



Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no Mapeamento de Cobertura e Uso da Terra no Maciço de Uruburetama, Ceará
Comparison of OLI/ Landsat-8 and MSI/Sentinel-2 Images in Cover and Land Use Mapping in the Uruburetama Massif, Ceará

Eduardo Viana Freires¹; Cláudio Ângelo da Silva Neto¹; Dominick Sávio Rocha Cunha²; Cynthia Romariz Duarte³; César Ulisses Vieira Veríssimo³ & Daniel Dantas Moreira Gomes⁴

¹ Universidade Federal do Ceará (UFC), Centro de Ciências, Departamento de Geologia. Programa de Pós-Graduação em Geologia. Campus do Pici, Bloco 912, Cep: 60455-760, Fortaleza - CE, Brasil

² Universidade Federal do Ceará (UFC), Centro de Ciências, Departamento de Geologia. Laboratório de Geoprocessamento do Ceará (GEOCE). Campus do Pici, Bloco 912, Cep: 60455-760, Fortaleza - CE, Brasil

³ Universidade Federal do Ceará (UFC), Centro de Ciências, Departamento de Geologia. Campus do Pici, Bloco 912, Cep: 60455-760, Fortaleza - CE, Brasil

⁴ Universidade de Pernambuco (UPE), Campus Garanhuns. Rua Cap. Pedro Rodrigues, 105, Cep 55294-902, Garanhuns, PE – Brasil

E-mails: eduardovgeo@gmail.com; claudioasn@gmail.com; dsgeologo@gmail.com; cynthia.duarte@ufc.br; cesarulisses85@gmail.com; daniel.gomes@upe.br

Recebido em: 04/06/2019 Aprovado em: 10/09/2019

DOI: http://dx.doi.org/10.11137/2019_4_427_442

Resumo

Imagens orbitais da série Landsat têm sido sistematicamente empregadas no mapeamento de cobertura e uso da terra. Porém, algumas áreas, devido às características de relevo ou a forte influência antrópica, impõem dificuldades nesta caracterização. O maciço de Uruburetama, no estado do Ceará, representa uma área com tais particularidades. Na tentativa de gerar melhores resultados na identificação e delimitação das diferentes classes de cobertura e uso da terra no maciço, este trabalho compara imagens dos sensores orbitais OLI/Landsat-8 e MSI/Sentinel-2, a fim de definir qual produto pode ser melhor empregado em estudos desta finalidade. A metodologia partiu da obtenção de imagens orbitais da área, passando por etapas de pré-processamento, geração de NDVI, segmentação por crescimento de regiões, classificação supervisionada, validação da classificação e produção dos mapas temáticos. Os produtos NDVI apresentaram correlação positiva muito forte, evidenciando compatibilidade espectral entre os sensores. Na etapa de segmentação, percebeu-se a influência da melhor resolução espacial do sensor MSI com a criação de quase oito vezes mais polígonos e uma área média correspondente a 12,5% a medida do sensor OLI. A classificação supervisionada utilizando o algoritmo Bhattacharya possibilitou mapear os dois produtos em sete classes temáticas de cobertura e uso da terra do maciço de Uruburetama: Mata Úmida; Mata Seca; Caatinga Arbustiva Densa; Caatinga Arbustiva Aberta; Urbano/Solo Exposto; Corpos D'água e Cultivos. A validação das classificações atestou a melhor acurácia do produto MSI/Sentinel-2 por meio dos índices Kappa e exatidão global. Os resultados demonstram que a imagem MSI/Sentinel-2, devido a sua melhor resolução espacial, permite um maior detalhamento dos alvos, e maior acurácia na classificação, o que possibilita a sua aplicação em estudos com maiores escalas de análise. Por sua vez, a imagem OLI/Landsat-8, demonstrou ser mais adequada a estudos com menores níveis de detalhes, ou com alvos mais homogêneos.

Palavras-chave: cobertura e uso da terra; NDVI; segmentação por regiões; classificação supervisionada

Abstract

Orbital images of the Landsat series have been systematically employed in the mapping of land cover and use. However, some areas, due to the relief characteristics or the strong antropic influence, impose difficulties in this characterization. The Uruburetama massif, in the state of Ceará, represents an area with such peculiarities. This work compares images of the OLI / Landsat-8 and MSI / Sentinel-2 orbital sensors in order to determine which product can best be used studies. The methodology was based on obtaining orbital images of the area, including pre-processing stages, NDVI generation, segmentation by region growth, supervised classification, classification validation and production of thematic maps. The NDVI products had very strong positive correlation, evidencing spectral compatibility among the sensors. In the segmentation stage, we noticed the influence of the best spatial resolution of the MSI sensor with the creation of almost eight times more polygons and a mean area corresponding to 12.5% the measurement of the OLI sensor. The supervised classification using the Bhat-tacharya algorithm allowed to map the two products in seven thematic classes of coverage and land use of the Uruburetama massif: Mata Humid; Mata Seca; Dense Shrub Caatinga; Open Shrub Caatinga; Urban / Ground Exposure; Water Bodies and Crops. The validation of the classifications attested to the best accuracy of the MSI / Sentinel-2 product through the Kappa indices and global accuracy. The results demonstrate that the MSI / Sentinel-2 image, due to its better spatial resolution, allows a greater detail of the targets, and a better accuracy in the classification, which allows even its application in studies with larger scales of analysis. The OLI / Landsat-8 image, on the other hand, has been shown to be more suitable for studies with lower levels of detail, or with more homogeneous targets.

Keywords: coverage and land use; NDVI; segmentation by regions; supervised classification

1 Introdução

Um dos maiores dilemas no mapeamento de cobertura e uso da terra subsidiada por imagens orbitais é identificar os diferentes extratos da cobertura vegetal e ao mesmo tempo distingui-los de áreas de cultivo e pastagens. Esta avaliação se torna mais difícil quando o foco são áreas com relevo planáltico, fortemente fraturado, com variados graus de intervenções antrópicas em suas encostas e submetidas a um clima semiárido. Todavia, com a diversidade de imagens orbitais disponíveis atualmente, com diferentes resoluções espectrais e espaciais, é possível obter melhores resultados empregando técnicas adequadas.

O Maciço de Uruburetama, localizado na porção norte do estado do Ceará (Figura 1), apresenta todos os elementos que dificultam a classificação e o mapeamento a partir de imagens de satélites: (1) está inserido numa área de domínio do clima semiárido, que altera a fisionomia da vegetação ao longo

do ano; (2) a diferença de altitude e a disposição do relevo favorecem a ocorrência de diferentes extratos vegetacionais (Mata úmida, Mata Seca, Caatinga Arbustiva Densa, Caatinga Arbustiva Aberta) no maciço e em seu entorno; (3) o relevo fortemente fraturado dificulta a visualização dos alvos devido ao efeito de sombra; (4) além disto, é marcado por forte intervenção antrópica, a partir do crescimento urbano e sobretudo das atividades agrícolas, com destaque para o cultivo de milho no sopé da serra e seu entorno e de banana nas áreas úmidas.

Conforme Silva (2007), em decorrência dessas intervenções, o Maciço de Uruburetama é o mais desconfigurado ambientalmente do estado do Ceará, principalmente quando comparado às serras do Machado, Meruoca, das Matas e de Baturité. Fato este que denota a dificuldade imposta para identificação e/ou diferenciação dos alvos terrestres e consequentemente para o mapeamento de cobertura e uso da terra desta área.

