

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E
TECNOLOGIAS DA GEOINFORMAÇÃO

ULISSES ALENCAR BEZERRA

**ÍNDICES ESPECTRAIS UTILIZANDO OS SENSORES OLI/LANDSAT-8 E
MSI/SENTINEL-2, NA BACIA HIDROGRÁFICA DO RIO MOXOTÓ-PE**



Recife
2019

ULISSES ALENCAR BEZERRA

**ÍNDICES ESPECTRAIS UTILIZANDO OS SENSORES OLI/LANDSAT-8 E
MSI/SENTINEL-2, NA BACIA HIDROGRÁFICA DO RIO MOXOTÓ-PE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como parte dos requisitos para obtenção do grau de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Área de concentração: Cartografia e Sistemas de Geoinformação.

Orientadora: Prof. Dra. Leidjane Maria Maciel de Oliveira

Recife
2019

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

B574i Bezerra, Ulisses Alencar.
Índices espectrais utilizando os sensores OLI/Landsat-8 e MSI/Sentinel-2, na
bacia hidrográfica do rio Moxotó-PE / - 2019.
112 folhas, il., tab., abr. e sigl.

Orientadora: Prof^a. Dr^a. Leidjane Maria Maciel de Oliveira.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa
de Pós-Graduação em Engenharia Cartográfica e de Agrimensura, 2019.
Inclui Referências.

1. Engenharia Cartográfica. 2. Análise multisensor. 3. Índices biofísicos.
4. Classificação *random forest*. 5. Fusão de imagens. I. Oliveira, Leidjane Maria
Maciel de (Orientadora). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2019-092

ULISSES ALENCAR BEZERRA

**ÍNDICES ESPECTRAIS UTILIZANDO OS SENSORES OLI/LANDSAT-8 E
MSI/SENTINEL-2, NA BACIA HIDROGRÁFICA DO RIO MOXOTÓ-PE**

Dissertação apresentada à Universidade Federal de Pernambuco como parte dos requisitos para obtenção do título de mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovada em: 19/02/2019.

BANCA EXAMINADORA

Prof^a. Dr^a. Leijdane Maria Maciel de Oliveira (Orientadora)
Universidade Federal de Pernambuco

Prof^a. Dr^a. Josiclêda Domiciano Galvício (Examinadora Externa)
Universidade Federal de Pernambuco

Prof^o. Dr. Alfredo Ribeiro Neto (Examinador Externo)
Universidade Federal de Pernambuco

*À minha mãe, Valcir, que se tornou
um anjo, ao meu pai, Cláudio, que
me ensinou a dar meu melhor, à
minha irmã Raíssa, e à minha noiva
Luísa por todo o amor.*

AGRADECIMENTOS

A Deus, pelo dom da vida, por sempre estar guiando e iluminando meus caminhos, por me proporcionar saúde e força de vontade para seguir firme na busca por meus objetivos, só tenho a agradecer por tudo que a vida tem me dado.

À minha família, em especial aos meus pais Cláudio e Valcir (*in memoriam*), e a minha irmã Raíssa, pelo amor, confiança, apoio e incentivo durante toda minha vida e por compreender a minha ausência em determinados momentos.

À minha amada noiva, Luísa, pelo amor, paciência, dedicação, e companheirismo durante todos os dias dessa minha jornada, me inspirando a buscar ser uma pessoa melhor, e a batalhar com mais determinação por nossos objetivos.

Meu profundo e sincero agradecimento a minha orientadora, Prof. Dra. Leidjane Maria Maciel de Oliveira, pessoa especial que me deu total liberdade para executar o trabalho. Por ter acreditado no meu potencial desde o início, acompanhando-me, sempre solícita, cordial e disposta ao diálogo sempre que necessário. Pela excelente orientação, ensinamentos, paciência, confiança e pelo exemplo de dedicação ao trabalho, profissional experiente e de exemplo incontestável. Muito obrigado Professora e minha amiga!

A Joana Muricy e Águida Carvalho, por todo o apoio e incentivo na execução desse trabalho, muito obrigado queridas!

A todos os professores e ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação. E à CAPES pela concessão da bolsa fundamental ao desenvolvimento deste trabalho.

À Elisabeth Galdino, pela pessoa ímpar que és, pela solicitude e gentileza com que sempre trata a todos na secretaria da Pós-graduação. Assim também a todos os funcionários, que sempre se encontram dispostos a ajudar de forma especial aos que vem de longe.

Aos meus colegas de turma, com quem sempre pude contar nos momentos de dúvidas, e onde encontrei acima de tudo, bons amigos. Em especial à Antônio Celso, Kelly Ferri, Lucas Lima, Absalão Nascimento e Thalles Ramon.

A todos, que de maneira direta ou indireta contribuíram para a realização deste trabalho.

Muito obrigado a todos!

RESUMO

Os sensores remotos têm evoluído em escala crescente, no que diz respeito às resoluções espacial, espectral e temporal. A aplicação conjunta de sistemas/sensores multiespectrais das plataformas dos satélites Landsat-8 e Sentinel-2, é muito importante e eficaz para aplicações de mudanças ambientais. Assim, a comparação cruzada entre os dois satélites torna-se indispensável para o uso complementar das imagens. A pesquisa propõe analisar o comportamento espectral e espacial entre os sensores: OLI/Landsat-8 e MSI/Sentinel-2 na bacia hidrográfica do rio Moxotó. A análise entre os sensores OLI e MSI, revelou que as características radiométricas e espectrais dos sensores, ainda que semelhantes, não são idênticas e podem produzir diferenças consideráveis. Avaliaram-se as bandas do visível, infravermelho próximo e infravermelho médio, entre os sensores, em níveis de reflectância topo da atmosfera (TOA) e de superfície (BOA), em dois períodos distintos agosto e dezembro, do ano de 2017. Os resultados assinalam que as maiores diferenças médias, entre os sensores estão na região do infravermelho próximo, ao se comparar a banda 5 do OLI com a 8 do MSI, contudo essa diferença é reduzida ao se comparar com a 8A do MSI. O presente estudo também mostrou a fusão das imagens 8 e 8A do sensor MSI, pelo algoritmo *Local Mean and Variance Matching* (LMVM), os resultados expõem que a banda fusionada obteve coeficientes de R^2 superiores a 0,837, ao se comparar com a banda 5 do OLI em reflectância TOA, e superiores a 0,856 em reflectância BOA. Calcularam-se os índices NDVI, SAVI, ARVI, EVI e NDMI, para o sensor MSI utilizando a banda 8, e também com a banda fusionada, e ambos foram comparados com os índices obtidos com o OLI. Os índices obtidos com a banda fusionada se mantiveram mais próximo do sensor OLI, tanto em valores médios como visualmente. A classificação por meio do *Random Forest* obteve coeficiente do Kappa superiores quando se utilizou os índices em reflectância BOA. A classificação *Random Forest* também foi feita considerando a sobreposição das combinações dos índices espectrais onde a qualidade do coeficiente Kappa foi excelente, avaliando todas as combinações feitas. A composição, que obteve melhor representação das classes, foi aquela com todos os índices espectrais, onde o menor valor de exatidão do produtor foi de 0,69, com o sensor MSI, nos demais casos os valores de exatidões do produtor e usuário foram superiores a 0,80.

Palavras-chave: Análise multisensor. Índices biofísicos. Classificação *random forest*. Fusão de imagens.

ABSTRACT

Remote sensors have evolved on a growing scale, with respect to spatial, spectral and temporal resolutions. The joint application of multispectral systems/sensors of the Landsat 8 and Sentinel-2 satellite platforms is very important and effective for applications of environmental changes. Thus, the cross-comparison between the two satellites becomes indispensable for the complementary use of the images. The research proposes to analyze the spectral and spatial behavior between the sensors: OLI/Landsat-8 and MSI/Sentinel-2 in the watershed of the Moxotó River. The analysis between the OLI and MSI sensors revealed that the radiometric and spectral characteristics of the sensors, although similar, are not identical and can produce considerable differences. The bands of the visible, near infrared and medium infrared were evaluated between the sensors at the Top-Of-Atmosphere (TOA) and Bottom-Of-Atmosphere (BOA) reflectance levels, in two distinct periods in August and December, both of the year 2017. The results indicate that the largest average differences between the sensors are in the near infrared region when comparing the band 5 of the OLI with the 8 of the MSI, but this difference is reduced when compared to the 8A of the MSI. The present study also showed the fusion of the MSI sensor images 8 and 8A by the Local Mean and Variance Matching (LMVM) algorithm, the results show that the fused band obtained R^2 coefficients higher than 0.837, when compared to the band 5 of the OLI in TOA reflectance and higher to 0.856 in reflectance BOA. The NDVI, SAVI, ARVI, EVI and NDMI indices were calculated for the MSI sensor using band 8, and also with the fused band, and both were compared with the indexes obtained with the OLI. The indices obtained with the fused band remained closer to the OLI sensor, both in average values and visually. The classification through Random Forest obtained higher coefficient of Kappa when the indexes were used in reflectance BOA. The Random Forest classification was also made considering the overlap of spectral index combinations where the quality of the Kappa coefficient was excellent considering all the combinations made. The composition, which obtained a better representation of the classes, was the one with all the spectral indices, where the lowest accuracy value of the producer was 0.69, with the MSI sensor, in the other cases the values of producer and user accuracy were higher to 0.80.

