em boa parte da ilha. Em seguida aparece quatro classes que inclui atividades de agricultura, junta ocuparam cerca de 33,5 % da área total, com destaque para o cultivo de cana-de-açúcar, na sua maioria concentrados ao norte da área de estudo, ao redor da usina Casur.

É importante salientar uma competitividade entre as áreas de plantio de cana-de-açúcar

e plátano, sendo as áreas com cana-de-açúcar se sobressaindo em comparação com a área de plátano, com cerca de 2,43 a mais de área.

6 CONCLUSÃO

O mapeamento e o uso e cobertura da terra no estado de Rivas e a cidade de Nandaime, Nicarágua, são fundamentais para a avaliação e tomadas de decisão sobre a gestão territorial para a usina CASUR e autoridades políticas. Nesse sentido, as técnicas de classificação e imagens de satélites foram ferramentas importantes para este estudo. A constante presença de nuvens na área de estudo foi um forte impedimento na classificação, sendo necessária uma edição na classificação para se ter sua conclusão. O algoritmo Random Forest, apresentou um ótimo desempenho na identificação, diferenciação e classificação das nove classes de uso e cobertura da terra na área de estudo. O presente estudo gerou uma confiabilidade dos resultados na classificação por meio da matriz de confusão e inclusão de intervalo de confiança, sendo assim, um estudo eficaz.

REFERÊNCIAS

ACATAMA, a **Qgis plugin**. Disponível em: <https://plugins.qgis.org/plugins/AcATaMa/>. Acesso em: 25 de ago.2021.

COCHRAN, W. G. **Técnicas de amostragem**. New York: J. Wiley, 1965. 428p

CROSTA, Alvaro Pentead. **Processamento digital de imagens de sensoriamento remoto**. UNICAMP/Instituto de Geociências, 1999.

CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. **Lewis Publishers, Boca Raton, FL**, 1999.

DANTAS, Guilherme Vieira. Utilização de classificador random forest na detecção de falhas em máquinas rotativas. **Unpublished data**, 2015.

DAVIS, C.; MONTEIRO, A. M. V. (Eds.). Introdução à ciência da geoinformação. São José dos Campos: **INPE**, 2001. p. 345.

ENGELBRECHT, S. A.; HEINE, G.; MAHEMBE, B. Integrity, leadership of ethics, trust and work engagement. **Leadership & Organization Development Journal**, v. 38, n. 3, p. 1–32, 2017.

FOODY, G. M. Land Cover Classification Accuracy Assessment. **Springer Geography**, v. 80, p. 105–118, 2002.

LOISEL, H.; JAMET, C.; RIEDI, J. Remote Sensing. **Surface Ocean-Lower Atmosphere Processes**, p. 287–301, 2009.

NASA - National Aeronautics and Space Administration. Disponível em: <http://www.nasa.gov/>. **NOAO - National Optical Astronomy Observatory**. Acesso em: 25 de ago.2021.

NETO, C. Di G. Potencial de técnicas de mineração de dados para o mapeamento de áreas cafeeiras. **INPE**, São José dos Campos, 2014.

NOVO, Evlyn ML de Moraes. **Sensoriamento Remoto: princípios e aplicações**. [S.l.]: Editora Blucher, 2010.

PAL, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26(1), 217-222.

QUEIROZ, C. J. de. **Análise de transformações geométricas para o georreferenciamento de imagens do satélite CBERS-I**. Dissertação de Mestrado (Mestrado em Sensoriamento Remoto). Universidade Federal do Rio Grande do Sul, 2003.

REDDY, M Anji; REDDY, Anji. Textbook of remote sensing and geographical information systems. [S.l.]: **BS publications Hyderabad**, 2008.

ROCHA, C. H. B. 2000. **Geoprocessamento: Tecnologia Transdisciplinar**. Juiz de Fora, MG, Ed. do Autor. 2ª Ed. 220 p.

STEHMAN, S. V. (2009). Sampling designs for accuracy assessment of land cover. (“FC-27 - Thematic Accuracy Assessment | GIS&T Body of Knowledge”) **International Journal of Remote Sensing**, 30(20), 5243-5272.

STORY, M. AND CONGALTON, R.G. (1986) Accuracy Assessment: A User’s Perspective. **Photogrammetric Engineering and Remote Sensing**, 52, 397-399.

TURNER, B.L.; MEYER, W. B.; SKOLE, D. Global land-use/land cover change: Towards an integrate study. **Ambio**, Londres, v.23, n.1, p. 91-95, 1994.