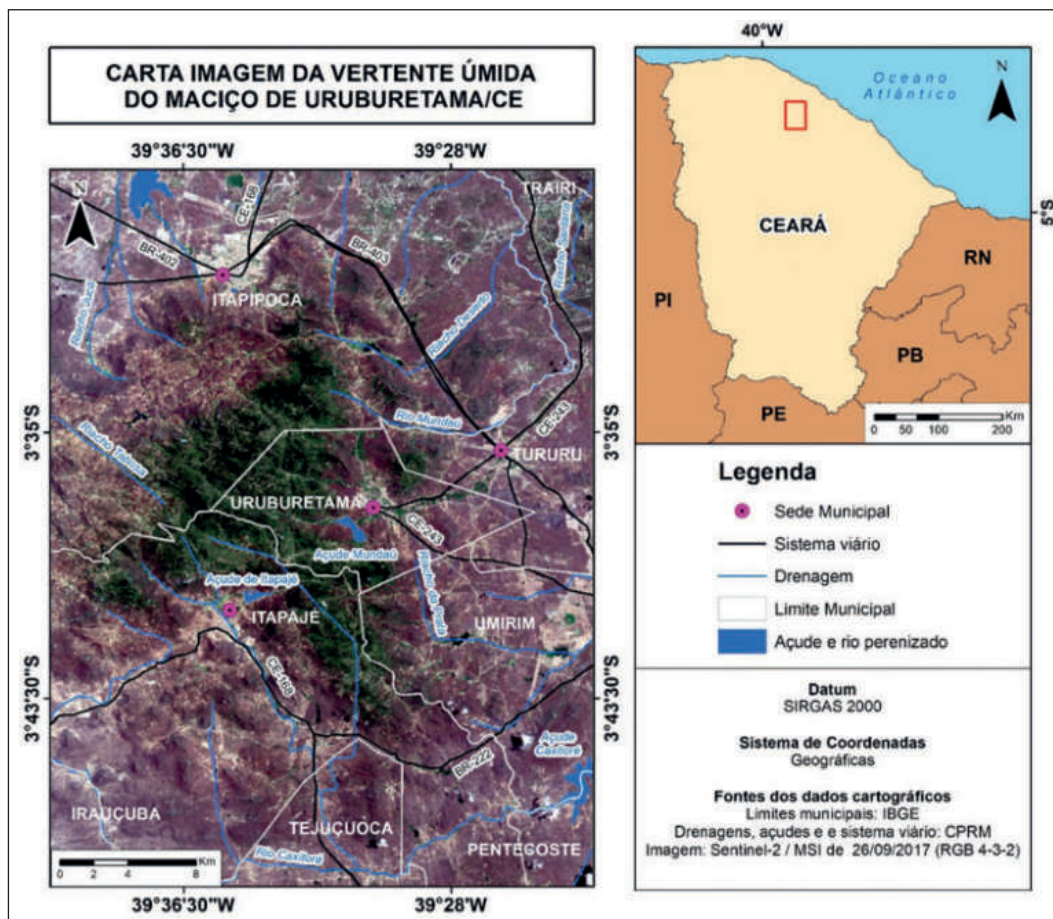


Figura 1
Mapa de localização da área de estudo.

A partir da problemática exposta e em busca de melhores técnicas para identificação e delimitação das diferentes classes de cobertura e uso da terra do Maciço de Uruburetama e adjacências, este trabalho teve como objetivo comparar a resposta das imagens provenientes dos sensores orbitais OLI/Landsat 8 e MSI/Sentinel-2, a fim de definir qual dos produtos pode ser melhor empregado em estudos ambientais desta finalidade.

A área de estudo apresenta uma extensão de 1.344,963 km² e localiza-se entre as coordenadas UTM (zona 24 Sul) 9.619.380-9.577.181 m N; e 424.667-456.494 m E. Como pode ser observado na Figura 1, a área está inserida, em diferentes proporções, dentro do limite administrativo de nove municípios do estado do Ceará, que são: Irauçuba, Itapajé, Itapipoca, Pentecoste, Tejuçuoca, Trairi, Tururu, Umirim e Uruburetama.

2 Materiais e Métodos

A metodologia desta pesquisa foi desenvolvida em três etapas complementares e encontra-se esquematizada no fluxograma da Figura 2.

A primeira etapa correspondeu à aquisição dos dados, em que houve a revisão bibliográfica, para embasar a pesquisa, e a obtenção das imagens

OLI/Landsat-8 e MSI/Sentinel-2 no *site* do Serviço Geológico dos Estados Unidos (USGS, 2018). Nessa etapa também ocorreram atividades de campo voltadas para o reconhecimento terrestre no intuito de definir as unidades de cobertura e uso da terra utilizadas na classificação supervisionada das imagens. As incursões à área de pesquisa foram realizadas antes e durante o processo de classificação no intuito de eliminar quaisquer dúvidas sobre os alvos das imagens, ou seja, verificar a compatibilidade entre o que era observado na imagem e o que de fato existia na área de estudo.

Na segunda etapa foi realizado o processamento das imagens orbitais, submetendo-as inicialmente à correção radiométrica através do método de Subtração do Pixel Escuro (DOS, do inglês *Dark Object Subtraction*). Após a correção radiométrica a imagem OLI/Landsat-8 teve seus *pixels* reamostrados de 30 m para 10 m, sem alterar os valores de DN, compatibilizando sua resolução espacial com a do sensor MSI/Sentinel-2 e, assim, permitindo o cálculo de correlação entre os dois conjuntos de dados, pois para realizar tal operação ambas as matrizes analisadas devem ser de igual tamanho. Em seguida, foi processado o Índice de Vegetação por Diferença Normalizada (NDVI) de cada imagem, a partir dos quais foi feita a segmentação por crescimento de regiões e classificação supervisionada, com posterior validação.

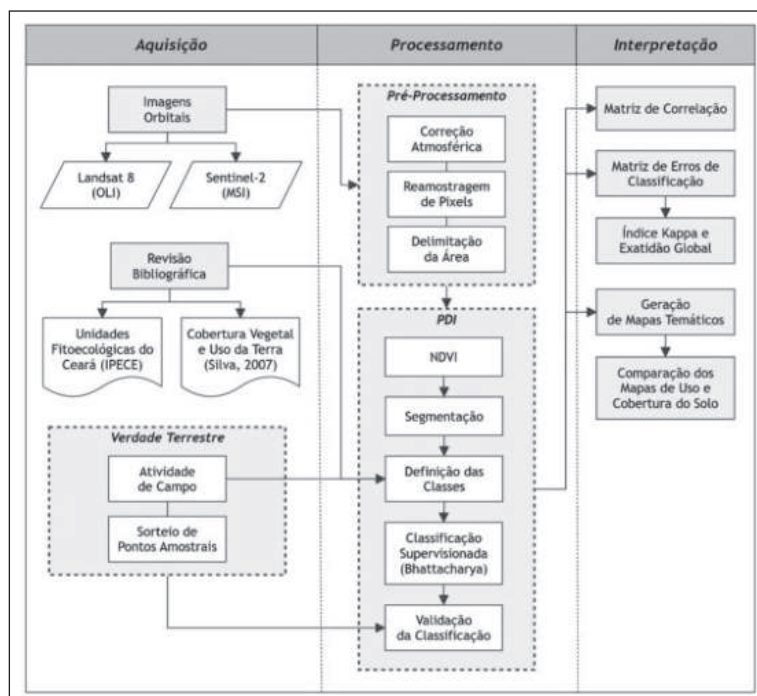


Figura 2
Resumo das atividades desenvolvidas neste trabalho.