Keywords: Multisensor analysis. Biophysical indices. Classification *random forest*. Image merging.

LISTA DE ILUSTRAÇÕES

Figura 1 – Interação da energia incidente com corpo d'água.....	19
Figura 2 – Curvas de reflectância espectral de alvos selecionados.....	20
Quadro 1 – Características do satélite Landsat-8	22
Quadro 2 – Comprimento de onda das bandas espectrais do satélite Landsat-8	23
Figura 3 – Missões Sentinel e as suas principais aplicações.....	25
Quadro 3 – Características do satélite Sentinel-2	25
Quadro 4 – Comprimento de onda das bandas espectrais do satélite Sentinel-2	26
Figura 4 – Funcionamento do método <i>Random Forest</i>	30
Figura 5 – Localização da área de estudo.....	38
Figura 6 – Correspondência da RSRF dos sensores OLI/Landsat-8 e MSI/Sentinel-2.	41
Figura 7 – Interface do <i>Local Mean and Variance Matching</i> no ambiente QGIS.....	43
Figura 8 – Interface do <i>Random Forest</i> no ambiente QGIS.	45
Figura 9 – Regime pluviométrico do posto Ibimirim com valores mensais de maio a dezembro de 2017.	46
Figura 10 – Gráfico de correlação entre: MSI Banda 8A × MSI Banda Fusionada, OLI Banda 5 × MSI Banda 8 e OLI Banda 5 × MSI Banda Fusionada. Reflectância TOA. A) agosto, 2017; B) dezembro, 2017.....	52
Figura 11 – Gráfico de correlação entre: MSI Banda 8A × MSI Banda Fusionada, OLI Banda 5 × MSI Banda 8 e OLI Banda 5 × MSI Banda Fusionada. Reflectância BOA. A) agosto, 2017; B) dezembro, 2017.	55
Figura 12 – Carta georreferenciada do índice NDVI para agosto de 2017, em reflectância TOA.....	57
Figura 13 – Carta georreferenciada do índice NDVI para dezembro de 2017, em reflectância TOA.....	58
Figura 14 – Carta georreferenciada do índice SAVI para agosto de 2017, em reflectância TOA.....	60
Figura 15 – Carta georreferenciada do índice SAVI para dezembro de 2017, em reflectância TOA.....	60
Figura 16 – Carta georreferenciada do índice ARVI para agosto de 2017, em reflectância TOA.....	63

Figura 17 – Carta georreferenciada do índice ARVI para dezembro de 2017, em reflectância TOA.....	64
Figura 18 – Carta georreferenciada do índice EVI para agosto de 2017, em reflectância TOA.....	66
Figura 19 – Carta georreferenciada do índice EVI para dezembro de 2017, em reflectância TOA.....	67
Figura 20 – Carta georreferenciada do índice NDMI para agosto de 2017, em reflectância TOA.....	69
Figura 21 – Carta georreferenciada do índice NDMI para dezembro de 2017, em reflectância TOA.....	70
Figura 22 – Representação gráfica das médias dos índices espectrais em nível de reflectância TOA.....	71
Figura 23 – Carta georreferenciada do índice NDVI para o período de agosto de 2017, em reflectância BOA.....	72
Figura 24 – Carta georreferenciada do índice NDVI para o período de dezembro de 2017, em reflectância BOA.....	73
Figura 25 – Carta georreferenciada do índice SAVI para o período de agosto de 2017, em reflectância BOA.....	76
Figura 26 – Carta georreferenciada do índice SAVI para o período de dezembro de 2017, em reflectância BOA.....	77
Figura 27 – Carta georreferenciada do índice ARVI para o período de agosto de 2017, em reflectância BOA.....	78
Figura 28 – Carta georreferenciada do índice ARVI para o período de dezembro de 2017, em reflectância BOA.....	79
Figura 29 – Carta georreferenciada do índice EVI para o período de agosto de 2017, em reflectância BOA.	80
Figura 30 – Carta georreferenciada do índice EVI para o período de dezembro de 2017, em reflectância BOA.....	81
Figura 31 – Carta georreferenciada do índice NDMI para o período de agosto de 2017, em reflectância BOA.....	82
Figura 32 – Carta georreferenciada do índice NDMI para o período de dezembro de 2017, em reflectância BOA.....	83
Figura 33 – Representação gráfica das médias dos índices espectrais em nível de reflectância BOA.	84

Figura 34 – Classificação pelo <i>Random Forest</i> dos índices espectrais em reflectância TOA, agosto de 2017.	85
Figura 35 – Classificação pelo <i>Random Forest</i> dos índices espectrais em reflectância TOA, dezembro de 2017.	86
Figura 36 – Classificação pelo <i>Random Forest</i> dos índices espectrais em reflectância BOA, agosto de 2017.	89
Figura 37 – Classificação pelo <i>Random Forest</i> dos índices espectrais em reflectância BOA, dezembro de 2017.	90
Figura 38 – Classificação pelo <i>Random Forest</i> das combinações dos índices espectrais em reflectância BOA, agosto de 2017.....	96
Figura 39 – Classificação pelo <i>Random Forest</i> das combinações dos índices espectrais em reflectância BOA, dezembro de 2017.	97

LISTA DE TABELAS

Tabela 1 - Imagens OLI/Landsat-8 e MSI/Sentinel-2 livres de nuvens disponíveis para a área de estudo.	39
Tabela 2 – Procedimento do nível de reflectância TOA e BOA dos satélites OLI/Landsat-8 e MSI/Sentinel-2.	40
Tabela 3 - Bandas espectrais das imagens OLI/Landsat-8 e MSI/Sentinel-2 selecionadas.	42
Tabela 4 - Índices espectrais usados neste estudo.....	44
Tabela 5 – Dados climáticos referentes as datas de aquisição das imagens.	46
Tabela 6 - Categorização de uma classificação a partir do valor do índice Kappa. ...	48
Tabela 7 – Softwares utilizados e sua aplicação na pesquisa.....	49
Tabela 8 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância TOA de cada sensor, referente a agosto/2017.....	50
Tabela 9 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância TOA de cada sensor, referente a dezembro/2017.	50
Tabela 10 – Diferença entre as médias das bandas utilizadas, entre os sensores, em reflectância TOA nos períodos analisados.	51
Tabela 11 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância BOA de cada sensor, referente a agosto/2017.....	53
Tabela 12 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância BOA de cada sensor, referente a dezembro/2017.	53
Tabela 13 – Diferença entre as médias das bandas utilizadas, entre os sensores, em reflectância BOA nos períodos analisados.....	54
Tabela 14 – Valores estatísticos dos NDVI em reflectância TOA de cada sensor. ...	56
Tabela 15 – Valores estatísticos dos SAVI em reflectância TOA de cada sensor.....	59
Tabela 16 – Valores estatísticos dos ARVI em reflectância TOA de cada sensor. ...	62
Tabela 17 – Valores estatísticos dos EVI em reflectância TOA de cada sensor.	65
Tabela 18 – Valores estatísticos dos NDMI em reflectância TOA de cada sensor....	68
Tabela 19 – Valores estatísticos dos NDVI em reflectância BOA de cada sensor. ...	71