Na terceira etapa houve a interpretação dos resultados, visando identificar a correlação entre as imagens NDVI; comparar os produtos das segmentações; avaliar a qualidade das classificações supervisionadas a partir do Índice Kappa e Exatidão Global e comparar os mapas de cobertura e uso da terra gerados a partir da classificação.

2.1 Materiais

As imagens dos satélites Landsat-8 e Sentinel 2 foram adquiridas georreferenciadas, de forma gratuita, através do site do USGS (<https://earthexplorer.usgs.gov>). A fim de obter imagens com o menor intervalo de dias entre elas, e interferência de nuvens reduzida, foi feita uma pesquisa que resultou nos seguintes produtos com as respectivas datas de aquisição por seus sensores:

Imagem OLI/Landsat-8 obtida em 30 de setembro de 2017;

Imagem MSI/Sentinel-2 obtida em 26 de setembro de 2017.

Devido à temática de comparação entre as imagens dos satélites Landsat 8 e Sentinel-2, é importante compreender as diferenças existentes entre

os parâmetros dos seus sensores, em especial suas resoluções espacial, espectral e radiométrica. Conforme a Tabela 1, é possível perceber que a diferença entre o tamanho do *pixel* dos produtos analisados é um fator a ser considerado, sendo este aspecto abordado mais à frente.

Os programas utilizados neste trabalho foram: ENVI 5.0 para pré-processamento das imagens, processamento do NDVI e geração de estatísticas; SPRING 5.5.3 para segmentação e classificação supervisionada; e o ArcGIS 10.5 para validação da classificação e produção dos mapas.

2.2 Métodos

2.2.1 Pré-Processamento

Um dos efeitos da atmosfera sobre as imagens orbitais é a redução do contraste entre os objetos de uma dada cena, devido aos fenômenos de espalhamento, absorção e refração da energia eletromagnética, afetando a radiância refletida pela superfície que é captada pelo sensor. Ela também reduz a possibilidade de detecção de pequenos objetos dentro de uma cena, ou de diferenciação entre objetos que apresentem pequenas variações na intensidade de sinal (Novo, 2008).

Landsat-8 (OLI e TIRS)			Sentinel-2 (MSI)		
Banda	Comprimento de Onda Central (µm)	Resolução Espacial	Banda	Comprimento de Onda Central (µm)	Resolução Espacial
1 - Aerosol	0,443	30 m	1 - Aerosol	0,443	60 m
2 - Azul	0,483	30 m	2 - Azul	0,490	10 m
3 - Verde	0,561	30 m	3 - Verde	0,560	10 m
4 - Vermelho	0,654	30 m	4 - Vermelho	0,665	10 m
5 - NIR	0,864	30 m	5 - Red Edge 1	0,705	20 m
6 - SWIR 1	1,609	30 m	6 - Red Edge 2	0,740	20 m
7 - SWIR 2	2,201	30 m	7 - Red Edge 3	0,783	20 m
8 - Pancromática	0,589	15 m	8A - Red Edge 4	0,865	20 m
9 - Cirrus	1,364	30 m	8 - NIR	0,842	10 m
10 - TIR 1	10,895	100 m	9 - Vapor D'água	0,940	60 m
11 - TIR 2	12,005	100 m	10 - Cirrus	1,375	60 m
			11 - SWIR 1	1,610	20 m
			12 - SWIR 2	2,190	20 m

Tabela 1 Parâmetros dos sensores OLI/Landsat-8 e MSI/Sentinel-2.

Neste contexto, a correção atmosférica de imagens de satélite é feita com a intenção de minimizar os efeitos atmosféricos na radiância de uma cena (Sanches *et al.*, 2011); e, também, é necessária para o cálculo de índices de vegetação computados a partir de duas ou mais bandas espectrais, visto que elas são afetadas diferentemente pelo espalhamento atmosférico (Mather, 1999).

Neste trabalho, a correção atmosférica das imagens OLI/Landsat-8 e MSI/Sentinel-2 foi realizada através do programa ENVI 5.0, utilizando processo de Subtração do Pixel Escuro (DOS, do inglês *Dark Object Subtraction*). Os métodos baseados na técnica de subtração dos objetos escuros estimam a interferência atmosférica diretamente da imagem (Gürtler *et al.*, 2003). Para efeitos de comparação era essencial que ambas as imagens passassem pelos mesmos processos. Desta forma, o DOS foi escolhido por ser um método compatível aos dois conjuntos de dados, com simples e rápida aplicação.

2.2.2 Processamento Digital de Imagens (PDI)

2.2.2.1 Índice de Vegetação por Diferença Normalizada (NDVI)

Segundo Baret & Guyot (1991), os índices de vegetação ressaltam as diferenças entre o solo e a vegetação, como também reduzem a informação espectral de duas bandas em apenas uma, relacionada às características da vegetação (área foliar, biomassa, produtividade, atividade fotossintética e percentagem de cobertura). Rosembach *et al.* (2005) reforçam a importância do uso de imagens NDVI no realce da vegetação em relação aos instrumentos urbanos, água e ao solo exposto.

Neste trabalho, o NDVI foi calculado no programa ENVI 5.0, através da Equação 1, utilizando as bandas do espectro do Vermelho (V) e Infravermelho Próximo (IVP) de cada sensor.

$$NDVI = \frac{IVP - V}{IVP + V} \quad (1)$$

Esta equação gera uma imagem com valores que vão de -1 a +1. Os valores próximos de +1 indicarão a presença de vegetação, ou seja, quanto maior o valor do índice, maior será a presença de vegetação. Enquanto os valores próximos a -1 representarão os alvos urbanos, solo exposto e água.

2.2.2.2 Segmentação por Crescimento de Regiões

No processo de segmentação divide-se a imagem em regiões que devem corresponder às áreas de interesse da aplicação. Entende-se por região um conjunto de *pixels* contíguos, que se espalham bidirecionalmente e que apresentam uniformidade. O crescimento de regiões é uma técnica de agrupamento de dados, na qual somente as regiões adjacentes, espacialmente, podem ser agrupadas (INPE, 2004).

As imagens NDVI de cada sensor foram submetidas ao processo de segmentação por crescimento de regiões como uma etapa prévia à classificação supervisionada. Nesta técnica foram utilizados os parâmetros de similaridade e área. A similaridade é o limiar abaixo do qual as regiões são consideradas similares e, conseqüentemente, se adjacentes podem ser agrupadas. O limiar de área é o número mínimo de *pixels* para que uma região seja individualizada.

Durante o processo de segmentação foram testadas as seguintes combinações de limiares de similaridade e área, respectivamente: 5 e 10, 8 e 10, 5 e 15, 8 e 15, 12 e 25, 15 e 25, 25 e 50, 50 e 100. A combinação padrão, com limiar de similaridade igual a 8 e limiar de área igual a 10 *pixels* foi a mais adequada ao mapeamento da área de estudo, significando que a distância Euclidiana entre a média digital de duas regiões na qual são agrupadas é de 8 tons de cinza e a área mínima de 10 *pixels*. Isso indica que a menor área é de 10 *pixels*, ou seja, na imagem OLI/Landsat-8 corresponde a uma área de 9.000 m² (30 m × 30 m × 10) para individualizar regiões espectralmente homogêneas. Enquanto a Imagem MSI/Sentinel-2 corresponde a uma área de 10 m × 10 m × 10, ou 1000 m².

2.2.2.3 Classificação Supervisionada por Região

Os classificadores por região utilizam, além de informação espectral de cada *pixel*, a informação espacial que envolve a relação com seus vizinhos. Buscam simular o comportamento de um foto-intérprete, reconhecendo áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais de imagens. A informação de borda é utilizada inicialmente para separar regiões e as propriedades espaciais e espectrais irão unir áreas com mesma textura (INPE, 2004).

A partir do mapa de Unidades Fitoecológicas elaborado pelo IPECE (2018), do mapa de Cobertura Vegetal e Uso da Terra da Serra de Uruburetama proposto por Silva (2007) e de levantamentos feitos em campo foram definidas sete classes temáticas de Cobertura e uso da terra na área de pesquisa (Tabela 2): Mata Úmida; Mata Seca; Caatinga Arbustiva Densa; Caatinga Arbustiva Aberta; Cultivos; Corpos D'água; e Urbano/Solo Exposto. Estas classes subsidiaram a posterior classificação com base nos polígonos gerados pela segmentação em cada produto.

A partir da segmentação por crescimento de regiões, disponível no programa SPRING, foi executada uma classificação supervisionada por regiões, pelo algoritmo de distância Euclidiana denominado *Bhattacharya*, visando extrair as feições de interesse. Este classificador é um algoritmo que permite a interação do analista, que seleciona os polígonos gerados na segmentação, para definir as amostras de treinamento das classes a serem mapeadas.

A classificação *Bhattacharya* utiliza como amostras os polígonos previamente criados no processo de segmentação das imagens NDVI para treinar o classificador, calculando a média e matriz de covariância de cada classe. Em seguida, cada segmento é alocado a uma dessas classes segundo a menor distância de *Bhattacharya*, visando extrair as feições de interesse (Bins, *et al.* 1996; INPE, 2004; Mather 2004).

Para a classificação da imagem NDVI, obtida da imagem OLI/Landsat-8, foram selecionadas 561 amostras representativas das sete classes temáticas definidas para o mapeamento. Para classificação da imagem NDVI gerada a partir da imagem MSI/Sentinel-2 foram selecionadas 881 amostras das classes estabelecidas. O número superior de amostras está relacionado ao fato de a maior resolução espacial desta imagem propiciar a geração de um maior número de segmentos.

Na tabela 2 podem ser observados os parâmetros utilizados para segmentação e classificação das imagens NDVI/Landsat-8 e NDVI/Sentinel-2

2.2.3 Validação da Classificação Supervisionada

A validação é um procedimento pós-classificatório que visa atestar a qualidade do mapeamento realizado. Para isso foram utilizadas, conforme Congalton (1991), amostras com coordenadas x e y, representativas das classes mapeadas, e que por sua vez correspondem a verdade terrestre.

De acordo com Congalton (1991), para validação em situações que a área de abrangência territorial corresponda até a 4.050 km² são necessárias pelo menos 50 amostras para cada classe mapeada.

Devido a extensão da área de estudo foram definidas 50 amostras para cada uma das sete classes, totalizando 350. Essas amostras foram obtidas através de um sorteio randômico a partir da ferramenta *Create Random Points* presente no *software* ArcGIS.

De acordo com Jensen (2009), existem dois métodos primários para obtenção de informações precisas de coordenadas x e y de um objeto. Um se dá através de medidas de campo utilizando técnicas tradicionais de levantamento topográfico ou instrumentos que utilizam o sistema de posicionamento global (GPS). E o outro ocorre a partir da coleta de dados de sensoriamento remoto do objeto, o registro (retificação) da imagem para um mapa-base, e então a extração das informações de coordenadas x e y diretamente da imagem retificada.

Conforme Chuvieco (1990), os dados de referência para a validação podem ser obtidos a partir de trabalhos de campo ou de documentos auxiliares, como fotografias aéreas e cartas.

Para determinação das classes das amostras de validação na área de pesquisa optou-se por uma imagem orbital de melhor resolução espacial do que as imagens OLI/Landsat-8 e MSI/Sentinel-2, aplicadas no mapeamento. Nesse intuito foi utilizada uma

Imagens	OLI/Landsat-8	MSI/Sentinel-2
Segmentação	Similaridade = 8 pontos	Área (pixel) = 10 pontos
Classes temáticas	Mata Úmida, Mata Seca, Caatinga Arbustiva Densa, Caatinga Arbustiva Aberta, Cultivos, Corpos D'água, Urbano/Solo Exposto.	
Total de amostras (Treinamento)	561	881

Tabela 2
Parâmetros utilizados no processamento das imagens OLI/Landsat-8 e MSI/Sentinel.

imagem Geoeye de 2017, com resolução espacial de 0,40 m, para interpretação e identificação dos alvos.

Após esta etapa foi realizado o cruzamento das classes definidas no mapeamento temático com as classes análogas obtidas no levantamento da verdade terrestre a partir da ferramenta *Compute Confusion Matrix* no software ArcGIS.

Como resultado foi gerada a matriz de erros onde pode-se atestar a qualidade dos mapeamentos realizados a partir dos coeficientes estatísticos Índice Kappa e Exatidão Global.

Segundo Lillesand *et al.* (2004) a matriz de erro, conhecida ainda como matriz de confusão ou tabela de contingência, compara basicamente a relação entre os dados de referência conhecidos e os resultados correspondentes de uma classificação automatizada.

O Índice Kappa é um método estatístico que permite analisar de forma comparativa os resultados dos mapas obtidos por meio do sensoriamento remoto, dentro de certo limite (Landis & Koch, 1977).

Conforme Lobão *et al.* (2005), este índice é bastante utilizado para medir a qualidade da classificação e também para quantificar os valores entre os classificadores.

O índice Kappa foi obtido por meio da equação 2:

$$\hat{K} = \frac{n \sum_{i=1}^e x_{ii} - \sum_{i=1}^e (x_{i+} + x_{+i})}{n^2 - \sum_{i=1}^e (x_{i+} + x_{+i})} \quad (2)$$

Onde: \hat{K} = índice de exatidão kappa; l = nº de linhas da matriz quadrada; n = nº de observações na linha i e da coluna i ; e = total marginal da linha i e coluna i , respectivamente; e n = número total de observações

Conforme pode ser observado na tabela 3, o resultado obtido pelo índice *Kappa*, varia no intervalo de 0 a 1, sendo que o valor mais próximo a 1 significa a melhor qualidade dos dados classificados.

De acordo com Congalton & Green (1999) a estimativa de acurácia é obtida pela Exatidão Global, que corresponde a razão entre a soma de todos

Classes do índice	Desempenho
<0	Péssimo
0 - 0,2	Ruim
0,21 - 0,4	Razoável
0,41 - 0,6	Bom
0,61 - 0,8	Muito Bom
0,81 - 1,0	Excelente

Tabela 3 Classes e desempenho do Índice Kappa. Adaptado de Landis & Koch (1977).

os elementos amostrais classificados corretamente e o número total de elementos, como pode ser verificado na equação 3.

$$EG = \frac{\sum_{i=1}^k x_{ii}}{N} \quad (3)$$

Onde: EG = índice de exatidão global; N = nº total de unidades amostrais contempladas pela matriz; x_{ii} = nº de elementos da diagonal principal corretamente classificados; e k = nº de categorias analisadas na matriz.

A acurácia pode ser analisada individualmente por meio da análise de erros de omissão e comissão presentes na classificação (Congalton & Green 1999). Um erro de omissão ocorre quando um objeto é excluído da classe à qual pertence, enquanto o de comissão ocorre ao incluir um objeto a uma classe que ele não pertença. Na matriz de erros esses valores são obtidos por meio da acurácia do produtor e do usuário, respectivamente (Rovedder, 2007).

A acurácia do usuário indica o percentual de acerto da classificação em relação a verdade terrestre. É expressa pela razão entre o número de elementos adequadamente classificados numa dada classe e o total de elementos da mesma classe, como pode ser verificado na equação 4.

$$au = \frac{x_{ii}}{x_{i+}} \quad (4)$$

Onde: X_{ii} = Número de elementos classificados corretamente; X_{i+} = Total de elementos classificados para uma classe i .