Tabela 20 – Valores estatísticos dos SAVI em reflectância BOA de cada sensor. ...	74
Tabela 21 – Valores estatísticos dos ARVI em reflectância BOA de cada sensor. ...	74
Tabela 22 – Valores estatísticos dos EVI em reflectância BOA de cada sensor.....	75
Tabela 23 – Valores estatísticos dos NDMI em reflectância BOA de cada sensor. ...	75
Tabela 24 - Estatísticas gerais da classificação <i>Random Forest</i> em nível de reflectância TOA, para o período de agosto de 2017 e dezembro de 2017.	87
Tabela 25 - Teste z para significância da classificação <i>Random Forest</i> de diferentes índices espectrais em nível de reflectância TOA.....	88
Tabela 26 - Estatísticas gerais da classificação <i>Random Forest</i> em nível de reflectância BOA, para o período de agosto de 2017 e dezembro de 2017.	91
Tabela 27 - Teste z para significância da classificação <i>Random Forest</i> de diferentes índices espectrais em nível de reflectância BOA.	92
Tabela 28 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por <i>Random Forest</i> , agosto de 2017, reflectância BOA.....	93
Tabela 29 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por <i>Random Forest</i> , dezembro de 2017, reflectância BOA.....	94
Tabela 30 - Estatísticas gerais da classificação <i>Random Forest</i> em nível de reflectância BOA, para o período de agosto de 2017 e dezembro de 2017.	98
Tabela 31 - Teste z para significância da classificação <i>Random Forest</i> de diferentes combinações dos índices espectrais em nível de reflectância BOA.....	99
Tabela 32 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por <i>Random Forest</i> , agosto de 2017, reflectância BOA.....	100
Tabela 33 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por <i>Random Forest</i> , dezembro de 2017, reflectância BOA.....	101

LISTA DE ABREVIATURAS E SIGLAS

APAC	Agência Pernambucana de Águas e Clima
ARVI	<i>Atmospherically Resistant Vegetation Index</i>
BF	Banda Fusionada
BOA	<i>Bottom-Of-Atmosphere</i>
ESA	Agência Espacial Europeia
EVI	<i>Enhanced Vegetation Index</i>
LANDSAT	<i>Land Remote Sensing Satellite</i>
LMVM	<i>Local Mean and Variance Matching</i>
MSI	<i>MultiSpectral Instrument</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDMI	<i>Normalized Difference Moisture Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
OLI	<i>Operational Land Imager</i>
PCA	<i>Principal Component Analysis</i>
RF	<i>Random Forest</i>
ROI	Regiões de Interesse
RSRF	<i>Relative Spectral Response Function</i>
SAM	<i>Spectral Angle Mapper</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SEN2COR	<i>Sentinel-2 Atmospheric Correction</i>
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SNAP	<i>Sentinel Application Platform</i>
SR	Sensoriamento Remoto
SWIR	<i>Short Wave Infrared</i>
TIRS	<i>Thermal Infrared Sensor</i>
TOA	<i>Top-Of-Atmosphere</i>
USGS	<i>United State Geological Survey</i>
UTM	Universal Transversa de Mercator

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivo Geral	18
1.2	Objetivos Específicos	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Sensoriamento Remoto	19
2.2	Sistemas sensores	21
2.2.1	Landsat-8	21
2.2.2	Sentinel-2	24
2.2.3	Estudos entre os satélites Landsat-8 e Sentinel-2	27
2.3	Fusão de Imagens	28
2.3.1	Fusão pelo algoritmo LMVM (<i>Local Mean and Variance Matching</i>)	28
2.4	Classificador <i>Random Forest</i>	30
2.5	Índices espectrais	31
2.5.1	Normalized Difference Vegetation Index – NDVI	31
2.5.2	Soil Adjusted Vegetation Index – SAVI	32
2.5.3	Atmospherically Resistant Vegetation Index – ARVI	33
2.5.4	Enhanced vegetation index – EVI	34
2.5.5	Normalized Difference Moisture Index – NDMI	35
3	MATERIAL E MÉTODOS	37
3.1	Caracterização da Área de Estudo	37
3.1.1	Aspectos Gerais	37
3.1.2	Delimitação da Área de Estudo	38
3.2	Escolha, Aquisição e Pré-processamento das imagens	39
3.3	Fusão das Imagens	42
3.4	Aplicação dos Índices Espectrais	44
3.5	Classificação <i>Random Forest</i>	44
3.6	Dados Meteorológicos	45
3.7	Análise Estatística	47
3.8	Softwares Utilizados	48
4	RESULTADOS E DISCUSSÃO	50
4.1	Análise das bandas espectrais entre os Sensores OLI e MSI	50
4.2	Avaliação dos Índices Espectrais	55
4.3	Classificação Supervisionada pelo método <i>Random Forest</i>	84

4.3.1	Classificação dos Índices Espectrais em reflectância TOA	84
4.3.2	Classificação dos Índices Espectrais em reflectância BOA	88
5	CONCLUSÃO	102
6	SUGESTÃO DE TRABALHOS FUTUROS	103
	REFERÊNCIAS	104

1 INTRODUÇÃO

Ao longo dos anos os sensores remotos evoluíram em escala crescente, sobretudo no que diz respeito às resoluções espacial, espectral e temporal. A série de satélites LANDSAT (*Land Remote Sensing Satellite*) vem fornecendo valiosos conjuntos de dados para monitorar e mapear a superfície terrestre por mais de 40 anos.

O satélite Landsat-8, lançado em 2013, aprimorou a capacidade de imagem desta série, apresentando novas faixas espectrais nas faixas de infravermelho, azul e de onda curta (SWIR), além de melhorar a relação sinal/ruído do sensor e a resolução radiométrica das imagens. O sensor *Operational Land Imager* (OLI) fornece imagens ópticas com 30 m de resolução espacial, sua faixa imageada é de 185 km, oito bandas espectrais e dezesseis dias de resolução temporal (ZHU e WOODCOCK, 2014; SOTHE et al., 2017a).

Na constante evolução dos sensores, surge o satélite Sentinel-2, lançado em 2015, que apresenta um sensor multiespectral de resolução espacial média/alta produzido pela Agência Espacial Europeia (ESA). Seu sensor, o *MultiSpectral Instrument* (MSI) apresenta uma larga faixa imageada (290 km), boa resolução temporal (cinco dias, com dois satélites, Sentinel-2A e Sentinel-2B), resolução espacial alta e média (10, 20 e 60 m) e contém treze bandas espectrais (DRUSCH et al., 2012; SOTHE et al., 2017a).

Diante de um número cada vez maior de sistemas/sensores de observação da Terra, a aplicação conjunta de dados de sensoriamento remoto adquiridos de múltiplos sensores é muito importante e eficaz para monitorar mudanças ambientais globais. E ainda vem a contribuir para aquisição de imagens livres de nuvens e/ou data de aquisição mais próximas, que por vezes dificulta estudos no sensoriamento remoto, além de gerar análises mais fiéis do ambiente estudado (TEILLET et al., 2007; CHEN et al., 2013; LI, JIANG e FENG, 2014; OLIVEIRA, 2015; MOUSIVAND et al., 2015).

De acordo com Li et al. (2017), os sensores OLI do Landsat-8 e MSI do Sentinel-2, em conjunto, podem constituir em uma fonte importante para a observação multiespectral, com cobertura global e acesso livre e aberto. No entanto, o maior desafio de usar dados de sensoriamento remoto de várias fontes é a intercalibração

entre diferentes sistemas sensores. Nesse caso, a comparação cruzada entre múltiplos sensores torna-se indispensável para o uso complementar de imagens.

Nas aplicações do Sensoriamento Remoto (SR), índices espectrais são desenvolvidos para monitorar e qualificar as condições e distribuições espaciais dos diferentes alvos presentes na superfície terrestre, como estruturas vegetais, espaços construídos, corpos hídricos, usando os dados digitais de reflectâncias espectrais da radiação eletromagnética. Tais índices podem ser calculados por razão, diferenças e somas pela combinação linear das bandas espectrais, em geral por meio das bandas do visível, e infravermelho (próximo e/ou de ondas curtas) (JACKSON e HUETE, 1991; SANTOS et al., 2015).

O sensor MSI, possui duas bandas referentes ao infravermelho próximo, a banda B8 e a B8A, com comprimentos de onda entre 0,78 a 0,90 μm , e 0,85 a 0,87 μm , com resoluções espaciais de 10 e 20 metros, respectivamente. Já a banda do infravermelho do sensor OLI tem comprimento de onda entre 0,85 a 0,88 μm , e resolução espacial de 30 metros (MANDACINI e BITELLI, 2016; LI et al., 2017). Uma possibilidade de uso conjunto das bandas do MSI e OLI é testar o comportamento de índices espectrais, utilizando a fusão das bandas 8 e 8A, e avaliar seu desempenho em relação aos índices obtidos com o sensor OLI.

De acordo com Lu et al. (2013), avaliar o comportamento espectral dos alvos terrestres, por meio dos índices espectrais, e distinguir diferentes tipos de cobertura e/ou uso da terra, constitui-se como uma estrutura essencial para estudos voltados para análise ambiental, gestão e planejamento de recursos naturais, compreensão dos processos hidrológicos, diagnóstico da dinâmica no espaço urbano e rural, entre outras finalidades.