A acurácia do produtor representa o percentual de acerto de um polígono ou pixel de referência

ter sido corretamente classificado. É expressa pela razão entre o número de elementos classificados corretamente em uma determinada classe pelo número de elementos de referência amostrados para a mesma classe, como pode ser observado na equação 5.

$$ap = \frac{x_{ii}}{x_{+i}} \quad (5)$$

Onde: X_{ii} = Número de elementos classificados corretamente; X_{+i} = Total de elementos classificados para uma classe i .

3 Resultados e Discussões

3.1 Correlação entre Imagens

No intuito de comparar as imagens OLI/Landsat 8 e MSI/Sentinel-2, a serem aplicadas no mapeamento de Cobertura e uso da terra, foi gerada uma matriz de correlação entre as respectivas imagens NDVI's obtidas, permitindo a análise comparativa entre os produtos dos dois sensores através do coeficiente de correlação de Pearson (r). Este parâmetro estatístico é utilizado para avaliar o grau de correspondência linear entre o NDVI de cada sensor, variando de -1 (correlação negativa perfeita) a +1 (correlação positiva perfeita), como mostra a Tabela 4.

Valor da Correlação (r)	Interpretação
0.9 a 1.0 (-0.9 a -1.0)	Correlação positiva (negativa) muito forte
0.7 a 0.9 (-0.7 a -0.9)	Correlação positiva (negativa) forte
0.5 a 0.7 (-0.5 a -0.7)	Correlação positiva (negativa) moderada
0.3 a 0.5 (-0.3 a -0.5)	Correlação positiva (negativa) fraca
0.0 a 0.3 (0.0 a -0.3)	Correlação positiva (negativa) desprezível

Tabela 4 Valores do coeficiente de correlação de Pearson (r). Adaptado de Mukaka (2012).

Os resultados mostram uma correlação positiva muito forte entre os produtos, evidenciando que, apesar da diferença de resolução espacial entre as imagens, espectralmente elas apresentam uma resposta muito semelhante no geral (Tabela 5). As imagens da série Landsat como um todo já são amplamente conhecidas por suas aplicações ambientais, em especial na caracterização de Cobertura e uso da terra, vide os trabalhos de Demarchi *et al.* (2011),

Freires & Mendes (2012), Nascimento *et al.* (2014), Salis *et al.* (2016) e Almeida *et al.* (2018). Desta forma, este resultado comprova, estatisticamente, que as imagens MSI/Sentinel-2 também podem ser utilizadas para este propósito.

Correlação (r)	OLI NDVI	MSI NDVI
OLI NDVI	1.000000	0.956218
MSI NDVI	0.956218	1.000000

Tabela 5 Valores de correlação entre os produtos de NDVI dos sensores estudados.

3.2 Segmentação das Imagens

Verificou-se que a segmentação foi mais efetiva na delimitação dos corpos d'água e na mata úmida, cujas áreas tiveram níveis de cinza mais homogêneos. Nas demais porções, a maior variabilidade de níveis de cinza contribuiu para a heterogeneidade das outras classes temáticas, reduzindo a eficiência do segmentador na geração dos polígonos.

Na Figura 3 são apresentados em traço vermelho os polígonos criados pelos limiares de segmentação definidos, sobrepostos às respectivas imagens NDVI de cada sensor. Um recorte da área total foi utilizado para visualizar o comportamento da segmentação em cada uma das imagens. É possível verificar que a imagem gerada a partir do sensor MSI apresentou maior eficiência na segmentação que o OLI. Visualmente é possível perceber uma maior quantidade de polígonos na imagem oriunda do Sentinel-2, além deles serem consideravelmente menores quando comparados aos gerados a partir do NDVI do Landsat 8. Numericamente, esta discrepância é ainda maior, conforme os dados da Tabela 6, evidenciando que a quantidade de polígonos gerados a partir da imagem MSI/Sentinel-2 é quase oito vezes maior que a OLI/Landsat 8. Além disso, sua área média representa cerca de 12,5% do valor dos polígonos obtidos do NDVI da Landsat 8.

A partir destes resultados, fica evidente o impacto da melhor resolução espacial das imagens MSI/Sentinel-2 na segmentação das classes temáticas definidas, permitindo a melhor definição de alvos que já eram visualizados nas imagens OLI/Landsat 8, porém indo além e conseguindo individualizar inúmeras pequenas manchas relacionadas a

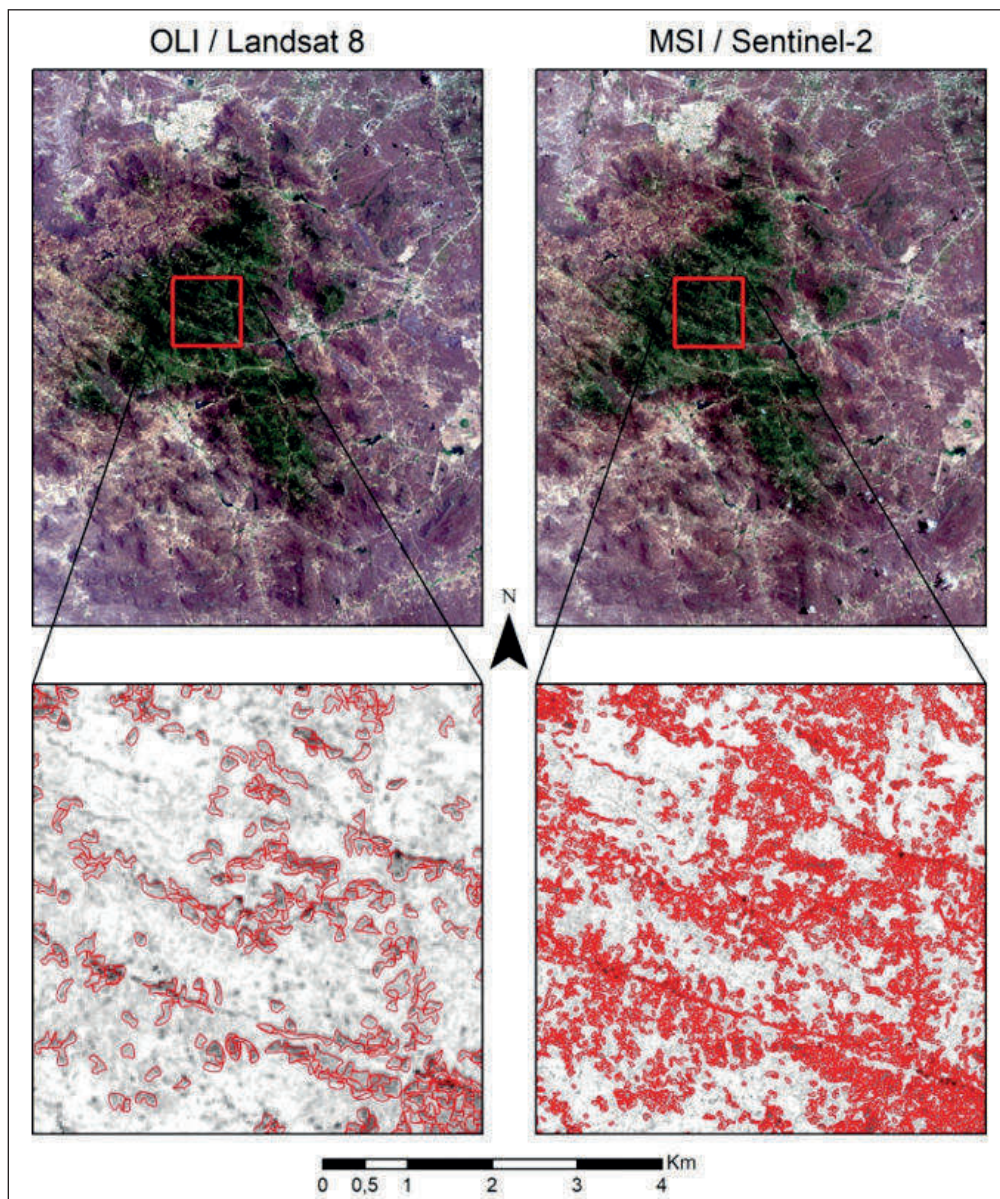


Figura 3
Recorte das imagens
NDVI com polígonos de
segmentação sobrepostos.