Neste contexto, o uso de classificadores tem se destacado, principalmente no mapeamento de grandes extensões geográficas e em locais de difícil acesso. Estas técnicas são viáveis e menos onerosas que os trabalhos a campo (SOTHE et al., 2017b). O *Random Forest* é um tipo de classificador, que tem a vantagem de conseguir lidar com a elevada variância temporal da reflectância da vegetação; possuir uma alta velocidade de processamento; necessita de poucos parâmetros a serem definidos pelo usuário (SILVEIRA, 2018).

A bacia hidrográfica do rio Moxotó - PE, objeto de estudo desta pesquisa, está localizada no semiárido do Nordeste brasileiro. Por se situar no semiárido, a bacia é caracterizada pelo baixo volume e pela alta variabilidade (espacial, temporal e

volumétrica) de sua precipitação que, aliada a temperatura elevada, produz déficit hídrico em praticamente o ano todo (FRANCISCO et al., 2012; SILVEIRA et al., 2018).

A bacia é coberta de norte a sul, em 89% da área, por Caatinga, considerado um *hotspot* de biodiversidade pela riqueza da fauna e flora. A área de estudo dessa pesquisa ainda contempla o reservatório Engenheiro Francisco Sabóia, conhecido como Poço da Cruz sendo o maior reservatório do interior do estado de Pernambuco (MELO, 2010). E o Parque Nacional do Catimbau, um remanescente de Caatinga, de extrema importância neste contexto por apresentar números relevantes de endemismos e espécies raras (SAMPAIO et al., 2002; CASTRO, FABRICANTE e SIQUEIRA FILHO, 2016).

Deste modo, estudos comparativos de índices espectrais entre os sensores OLI/Landsat-8 e MSI/Sentinel-2 ainda não foram reportados no ambiente da Caatinga, bem como uso de classificador *Random Forest* comparando esses índices na distribuição espacial e temporal da bacia hidrográfica do rio Moxotó - PE.

1.1 Objetivo Geral

Analisar o comportamento espectral e espacial dos alvos de superfície sob o ponto de vista dos índices espectrais e classificação supervisionada na bacia hidrográfica do rio Moxotó entre os sensores: OLI/Landsat-8 e MSI/Sentinel-2.

1.2 Objetivos Específicos

Para se alcançar os objetivos gerais, os seguintes objetivos específicos são propostos:

- Comparar as bandas do visível, infravermelho próximo e de ondas curtas das imagens dos sensores OLI e MSI, em níveis de reflectância topo da atmosfera (TOA) e de superfície (BOA);
- Fusionar as bandas 8 e 8A, referente as imagens do sensor MSI/Sentinel-2; com o intuito de conservar respostas espectrais da banda 8A, adquirindo a resolução espacial da banda 8;
- Analisar o comportamento espectral dos índices: NDVI, SAVI, ARVI, EVI e NDMI, a partir dos sensores OLI e MSI, na área de estudo;
- Avaliar as classificações supervisionadas dos índices espectrais pelo método *Random Forest*, utilizando estatísticas para avaliação temática, entre os sensores OLI e MSI.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão abordados os temas conceituais e teóricos que servirão de alicerce para o desenvolvimento desta pesquisa, bem como para auxiliar na compreensão das análises e na interpretação dos dados.

2.1 Sensoriamento Remoto

Historicamente, reconhece-se Sensoriamento Remoto (SR) como a capacidade de se obter informação sobre um objeto (alvo), área ou fenômeno através da análise de dados adquiridos por um dispositivo (sensor) que não está em contato direto com o objeto, área ou fenômeno sob investigação (LILLESAND, KIEFER, e CHIPMAN, 2015).


De acordo com Lillesand, Kiefer, e Chipman (2015), quando a energia eletromagnética incide em algum objeto ou alvo da superfície terrestre, três interações fundamentais de energia são possíveis. A energia incidente no elemento pode ser refletida, absorvida e/ou transmitida. A capacidade de refletir a energia incidente indica a reflectância de um objeto, assim como a absorptância indica a capacidade de um objeto absorver essa energia. Aplicando o princípio de conservação de energia, é possível chegar à seguinte relação:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda) \quad (1)$$

onde: E_I = Energia Incidente, E_R = Energia Refletida, E_A = Energia Absorvida, E_T = Energia Transmitida e λ os comprimentos de onda.

Essas interações podem ser observadas na Figura 1, que representa a interação da energia incidente com um corpo d'água.


Figura 1 – Interação da energia incidente com corpo d'água.



Fonte: LILLESAND, KIEFER, e CHIPMAN (2015).

Jensen (2011) e Lillesand, Kiefer, e Chipman (2015), afirmaram que a proporção de energia refletida, absorvida e transmitida varia de acordo com os diferentes alvos terrestres, que vem a depender do tipo, material e condição. Essas diferenças de comportamento permitem ao observador distinguir diferentes objetos em uma mesma imagem. Outro fator determinante para a identificação de alvos é a faixa do comprimento de onda que o alvo está submetido, um mesmo objeto pode ter diferentes proporções de energia refletida, absorvida e transmitida, a depender do comprimento de onda. Dessa forma, dois objetos podem ser semelhantes em uma faixa espectral e bem diferentes em outra banda de comprimento de onda.

Jensen (2011), destacou que os dados advindos dos sensores remotos podem ser empregados no estudo de diversos alvos, entre eles: Vegetação (Estruturas e altura do dossel, Biomassa derivada de índices de vegetação, Evapotranspiração), Solo e Rochas (Umidade, Composição mineral, Taxonomia, Alteração hidrotermal) Água (Cor, Hidrologia de Superfície, Minerais/Clorofila/Material orgânico em suspensão, Material orgânico dissolvido), Neve e Gelo Marinho (Extensão e características), Efeitos Vulcânicos (Temperatura, gases), Uso da Terra (Comercial, Cadastral, Mapeamento para taxaço). A Figura 2 representa curvas espectrais de alguns alvos com relação a energia por eles refletida.



Os estados da arte destacam os trabalhos que utilizaram o sensoriamento remoto, Bezerra et al. (2017), que utilizaram técnicas de SR para análise multitemporal de índices de vegetação na bacia hidrográfica do rio Moxotó. Leite et al. (2017), compararam índices de umidade na região do perímetro irrigado Nilo Coelho. Wang et al. (2018), avaliaram o desempenho de Sentinel-2, Landsat-8 e Pléiades-1 no Mapeamento de Extensão e Espécies de Manguezais. Halabisky, Babcock e Moskal (2018), exploraram como as características temporais podem ser usadas para classificar objetos quando a distinção entre propriedades espectrais, espaciais ou outros atributos são limitados. Grosso et al. (2018), mapearam a evapotranspiração do milho usando o SEBAL (*Surface Energy Balance Algorithm for Land*) e compararam com as estimativas de evapotranspiração pelo método da FAO (Organização das Nações Unidas para a Alimentação e a Agricultura). Souza et al. (2018), utilizaram dados de umidade do solo do SMOS L3 (*Soil Moisture Ocean Salinity*) utilizando duas bases de dados *in situ* para o estado de Pernambuco, após a validação, os dados do SMOS foram utilizados para a avaliação da seca, calculando as anomalias de umidade do solo para o período disponível de dados.

2.2 Sistemas sensores

Atualmente, um grande número de sensores orbitais está disponível para o monitoramento global da superfície terrestre, cada um deles com diferentes características espectrais, espaciais e radiométricas. À vista disso, é útil combinar e analisar estes dados e, assim, aproveitar suas diferentes características para melhorar o processo de extração de informações em imagens de satélite (FONSECA; MANJUNATH, 1996).

Para um melhor entendimento dos sistemas sensores utilizados nesse trabalho, se faz necessário aprofundar o conhecimento acerca dos conceitos fundamentais, características gerais dos sensores e os parâmetros de imageamento.

2.2.1 Landsat-8

O programa LANDSAT (*Land Remote Sensing Satellite*) foi desenvolvido pela NASA (*National Aeronautics and Space Administration*) e captura imagens da superfície terrestre desde 1972, criando assim um acervo incomparável de milhões de

cenas. O primeiro satélite da série chamava-se *Earth Resources Technology Satellite* (ERTS-A), posteriormente renomeado para Landsat 1 (USGS, 2016).

Ainda de acordo com a USGS (2016), o Landsat-8 é o mais recente lançamento da série, batizado originalmente de *Landsat Data Continuity Mission* (LDCM), mais tarde rebatizado de Landsat 8, foi lançado em 11 de fevereiro de 2013, operando com os sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS). O grande diferencial do sucessor da série Landsat não está apenas na inclusão de novas bandas, mas também na sua resolução radiométrica de 12 bits, que são dimensionados para inteiros de 16 bits e entregues aos usuários.

De acordo com Roy et al. (2014), o principal sensor do Landsat-8 é o OLI, que apresenta todas as bandas já existentes no Landsat-5, e gera dados em duas novas bandas, na banda azul profundo (banda 1) para observar a atmosfera e a qualidade da água em lagos e águas costeiras rasas e, uma banda *Cirrus* para observar nuvens de alta altitude (banda 9).

O sensor infravermelho termal, o TIRS, gera dados em duas bandas com resolução espacial de 100 m (bandas 10 e 11), em comparação com uma única banda termal com resolução 120 m do Landsat 5, o que melhora bastante as estimativas da temperatura da superfície e possibilita um monitoramento mais eficiente do consumo de água, especialmente em regiões áridas. Por fim, ainda apresenta uma banda pancromática de 15 m (ROY et al., 2014; USGS, 2016). O Quadro 1 apresenta as características do sistema satélite Landsat-8.

Quadro 1 – Características do satélite Landsat-8.

Satélite	Landsat-8
Data Lançamento	11/02/2013
Instrumentos Sensores	OLI e TIRS
Bandas Espectrais	11 bandas: (9 bandas OLI e 2 bandas TIRS)
Resolução Temporal	16 dias
Resolução Radiométrica	16 bits (65536 níveis de cinza).
Resolução Espacial	30 m (Bandas 1 - 7 e 9)
	15 m (Banda 8)
	100 m (Bandas 10 e 11)
Sistema Geodésico de Referência	WGS84
Sistema de projeção	UTM

Fonte: Adaptado de USGS (2016).

Os produtos digitais dos sensores acoplados aos satélites estão disponíveis por bandas. Cada banda representa a resposta do alvo em certa faixa do espectro eletromagnético. No Quadro 2 é possível observar as faixas espectrais das bandas disponíveis no satélite Landsat-8.

Quadro 2 - Comprimento de onda das bandas espectrais do satélite Landsat-8.

Banda	Comprimento de onda (µm)	Banda Espectral
Banda 1	0,43 – 0,45	Coastal aerossol
Banda 2	0,45 – 0,51	Blue
Banda 3	0,53 – 0,59	Green
Banda 4	0,64 – 0,67	Red
Banda 5	0,85 – 0,88	Near Infrared
Banda 6	1,57 – 1,65	Shortwave Infrared 1
Banda 7	2,11 – 2,29	Shortwave Infrared 2
Banda 8	0,50 – 0,68	Panchromatic
Banda 9	1,36 – 1,38	Cirrus
Banda 10	10,60 – 11,19	Thermal Infrared 1
Banda 11	11,50 – 12,51	Thermal Infrared 2

Fonte: Adaptado de USGS (2016).

Dentre os trabalhos publicados, utilizando este satélite, destacam-se Wei et al. (2018), que avaliaram esquemas de correção atmosférica Landsat-8 e produtos de refletância de SR em recifes de corais e águas costeiras turvas, e confirmaram que o instrumento Landsat-8 pode de fato fornecer medições reflectância de alta qualidade para águas superficiais.

Markogianni et al. (2018), avaliaram o potencial do Landsat-8 na estimativa de clorofila-a, concentrações de amônia e outros indicadores de qualidade da água, por meio de análise de regressão entre a refletância de superfície Landsat-8 e os dados simultâneos *in-situ* do lago Trichonis localizado na Grécia, e constataram que o lançamento de sistemas de sensores espaciais, como o Landsat-8, pode ajudar a melhorar a capacidade de estimar as propriedades lacustres de água doce.

Karakizi et al. (2018), mapearam a cobertura da Terra a partir dos dados multitemporais do Landsat-8 com diferentes coberturas de nuvens, formando conjuntos de dados experimentais de imagens Landsat-8 com cobertura de nuvens que foram gradativamente aumentadas para avaliar a influência da presença de nuvens nos dados de referência e a precisão da classificação resultante.

2.2.2 Sentinel-2


O Sentinel-2, é um satélite com sensor multiespectral de resolução espacial média produzido pela Agência Espacial Europeia (ESA), foi arquitetado para assegurar a continuidade da cobertura de dados globais da Terra realizada pelas séries de satélites LANDSAT e SPOT (do francês *Satellite Pour l'Observation de la Terre*). Esta missão foi lançada em 2015 e o sensor *MultiSpectral Instrument* (MSI) apresenta uma larga faixa imageada (290 km), boa resolução temporal (cinco dias, com dois satélites), resolução espacial alta e média (10, 20 e 60 m) e um número relativamente alto de bandas (13 bandas espectrais), e o tamanho da cena disponibilizada é de 100 por 100 km (DRUSCH et al., 2012; SOTHE et al., 2017a).

O plano de longo prazo é lançar e manter uma série de satélites Sentinel-2 (nomeados 2A, 2B, etc.) durante vários anos, com o Sentinel-2A lançado em 23 de junho de 2015 e o Sentinel-2B lançado em 7 de março de 2017. Cada um tem uma vida planejada de sete anos, e outros lançamentos são planejados com o mesmo instrumento em anos posteriores (FLOOD, 2017).

Esta missão pertence à família de satélites desenvolvida pela ESA como parte do Programa Copernicus de Observação da Terra. Esta é uma iniciativa conjunta da ESA e da Comissão Europeia e tem como objetivo a implementação de serviços de informação direcionados para o ambiente e para a segurança. As missões Sentinel, são divididas em 5 famílias de satélites: a missão Sentinel-1, equipada com radar imageador na banda C; a missão Sentinel-2, aparelhado com um imageador multiespectral; a missão Sentinel-3, que será dotada de diferentes instrumentos para medir diversos parâmetros da terra e do mar; e as missões Sentinel-4 e Sentinel-5, voltadas para a aquisição de dados da composição atmosférica (ASCHBACHER e MILAGRO-PÉREZ, 2012; ESA, 2013).

Na Figura 3, é possível observar as várias missões Sentinel e as suas principais aplicações.

Figura 3 – Missões Sentinel e as suas principais aplicações.

Sentinel-1	Sentinel-2	Sentinel-3	Sentinel-4	Sentinel-5	Jason-CS
					
Imagens SAR	Imagens Multiespectrais	Monitorização global terrestre e Oceano	Atmosférico Geoestacionário	Atmosférico de baixa órbita	Altimetria de baixa inclinação
1. Monitorização de gelo e ambientes polares; 2. Monitorização de movimentos da superfície terrestre; 3. Cartografia de florestas, água, solo e agricultura.	1. Cobertura do solo, uso do solo e mapas de deteção de mudanças de uso do solo; 2. Mapas de risco; 3. Mapas geofísicos de variabilidade.	1. Dados de cor do mar e solo; 2. Temperaturas da superfície terrestre e do mar; 3. Altimetria de alta resolução.	1. Monitorização de mudanças da composição da atmosfera; 2. Mapeamento diário de gases a nível global e regional.	1. Monitorização de mudanças da composição da atmosfera; 2. Mapeamento diário de gases a nível global e regional.	1. Monitorização de mudanças a nível do mar; 2. Oceanografia.

Fonte: Adaptado de ESA (2013).

O Quadro 3 apresenta as características do sistema satélite Sentinel-2.

Quadro 3 – Características do satélite Sentinel-2.

Satélite	Sentinel-2
Data Lançamento	2A - 23/06/2015 2B - 07/03/2017
Instrumentos Sensores	MSI
Bandas Espectrais	13 bandas
Resolução Temporal	5 dias
Resolução Radiométrica	12 bits (4096 níveis de cinza).
Resolução Espacial	10 m (Bandas 2 - 4 e 8) 20 m (Banda 5 - 8A, 11 e 12) 60 m (Bandas 1, 9 e 10)
Sistema Geodésico de Referência	WGS84
Sistema de projeção	UTM

Fonte: Adaptado de ESA (2017).

As bandas do Sentinel-2 cobrem as regiões espectrais do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). As quatro bandas com resolução espacial de 10 metros (2, 3, 4 e 8), foram definidas para manter a compatibilidade com os produtos SPOT, enquanto que as bandas de 20 metros de resolução espacial, foram arquitetadas para observar principalmente as características da vegetação (borda vermelha da vegetação e a banda de absorção da lignina). As bandas de resolução espacial de 60 metros são destinadas a correção

atmosférica (ESA, 2017). No Quadro 4 é possível observar as faixas espectrais das bandas disponíveis no satélite Sentinel-2.

Quadro 4 – Comprimento de onda das bandas espectrais do satélite Sentinel-2.