Sensor / Satélite	Nº de polígonos	Área média
OLI / Landsat 8	31.861	≅ 55.757 m ²
MSI / Sentinel-2	252.199	≅ 6.961 m ²

Tabela 6 Número de polígonos gerados na segmentação para cada NDVI e suas respectivas áreas médias.

áreas com graus variados de intervenção antrópica. Tais porções são relacionadas a áreas de cultivos nas vertentes do maciço, bem como estradas e solos expostos. Alguns exemplos destas áreas podem ser visualizados na Figura 4, onde, com a mudança de perspectiva do observador, é possível identificar

fortes intervenções agrícolas em áreas mais restritas que não são bem definidas nas imagens do sensor OLI, cuja menor resolução espacial dificulta a identificação e interpretação destes alvos. Estas constatações reafirmam as colocações de Shimabukuro & Ponzoni (2017), que ponderam a respeito da influência da resolução espacial de um sensor na definição dos alvos. De acordo com os autores, quanto maior a resolução espacial, maiores também as chances de encontrar *pixels* puros. Desta forma, imagens Sentinel-2 têm uma tendência a minimizar a mistura espectral, definindo melhor os alvos desejados




Figura 4 Manchas de cultivos, delimitadas em traço vermelho, em vertentes no maciço de Uruburetama.

3.3 Mapeamento de Cobertura e Uso da Terra

As tabelas 7 e 8 apresentam as matrizes de erros de classificações das imagens NDVI geradas a partir das imagens OLI/Landsat-8 e MSI/Sentinel-2. A matriz de erros de classificação mostra a distribuição de porcentagem de *pixels* classificados correta e erroneamente. E por meio dos resultados gerados são calculados o coeficiente Kappa e a Exatidão Global, que indicam a qualidade do mapeamento realizado.

Como pode ser observado na tabela 7, na classificação da imagem NDVI/Landsat-8, o índice Kappa apresentou o valor de 0,426, o que indica uma boa classificação conforme a tabela de desempenho. Já a exatidão global apresentou um melhor desempenho, com o valor de 0,511, porém verifica-se o baixo percentual de acurácia do usuário e do produtor para as classes caatinga densa, caatinga aberta, urbano/solo

exposto, mata seca e cultivos. O que indica um baixo percentual de acerto de classificação em relação a verdade terrestre e também um baixo percentual de acerto de pixel de referência classificado corretamente para essas classes.

Tal fato pode estar relacionado a grande dificuldade do operador em discernir numa imagem OLI/Landsat-8 os diferentes extratos vegetacionais, que não apresentam faixas de transições nítidas e, em alguns casos, respostas distintas em virtude da mistura espectral. Soma-se a isso as práticas agrícolas, com o corte da vegetação e plantio de variados cultivos, com diferentes fisionomias, que contribuem para dificultar a interpretação dos alvos.

A Classificação obtida a partir da imagem NDVI/Sentinel-2 obteve um índice Kappa de 0.883 e a exatidão global de 0.857, atestando uma excelên-

Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no Mapeamento de Cobertura e Uso da Terra no Maciço de Uruburetama, Ceará

Eduardo Viana Freires; Cláudio Ângelo da Silva Neto; Dominick Sávio Rocha Cunha;
Cynthia Romariz Duarte; César Ulisses Vieira Veríssimo & Daniel Dantas Moreira Gomes

Classes	Mata Úmida	Mata Seca	Caatinga Densa	Caatinga Aberta	Urbano/Solo Exposto	Corpos D'água	Cultivos	Total	Acurácia Usuário	Kappa
Mata Úmida	43	0	0	0	1	0	3	47	0.9148	0
Mata Seca	0	17	10	2	9	0	11	49	0.3469	0
Caatinga Densa	0	13	36	7	12	0	7	75	0.48	0
Caatinga Aberta	0	1	8	15	4	0	4	32	0.4687	0
Urbano/Solo Exposto	0	0	1	4	13	7	3	28	0.4642	0
Corpos D'água	0	0	1	0	1	29	0	31	0.9354	0
Cultivos	7	20	4	13	9	9	26	88	0.2954	0
Total	50	51	60	41	49	45	54	350	0	0
Acurácia Produtor	0.86	0.3333	0.6	0.3658	0.2653	0.6444	0.4814	0	0.5114	0
Kappa	0	0	0	0	0	0	0	0	0	0.4262

Tabela 7 Matriz de erros de classificação da imagem NDVI/Landsat -8

te classificação conforme a tabela de desempenho. Conforme pode ser observado na tabela 08, tanto a acurácia do usuário quanto do produtor apresentou percentuais altos, demonstrando, respectivamente, a compatibilidade da classificação com a verdade terrestre e os pixels de referência classificados corretamente. O melhor resultado obtido a partir da imagem MSI/Sentinel-2 indica que sua melhor resolução espacial permitiu inferir e/ou distinguir com maior precisão os alvos. O que também diminuiu possíveis confusões entre classes pelo algoritmo de classificação.

As figuras 5 e 6 apresentam os mapas gerados a partir da classificação supervisionada por crescimento de regiões das imagens NDVI obtidas das imagens OLI/Landsat-8 e MSI/Sentinel 2, respectivamente.

Ao observar as classes de Cobertura e uso da terra desses mapas, é possível identificar uma certa compatibilidade na distribuição espacial das classes temáticas. Contudo, como pode ser verificado na

Tabela 9, que traz um comparativo das áreas das classes mapeadas de ambas as imagens, as unidades de Cobertura e uso da terra apresentaram algumas variações na extensão de suas áreas. Essas desconformidades na extensão das áreas das classes de uso de cobertura do solo estão relacionadas às diferentes resoluções espaciais das imagens das quais foram obtidas.

A diferença de resolução espacial das imagens contribui para respostas espectrais distintas. Conforme Shimabukuro & Ponzoni (2017), os objetos refletem, transmitem e absorvem a radiação eletromagnética incidente de maneira particular. Cada objeto contido dentro de um elemento de resolução no terreno irá refletir mais ou menos do que outro dentro de uma determinada faixa espectral. Consequentemente, o valor de radiância efetivamente medido em uma determinada faixa espectral será fortemente influenciado pelo objeto que refletir mais intensamente nessa mesma faixa espectral. Desta forma, sensores que apresentem produtos com uma forte correlação positiva, mas que apresentem relativa diferen-

Classes	Mata Úmida	Mata Seca	Caatinga Densa	Caatinga Aberta	Urbano/Sol. Exposto	Corpos D'água	Cultivos	Total	Acurácia Usuário	Kappa
Mata Úmida	46	1	1	0	0	0	0	48	0.9583	0
Mata Seca	0	45	2	0	0	1	1	49	0.9183	0
Caatinga Densa	0	1	46	1	0	0	3	51	0.9019	0
Caatinga Aberta	0	0	2	40	2	0	5	49	0.8163	0
Urbano/Solo Exposto	0	0	5	0	40	1	5	51	0.7843	0
Corpos D'água	0	0	2	0	4	43	0	49	0.8775	0
Cultivos	4	4	2	0	3	0	40	53	0.7547	0
Total	50	51	60	41	49	45	54	350	0	0
Acurácia Produtor	0.92	0.8823	0.7666	0.9756	0.8163	0.9555	0.7407	0	0.8571	0
Kappa	0	0	0	0	0	0	0	0	0	0.8332

Tabela 8 Matriz de erros de classificação da imagem NDVI/Sentinel-2.