Banda	Comprimento de onda (µm)	Banda Espectral
Banda 1	0,43 – 0,45	Aerossol
Banda 2	0,46 – 0,52	Blue
Banda 3	0,54 – 0,58	Green
Banda 4	0,65 – 0,68	Red
Banda 5	0,7 – 0,71	Red-edge-1
Banda 6	0,73 – 0,75	Red-edge-2
Banda 7	0,76 – 0,78	Red-edge-3
Banda 8	0,78 – 0,90	Near Infrared
Banda 8A	0,85 – 0,87	Near Infrared plateau
Banda 9	0,93 – 0,95	Water vapor
Banda 10	1,36 – 1,39	Cirrus
Banda 11	1,56 – 1,65	Shortwave Infrared -1
Banda 12	2,10 – 2,28	Shortwave Infrared -2

Fonte: Adaptado de ESA (2017).

Antes mesmo do lançamento do primeiro satélite Sentinel-2, diversos autores testaram suas características no mapeamento de propriedades químicas e físicas da vegetação. Nestes estudos e em outros trabalhos que simularam dados do Sentinel-2, foi encontrada boa correlação com a reflectância ao se estimar diversos atributos biofísicos e bioquímicos, como a clorofila e o IAF (FRAMPTON et al., 2013); a radiação fotossinteticamente ativa (DONG et al., 2015); a biomassa acima do solo (SIBANDA MUTANGA e ROUGET, 2015); e o IAF verde e senescente (DELEGIDO et al., 2015).

Os dados do sensor MSI/Sentinel-2 são disponibilizados ao público como reflectância no topo da atmosfera e são orto-corrigidos (nível 1C), sendo possível a correção para a reflectância de superfície (nível 2A) por meio do algoritmo *Sentinel-2*

Atmospheric Correction (Sen2Cor) que está disponível no software SNAP (*Sentinel Application Platform*) disponibilizada pela ESA. Este algoritmo utiliza as bandas de aerossol (443 nm), de absorção de vapor d'água atmosférico (945 nm) e de nuvens cirros (1375 nm) em funções de transferência radiativa, oriundas de *lookup tables* (LUT) e geradas a partir da biblioteca *LibRadtran*, que calculam a radiação solar e termal na atmosfera terrestre (MUELLER-WILM, DEVIGN e PESSIOT, 2015; EMDE et al., 2016; LOUIS et al., 2016).

Como estado da arte destacam os trabalhos de Silveira et al. (2018), que estudaram a vegetação e suas relações com os atributos do solo no semiárido brasileiro por meio dos dados do satélite Sentinel-2 e LiDAR. Liu et al. (2018), analisaram o estresse induzido por metais pesados em lavouras de arroz, detectadas por séries temporais de imagens de satélite Sentinel-2. Lobo et al. (2018), mapearam áreas ativas de mineração (poços abertos) em larga escala na Amazônia Brasileira usando imagens Sentinel-2A aplicando um método de mapeamento de baixo tempo de processamento baseado em GEE (*Google Earth Engine*).

2.2.3 Estudos entre os satélites Landsat-8 e Sentinel-2

Visto que as imagens do satélite Landsat-8 vêm sendo utilizadas a bastante tempo e têm se consolidado como uma das principais ferramentas para a análise e avaliação de impactos ambientais, uso e cobertura do solo, estimativa de parâmetros biofísicos, georreferenciamento e planejamento agrícola e ambiental por todo o mundo, e que o Sentinel-2 tem potencial para as mesmas finalidades que o Landsat-8, estudos comparativos entre os satélites têm sido desenvolvidos.

Mandanici e Bitelli (2016), fizeram uma comparação preliminar do Sentinel-2 e Landsat-8, apontando as diferenças espectrais entre os sensores OLI e MSI, na perspectiva de um uso combinado dos dois para análises de séries temporais. Li et al. (2017), exploraram os aspectos da calibração cruzada radiométrica dos sensores MSI e OLI, com base em alvos comuns em ambos os sensores na região do deserto do Saara.

Padró et al. (2017), compararam as refletâncias de superfície obtidas através dos sensores ETM+, OLI e MSI com dados de espectroradiometria de campo. Além disso, os dados de campo também foram comparados com os resultados de algoritmos de correção atmosférica comumente usados, como o *ATROR3*, o plug-in *Semi-Automatic Classification* implementado no QGIS (*SAC-QGIS*), o *6S-LEDAPS* o

6S- LaSRC e o Sen2Cor. Zhang et al. (2018), caracterizaram as diferenças entre as reflectâncias: topo da atmosfera e reflectância da superfície corrigida atmosféricamente, e do índice de vegetação NDVI no Sentinel-2A e Landsat-8.

Pastick, Wylie e Wu (2018), propuseram uma análise espaço-temporal de dados Landsat-8 e Sentinel-2 para apoiar o monitoramento de ecossistemas de terras áridas, por meio de estruturas de modelagem de árvores de regressão onde combinaram informações coletadas pelo OLI e do MSI. Urban et al. (2018), estudaram o potencial de se obter informações de umidade e vegetação da superfície para monitoramento de secas no ecossistema de cerrado da parte sul do Parque Nacional Kruger, na África do Sul usando as séries temporais Sentinel-1, Sentinel-2 e Landsat-8.

2.3 Fusão de Imagens

Técnicas de fusão de imagens caracterizam um conjunto de operações utilizadas para integrar imagens de diferentes características, tais como a resolução espacial, e/ou espectral. O principal interesse da fusão de dados de imagem de resolução múltipla é criar imagens compostas de interpretabilidade aprimorada (WELCH e EHLERS, 1987; KACZYNSKI, DONNAY e MULLER, 1995). As imagens devem ter o maior conteúdo de informação espacial possível, preservando ao mesmo tempo uma boa qualidade de informação espectral (CLICHE et al., 1985).

Conforme Sivagami et al. (2015), a fusão de imagens tem muitas vantagens que abrangem aprimoramento de recursos, nitidez de imagens, e essa técnica é usada para muitas etapas de processamento de imagem, como segmentação de imagens, extração de recursos, identificação, detecção de objetos e detecção de alvo.

2.3.1 Fusão pelo algoritmo LMVM (*Local Mean and Variance Matching*)

Diferentes métodos de fusão foram propostos na literatura, usando Análise de Componentes Principais (PCA), Saturação, Intensidade Matiz (IHS) ou Filtros de Alta Passagem (HPF), foram mutuamente comparados em relação à preservação da informação espectral (CHAVEZ et al., 1991).

De modo recente, novos algoritmos de fusão foram criados para mesclar conjuntos de dados de imagens de multirresolução com preservação máxima da informação espectral, baseado em correspondência de média local (*Local Mean and*

Matching – LMM) ou em filtros de média local e variância correspondente (*Local Mean and Variance Matching* – LMVM) no domínio espacial permitem controlar a quantidade de informação espectral a ser preservada (BETHUNE, MULLER e BINARD, 1997).

Esses filtros aplicam funções de normalização (Joly, 1986) em uma escala local dentro das imagens, a fim de combinar a média local e/ou os valores de variação da imagem PAN com aqueles do canal espectral original de baixa resolução. As pequenas diferenças residuais remanescentes correspondem à alta informação espacial resultante da imagem PAN de alta resolução. Este tipo de filtragem aumenta drasticamente a correlação entre o produto fundido e o canal com baixa resolução. A quantidade de informação espectral preservada no produto fundido pode ser controlada ajustando os tamanhos das janelas de filtragem.

O algoritmo LMVM é dado por:

$$F_{i,j} = \frac{(H_{i,j} - \bar{H}_{i,j}) \times s(L)_{i,j(w,h)}}{s(H)_{i,j(w,h)}} + \bar{L}_{i,j} \quad (2)$$

onde: $F_{i,j}$ = Imagem fusionada; $H_{i,j}$ e $L_{i,j}$ = são respectivamente as imagens de alta e baixa resolução espacial nas coordenadas de pixel i, j ; $\bar{H}_{i,j}$ e $\bar{L}_{i,j}$ = são as médias locais calculados dentro da janela (w,h) e s é o desvio padrão local.

Witharana, Civco e Meyer (2013), analisaram como diferentes algoritmos de fusão executam quando aplicados a imagens de satélite de resolução espacial muito alta (VHSR), a avaliação envolveu doze algoritmos de fusão, dentre eles o LMVM. Considerando a fidelidade espacial e espectral, o desempenho do algoritmo LMVM superou nove técnicas de fusão, com coeficiente de correlação superior a 0,91 quando comparada com a imagem original.


Nikolakopoulos e Oikonomidis (2015) estudaram dez técnicas de fusão comumente usadas, implementadas em pacotes de software, aplicados aos dados do Worldview-2. O desempenho do LMVM foi bastante satisfatório com valores de correlação superiores a 0,89 entre as bandas comparadas. Duran et al. (2018), propuseram um novo modelo variacional não-local para o ajuste de imagens de satélite reais, e também realizaram uma comparação exaustiva entre o modelo proposto e os mais relevantes clássicos e técnicas, dentre eles o LMVM, e segundo o autor o LMVM se comporta muito bem em termos do índice SAM (*Spectral Angle Mapper*), na verdade, é o melhor método não-variacional a esse respeito.

2.4 Classificador *Random Forest*

A classificação de imagens tem um importante valor para estudos ambientais. Através dela é possível extrair as categorias de diferentes alvos da superfície terrestre.

O algoritmo *Random Forest* (RF) é um dos diversos algoritmos de aprendizado de máquinas que foi introduzido no sensoriamento remoto nos últimos anos (LARY et al., 2016). É baseado na combinação de árvores de decisão de modo que cada árvore dependa dos valores de um vetor randômico, amostrado independentemente e com a mesma distribuição de todas as árvores na floresta (BREIMAN, 2001). O RF constrói cada árvore usando um algoritmo determinístico, que seleciona um conjunto casual de variáveis com uma amostra aleatória a partir dos dados de calibração (RAMOELO et al., 2015). Depois que um grande número de árvores é gerado, cada uma delas classifica o pixel em análise em uma determinada classe. O somatório das diversas classificações determinará a classe final a qual aquele pixel pertence (BREIMAN, 2001; LARY et al., 2016). A Figura 4 apresenta o funcionamento do método *Random Forest*.

Figura 4 – Funcionamento do método *Random Forest*.



Fonte: OSHIRO (2013).

O algoritmo RF tem sido usado em mapeamentos de vegetação, detecção de alvos urbanos, entre outros, por meio do sensoriamento remoto apresentando bons resultados, uma vez que consegue acomodar diferentes respostas espectro-temporais, boa velocidade de classificação e de treinamento.

Sothe et al. (2017b), avaliaram metodologias para classificação do estágio sucessional da vegetação do Bioma Mata Atlântica, usando imagens RapidEye e Landsat-8, e testaram o desempenho dos algoritmos por aprendizagem de máquina RF e SVM e compará-los com o classificador máxima verossimilhança (Maxver). O RF teve melhor desempenho para discriminar as classes vegetação em estágio avançado e vegetação em estágio médio.

Wessel, Brandmeier e Tiede (2018), investigaram nos métodos OBIA versus os classificadores RF e SVM, por imagens do Sentinel-2, para classificação de tipos e espécies de árvores. Os resultados apontaram uma acurácia acima de 0,86 para a classificação por meio do RF. Halabisky, Babcock e Moskal (2018), usaram um modelo de RF para distinguir áreas úmidas de planaltos usando uma série temporal de 285 imagens de satélite Landsat (1984-2011), e detectaram que o RF melhorou a distinção entre objetos de terras úmidas e de terras altas explorando seu padrão temporal.

2.5 Índices espectrais

Índices espectrais são técnicas de transformação de imagens de sensoriamento remoto utilizados para realçar a resposta espectral de alvos da superfície terrestre e para avaliar e monitorar diferentes processos de mudanças de cobertura da terra. Estes índices resultam da combinação de respostas espectrais em duas ou mais bandas espectrais do espectro eletromagnético e são amplamente utilizados por sua simplicidade conceitual e eficiência computacional para realçar feições presentes na imagem (HUETE et al., 2002; SCHEPERS et al., 2014).

2.5.1 Normalized Difference Vegetation Index – NDVI

O Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI) foi proposto por Rouse et. al. (1973), com a finalidade de produzir um índice de vegetação com resposta espectral que separa vegetação verde a partir do seu brilho do solo de fundo.

Segundo Robinson et al. (2017), o NDVI é indiscutivelmente o índice espectral de detecção remota mais amplamente utilizado para monitorar a superfície terrestre.

A obtenção simples do NDVI e sua relação direta com a capacidade fotossintética da vegetação é um intermédio para estudos relacionados com características e funções vegetais essenciais como fração de radiação fotossintética absorvida pelo dossel, área foliar, produtividade primária bruta, com inúmeras aplicações na agricultura, silvicultura, ecologia, biodiversidade, análise ambiental, a exemplo da ciclagem de nutrientes, produtividade primária líquida, evapotranspiração, mudança das componentes ambientais, dentre outros (PONZONI, SHIMABUKURO e KUPLICH, 2012; ROBINSON et al., 2017).

Dentre os trabalhos mais atuais, relacionados a esse índice destacam-se: Konda et al. (2018), que avaliaram danos na vegetação devido ao ciclone “Hudhud” com base no NDVI usando imagens de satélite Landsat-8, antes e depois o ciclone. A estratégia de índice de vegetação foi utilizada para avaliar os danos à vegetação. Os resultados mostram que 13,25% da agricultura e 31,1% da vegetação foram danificadas.

Boke-Olén et al. (2018), detectaram remotamente a umidade do solo para estimar a savana NDVI, utilizando dados de umidade do solo como CCI, ASCAT, SMOS e AMSRE e estimaram o NDVI, feito isso compararam com os dados reais de NDVI do sensor MODIS, e constaram que o NDVI modelado pode potencialmente ser usados em conjunto com outros de dados de vegetação de sensoriamento remoto para melhorar a informação fenológica, melhorando assim as estimativas da fenologia da vegetação de savana.

Wilson e Norman (2018), fizeram uma análise da recuperação da vegetação em torno de uma área alagada restaurada usando o índice de infravermelho diferenciado normalizado (NDII) e NDVI, os resultados desses esforços de restauração podem ser avaliados usando imagens multiespectrais do Landsat para medir o verde da vegetação e o conteúdo de água. O NDVI foi capaz de rastrear melhor mudanças na vegetação em áreas sem pastoreio, enquanto o NDII foi melhor em rastrear mudanças em áreas com pastagem contínua.

2.5.2 Soil Adjusted Vegetation Index – SAVI

O Índice de Vegetação Ajustado para os Efeitos do Solo (*Soil Adjusted Vegetation Index – SAVI*) é uma proposta de Huete (1988), após verificar que as características do solo têm uma considerável influência no espectro de radiação

proveniente de dosséis vegetais e que a resposta espectral do solo em uma área com pouca cobertura vegetal poderia ser dominante sobre a resposta desta. Por isso, adicionou-se a constante L à equação do NDVI, originando dessa forma o SAVI. A constante L é um fator de ajuste dependente das propriedades do solo que tem a função de minimizar o efeito do solo no resultado final do índice (PONZONI, SHIMABUKURO e KUPLICH, 2012).

Ren, Zhou e Zhang (2018), desenvolveram um estudo onde utilizaram o fator de ajuste negativo do solo no índice SAVI para estimativa de biomassa viva acima do solo em pastagens áridas. Segundo os autores valores do fator de ajuste do solo (L) de 0 a 1 no SAVI mostraram-se indesejáveis em áreas áridas com cobertura vegetal esparsa. Diante disso hipotetizaram que o fator negativo de ajuste do solo no SAVI seria satisfatório em áreas áridas. Encontrando um fator negativo de ajuste do solo para uma redução satisfatória do ruído de fundo do solo $L = -0,2$ proporcionando melhorias significativas sobre o NDVI.

Kuiawski et al. (2017), avaliaram Índices de vegetação e delineamento de zonas de manejo para soja, e utilizaram o NDVI, SAVI e índice de razão simples, o mapa de produtividade das culturas foi tomado como referência para avaliar a concordância espacial com os diferentes mapas gerados a partir dos índices espectrais. Tendo destaque para o SAVI que apresentou a maior concordância com o mapa de produtividade da soja.

Dube et al. (2018), estudaram a relação entre o reservatório de carbono lenhoso de superfície e o reservatório de carbono do solo, usando métodos de sensoriamento terrestre e remoto, utilizando os Índices RVI, NDVI e o SAVI calculados a partir dos dados do satélite Landsat-8.

2.5.3 Atmospherically Resistant Vegetation Index – ARVI

O Índice de Vegetação Resistente à Atmosfera (*Atmospherically Resistant Vegetation Index* - ARVI) foi desenvolvido por Kaufman e Tanré (1992) como uma técnica de sensoriamento remoto baseada na reflectância das vegetações, utilizando plataformas orbitais.