Figura 5
Mapa de Cobertura e uso da terra gerado a partir da imagem NDVI/Landsat-8.




Figura 6
 Mapa de Cobertura e uso da terra gerado a partir da imagem NDVI/Sentinel-2.

Classes de Cobertura e Uso da Terra	OLI / Landsat 8	MSI / Sentinel-2
Mata Úmida	109,311592	93,291866
Mata Seca	278,722946	166,630904
Caatinga Densa	374,074262	352,264876
Caatinga Aberta	118,684344	76,257872
Urbano/solo exposto	74,273088	126,917904
Corpos D'água	5,856381	5,663893
Cultivos	384,041266	523,936564
Total (km²)	1344,963879	1344,963879

Tabela 9 Comparação das áreas das unidades de Cobertura e uso da terra.

ça entre suas resoluções espaciais, que é o caso da comparação entre OLI/Landsat 8 e MSI/Sentinel-2, podem apresentar distorções quanto às unidades de Cobertura e uso da terra detectadas, justamente pela melhor capacidade de definição dos alvos do sensor MSI, sendo capaz de diferenciar duas ou mais classes numa mesma área, o que no sensor OLI seria somente uma espécie de alvo.

Ao analisar o mapa gerado da imagem MSI/Sentinel 2 em conjunto com a figura 7 é possível verificar que as classes Urbano/Solo exposto e Cultivos apresentaram maior extensão que as mesmas classes do mapa gerado a partir da imagem OLI/Landsat-8. Essa maior abrangência decorre do fato da resolução

da imagem MSI/Sentinel-2 permitir ao classificador individualizar e identificar com maior precisão áreas como Urbano/Solo exposto e Cultivos do que na imagem OLI/Landsat-8, com menor resolução espacial. Neste caso, a segmentação, que antecede a classificação, gera polígonos maiores, cuja abrangência individualizam classes em detrimento de outras. Assim, no mapa gerado a partir imagem OLI/Landsat-8 verifica-se maior ocorrência das demais unidades de Cobertura e uso da terra: Mata Úmida, Mata Seca, Caatinga Aberta, Caatinga Densa.

Essas variações de áreas das classes de Cobertura e uso da terra podem ser visualizadas nos mapas temáticos. No mapa gerado a partir da imagem MSI/Sentinel-2 observa-se que a unidade Urbano/Solo Exposto, na cor vermelha, está mais disseminada, sendo possível identificar com maior clareza o delineamento das estradas. Assim como é possível perceber uma maior distribuição da Classe Cultivos, na cor laranja, que devido a melhor resolução se individualiza e “incorpora” as áreas de outras unidades temáticas. O que fica claro pela diferença observada na classe Mata Úmida dos dois mapas temáticos.

No tocante às aplicações das imagens OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento de cobertura e uso da terra, compreende-se que ambas apresentaram resultados satisfatórios, que são atestados pelos coeficientes Kappa e exatidão global.

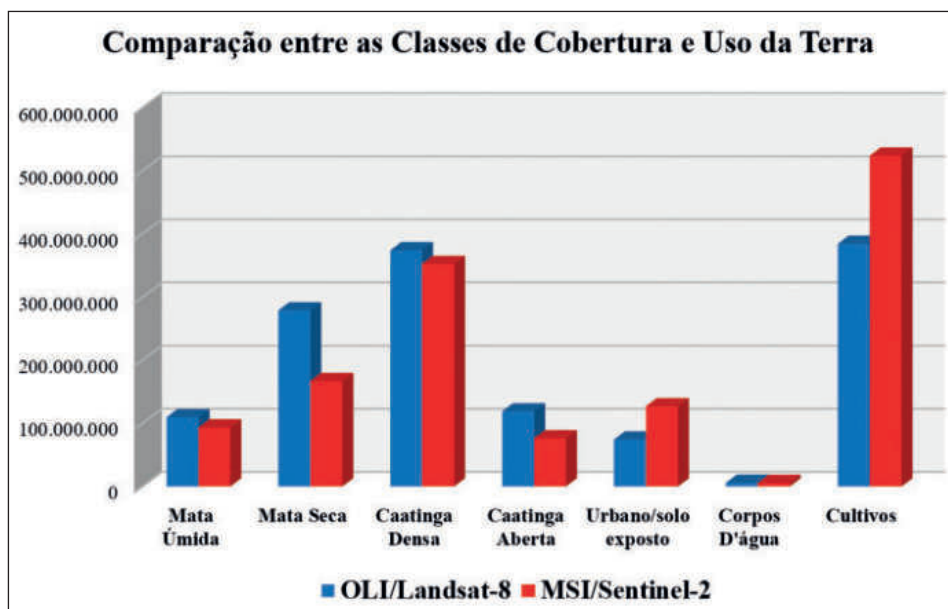


Figura 7 Comparação entre as áreas das unidades de Cobertura e uso da terra obtidas a partir da classificação das imagens NDVI, geradas das imagens OLI/Landsat-8 e MSI/Sentinel-2.

Porém, em virtude da extensão da área mapeada, representada numa escala de 1:200.000, verifica-se um melhor desempenho da imagem MSI/Sentinel-2, por permitir maior distinção entre os alvos e maior detalhamento das áreas mapeadas, chegando a uma representação mais condizente com a realidade observada. O que sugere a possibilidade de seu emprego tanto em estudos em escala de análise regional, como também em aplicações que demandem maiores escalas de representação cartográfica. Já a imagem OLI/Landsat-8, apesar do resultado apresentado, demonstrou ser mais adequada a estudos com menores níveis de detalhes, ou com alvos mais homogêneos.

4 Conclusões

Ao comparar a aplicação das imagens OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento de cobertura e uso da terra da vertente úmida do Maciço de Uruburetama, verificou-se, a partir do Índice de Vegetação por Diferença Normalizada, que as cenas apresentaram alta correlação.

Os mapeamentos de cobertura e uso da terra, gerados a partir dos NDVI's, obtidos das imagens OLI/Landsat-8 e MSI/Sentinel-2, apresentaram resultados satisfatórios, que foram atestados pelo procedimento de validação das classificações supervisionadas pelo algoritmo *Bhattacharya*. A classificação da imagem NDVI/Landsat-8 apresentou índice Kappa de 0,426 e exatidão global de 0,514, indicando um bom desempenho. Enquanto a classificação da imagem NDVI/Sentinel-2 apresentou índice Kappa de 0,833 e exatidão global de 0,857, que atesta uma excelente classificação.

Quando comparados visualmente, os mapeamentos apresentaram semelhanças na distribuição espacial das classes temáticas. Porém, foi possível verificar incompatibilidade das áreas dessas classes. Fato que está relacionado com a resposta espectral dos alvos mapeados em função da resolução espacial de cada cena. A imagem MSI/Sentinel-2 permitiu, a partir da classificação supervisionada, maior detalhamento das classes Urbano/Solo exposto, Corpos D'água e Cultivos, enquanto a imagem OLI/Landsat-8 gerou as classes Mata Úmida, Mata Seca, Caa-

tinga Densa e Caatinga Aberta com maior abrangência que a anterior.

Quando se trata da aplicação dessas imagens no mapeamento de cobertura e uso da terra, compreende-se que ambas apresentaram resultados satisfatórios. No entanto, considerando a extensão da área de análise dessa pesquisa, e a sua respectiva escala de representação, compreende-se que a imagem MSI/Sentinel-2, devido a sua melhor resolução espacial, permite um maior detalhamento dos alvos, e maior acurácia na classificação. O que possibilita o seu emprego tanto nos estudos em escala regional, como em aplicações que demandem maiores escalas de representação cartográfica. Por sua vez, a imagem OLI/Landsat-8, demonstrou ser mais adequada a estudos com menores níveis de detalhes, ou com alvos mais homogêneos. Sendo muitas vezes necessário trabalhar com um número menor de classes temáticas no intuito de reduzir os erros de classificação e conseqüentemente garantir um mapeamento mais compatível com a verdade.

5 Agradecimentos

Os autores agradecem ao Programa de Pós-Graduação em Geologia da Universidade Federal do Ceará, a Coordenação de Aperfeiçoamento de Nível Superior (CAPES) e a Fundação Cearense de Apoio ao Desenvolvimento, Científico e Tecnológico (FUN-CAP) pelo apoio para realização dessa pesquisa.

6 Referências

- Almeida, R.F.B.; Júnior, L.G.F. & Bayer, M. 2018. Análise da cobertura e uso da terra da bacia hidrográfica do Rio do Coko e suas implicações sobre as áreas de preservação permanente como instrumento na gestão dos recursos hídricos. *Desenvolvimento e Meio Ambiente*, 49: 60-82.
- Baret, F. & Guyot, G. 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35 (2 e 3): 161-173.
- Bins, L.S.; Fonseca, L.M.G.; Erthal, G.J. & Li, F.M. 1996. Satellite imagery segmentation: a region growing approach. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 8, Salvador, 1996. *Artigos completos*, São José dos Campos, INPE, p.677-680.
- Chuvieco, E. 1990. *Fundamentos de teledeteção espacial*. Madrid, Unigraf. 453 p.
- Congalton, R.G. A 1991. A review of assessing the accuracy classifications of remotely sensed data. *Remote Sensing*

Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no Mapeamento de Cobertura e Uso da Terra no Maciço de Uruburetama, Ceará

Eduardo Viana Freires; Cláudio Ângelo da Silva Neto; Dominick Sávio Rocha Cunha;
Cynthia Romariz Duarte; César Ulisses Vieira Veríssimo & Daniel Dantas Moreira Gomes

- Environment*, 37: 35-46.
- Congalton, R.G. & Green, K. 1999. *Assessing the Accuracy of Remotely Sensed Data: principles and practices*. New York, Lewis Publishers. 137 p.
- Demarchi, J.C.; Piroli, E.L. & Zimback, C.R.L. 2011. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo-SP usando imagens LANDSAT-5. *RA'E GA - O Espaço Geográfico em Análise*, 21: 234-271.
- Freires, E.V. & Mendes, L.M.S. 2012. Análise da cobertura vegetal do município de Maracanaú/CE dos anos de 1991 e 2006. *GeoUECE*, 1 (1): 44-55.
- Gürtler, S.; Luiz, A.J.B. & Epiphânio, J.C.N. 2003. Uniformização de imagens Landsat para previsão de safras agrícolas. In: Simpósio Brasileiro de Sensoriamento Remoto, 11, Belo Horizonte, 2003. *Artigos completos*, São José dos Campos, INPE, p. 109-116.
- INPE. SPRING, Sistema de Processamento de Informações Georreferenciadas: *manual de ajuda*. São José dos Campos: INPE, 2004.
- IPECE, Instituto de Pesquisa e Estratégia Econômica do Ceará. Ceará em Mapas: Mapa das Unidades Fitoecológicas do Ceará. 1 mapa: 21x29,7 cm. Em: <<http://www2.ipece.ce.gov.br/atlas/>>. Acesso em: 30 mai. 2018.
- JENSEN, R.J. 2009. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. São José dos Campos, Parêntese. 585 p.
- Landis, J.R. & Koch, G.G. 1977. The measurement of observer agreement for categorical data. *Biometrics*, 33 (1): 159-174.
- Lillesand, T.M.; Kiefer, R.W. & Chipman, J.W. 2004. *Remote sensing and interpretation*. 5ed. Madison, Wiley. 763 p.
- Lobão, J.S. B.; França-Rocha, W.J.S. & Silva, A.B. 2005. Aplicação dos índices Kappa & PABAK na validação da classificação automática de imagem de satélite em Feira de Santana – BA. In: Simpósio Brasileiro de Sensoriamento Remoto, 12, Goiânia, 2005. *Artigos completos*, São José dos Campos, INPE, p. 1207-1214.
- Mukaka, M.M. 2012. A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, 24 (3): 69-71.
- Mather, P.M. 2004. *Computer processing of remotely-sensed images: an introduction*. Chichester, John Wiley & Sons. 324 p.
- Nascimento, S.S.; De Lima, E.R.V. & De Lima, P.P.S. 2014. Análise Temporal da degradação da Caatinga Na Sub-Bacia Do Alto Paraíba. *Okara: Geografia em debate*, 8 (1): 72-94.
- Novo, E.M.L.M. 2008. *Sensoriamento Remoto: princípios e aplicações*. São Paulo, Blucher. 363 p.
- Rosenback, R.; França, A.M.S. & Florenzano, T.G. 2005. Análise comparativa dos dados NDVI obtidos de imagens CCD/CBERS-2 e TM/LANDSAT-5 em área urbana. In: Simpósio Brasileiro de Sensoriamento Remoto, 12, Goiânia, 2005. *Artigos completos*, São José dos Campos, INPE, p. 1075-1082.
- Rovedder, J. 2007. *Validação da classificação orientada a objetos em imagens de satélite Ikonos II e elaboração de indicadores ambientais georreferenciados no município de Torres, planície costeira do Rio Grande do Sul, Brasil*. Programa de Pós-graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Dissertação de Mestrado, 83p
- Salis, H.H.C.; Costa, A.M. & Viana, J.H.M. 2016. Análise do uso e ocupação do solo nas APP de curso d'água da bacia do córrego Marinheiro por meio de NDVI aplicado em imagens Landsat 8 e Ikonos-II. *Geografias*, 22: 40-53.
- Sanches, I.D.A.; Andrade, R.G.; Quartaroli, C.F. & Rodrigues, C.A.G. 2011. Análise comparativa de três métodos de correção atmosférica de imagens Landsat 5 – TM para obtenção de reflectância de superfície e NDVI. In: Simpósio Brasileiro de Sensoriamento Remoto, 15, Curitiba, 2011. *Artigos completos*, São José dos Campos, INPE, p. 7564-7571.
- Shimabukuro, Y.E. & Ponzoni, F.J. 2017. *Mistura Espectral: modelo linear e aplicações*. São Paulo, Oficina de Textos. 127 p.
- Silva, M.V.C. 2007. *Análise Geoambiental: subsídios ao planejamento agrícola da Serra de Uruburetama – Ce*. Programa de Pós-Graduação em Geografia, Universidade Estadual do Ceará, Dissertação de Mestrado, 191p.
- USGS, 2018. *United States Geological Survey*. Em: <<http://earthexplorer.usgs.gov/>>. Acesso em: 5 mai. 2018.