Foi proposta uma adaptação na formulação do NDVI, fazendo-se a redução dos efeitos causados pela variação da opacidade atmosférica sobre o canal do Vermelho. O objetivo foi o de formar um índice de vegetação mais resistente às variações de reflectância das vegetações, sob a visada dos sensores orbitais,

ocorridas devido às mudanças de opacidade na atmosfera, que normalmente ocorrem devido à presença de aerossóis (dispersão coloidal de líquidos ou sólidos no ar), fumaças e poeiras (KAUFMAN e TANRÉ, 1992). O índice ARVI apresenta em sua formulação, a diferença entre os valores de reflectância do canal do Azul e os do Vermelho.

Dentre os trabalhos publicados recentemente destacam-se: Wang et al. (2017), que mapearam a biomassa de *Spartina alterniflora* utilizando dados LiDAR e hiperespectrais, os resultados mostraram que o maior coeficiente de correlação com a biomassa de *S. alterniflora* foi com a altura do dossel da vegetação (0,817), seguido pelo NDVI (0,635), e do ARVI (0,631).

Fan et al. (2015), em estudo apresentaram um método simples para mapeamento de plantações de seringueiras na região sudeste da China, usando a diferenciação de índices de vegetação entre eles o ARVI, por meio de dados do satélite Landsat-8. Os resultados demonstram o potencial promissor da diferenciação de índices de vegetação baseada em fenologia para o mapeamento e monitoramento da expansão da seringueira em escala regional.

2.5.4 Enhanced vegetation index – EVI

O Índice de Vegetação Realçado (*Enhanced Vegetation Index* – EVI) foi proposto por Huete et al. (1997), tendo sido formulado a partir de uma combinação de outros dois índices de vegetação, o SAVI e o ARVI, com a finalidade de atenuar os efeitos do solo e da atmosfera sobre o monitoramento da vegetação. O EVI utiliza fatores de ajustes e a reflectância no azul para corrigir a influência indesejada da atmosfera e do solo, este último mais acentuado no ambiente semiárido, além disto, alguns trabalhos apontam que o EVI apresenta substancial melhora na sensibilidade às alterações do dossel em relação ao NDVI, principalmente em áreas de maior densidade de biomassa (JUSTICE et al., 1998; HUETE et al., 2002).

Dentre os trabalhos que utilizaram este índice destacam-se: Jarchow et al. (2018), que fizeram a comparação do EVI derivado do MODIS, e nas plataformas VIIRS, TM/Landsat-5 e OLI/Landsat-8. E encontraram alta correspondência entre Landsat e MODIS EVI ($R^2 = 0,93$ para toda a área estudada e 0,97 para campos agrícolas).

Manabe, Melo e Rocha (2018), que desenvolveram uma estrutura para o mapeamento de áreas de integração lavoura-pecuária em Mato Grosso, usando a

série temporal do EVI do MODIS. He et al. (2018), avaliaram as características temporais e espaciais do EVI, por meio de dados do MODIS, e sua resposta aos fatores climáticos nos últimos 16 Anos na Mongólia, China.

2.5.5 Normalized Difference Moisture Index – NDMI

O Índice de Umidade por Diferença Normalizada (*Normalized Difference Moisture Index* - NDMI) foi proposto por Gao (1996), é resultante da combinação das bandas espectrais do infravermelho próximo (NIR) e do infravermelho de onda curta (SWIR) sendo portanto o SWIR mais sensível a quantidade de água presente na vegetação e a umidade do solo. Hardisky, Klemas e Smart (1983) e Gao (1996) notaram que o índice baseado nas bandas do infravermelho próximo e infravermelho de ondas curtas, era altamente correlacionado com o conteúdo de água do dossel vegetal e conseguia acompanhar melhor mudanças na biomassa e nos estresses de umidade das plantas do que o NDVI.

Quanto a nomenclatura desse índice, existe uma certa confusão a respeito do NDMI estabelecido por Gao (1996), ele é comumente confundido com o Índice de Água de Diferença Normalizada (*Normalized Difference Water Index* - NDWI) estabelecido por McFeerts (1996), no qual tem como finalidade detectar águas superficiais em ambientes de zonas úmidas e permitir a medição da extensão da água superficial, e é calculado através da razão entre as reflectâncias das bandas do verde e infravermelho próximo. Leite et al. (2017), compararam os métodos de processamento de ambos os índices e comprovaram as potencialidades de cada metodologia, sendo que o índice proposto por Gao (1996) (NDMI) permitiu constatar a presença de água na estrutura interna da vegetação, bem como a presença de áreas inférteis, e que o índice proposto por McFeerts (1996) (NDWI) apresentou uma melhor delimitação dos corpos hídricos.

Outra confusão presente na literatura é quanto a obtenção do índice NDMI, por se tratar da diferença das reflectâncias do infravermelho próximo e do infravermelho de ondas curtas, dividido pela soma das mesmas. Este índice tem vários nomes na literatura, incluindo índice de infravermelho (II), índice de diferença de infravermelho normalizado (NDII), índice de umidade de diferença normalizada (NDMI), índice de superfície de água da terra (LSWI) e razão de queima normalizada (NBR), entre outros, (Ji et al., 2011).

Ji et al. (2011) propuseram-se analisar a definição de cada termo, e os sensores associados e as especificações de cada canal, e detectaram que o índice consiste em três variantes, diferindo apenas na região SWIR (1,2–1,3; 1,55–1,75 ou 2,05–2,45 μm). Assim, três termos são suficientes para representar essas três variantes do SWIR; outros nomes são redundantes e, portanto, desnecessários. Considerando a representatividade espectral, a popularidade do termo e a "regra de prioridade" na nomenclatura científica, NDMI, NDII e NBR, cada um correspondendo às três regiões SWIR, são termos mais preferíveis. Os autores ainda afirmam que o NDWI definido como $(\text{verde} - \text{NIR}) / (\text{verde} + \text{NIR})$ também foi desenvolvido independentemente por McFeeters (1996) para uso no delineamento de corpos d'água superficiais.

Como trabalhos utilizando o índice proposto por Gao (1996), destacam-se: Sharma et al. (2018), identificaram a evolução histórica das terras de cultivo irrigadas para as estações pós-monsoão e de verão na bacia hidrográfica de Berambadi, no sul da Índia. Para isso utilizaram três índices NDVI, NDMI e EVI, que foram derivados de imagens de satélite multi-temporais Landsat. As terras irrigadas e não irrigadas foram estimadas com alta precisão de classificação (coeficiente kappa maior que 0,9).

Teixeira, Candeias e Tavares Junior (2017), fizeram um comparativo de índices físicos, entre eles o NDMI com e sem a correção Dark Object Subtraction (DOS). Yang et al. (2017), mapearam corpos de águas superficiais urbanas a partir de imagens Sentinel-2 com 10m de resolução baseada no NDMI, e os resultados mostram que a imagem no NDMI apresenta maior capacidade de separação e é mais efetiva para os mapas de água em nível de classificação e em nível de fronteira do que as abordagens tradicionais.

3 MATERIAL E MÉTODOS

Nesta seção serão apresentados os materiais utilizados e a metodologia empregada para a execução da pesquisa.

3.1 Caracterização da Área de Estudo

A seguir é apresentado os aspectos gerais e delimitação da área de estudo dessa pesquisa.

3.1.1 Aspectos Gerais da bacia hidrográfica do rio Moxotó

O objeto de estudo desta pesquisa foi a bacia hidrográfica do Moxotó. Esta bacia contempla uma área de 9.752,71 Km², com 90% nos territórios em Pernambuco e acrescentando-se o restante de sua área ao estado de Alagoas. A bacia hidrográfica localiza-se entre as coordenadas 07°52'21" e 09°19'03" de latitude Sul, e entre as coordenadas 36°57'49" e 38°14'41" de longitude Oeste, e está inserida na Unidade de Planejamento Hídrico UP8, e totalmente no semiárido (APAC, 2018).

A bacia hidrográfica do rio Moxotó é coberta de norte a sul, em 89% da área, por Caatinga. É considerado um *hotspot* de biodiversidade pela riqueza da fauna e flora. A cultura cíclica ocupa 7% da bacia, enquanto que os 4% restantes são ocupados por vegetação arbórea aberta (MELO, 2010).

Os recursos minerais da bacia compreendem argila, areia quartzosa, amianto, calcário, cristais de quartzo, caulim, ferro, grafite, mármore, talco, vanádio e vermiculita. Destes, apenas o caulim é explorado economicamente (MMA, 1998).

Os solos existentes na bacia são bastante variados. São identificados mais de dez grupos pedológicos distintos. Há uma nítida predominância dos solos do tipo Bruno Não-Cálcicos ao norte da bacia, areias quartzosas álicas ao centro e planossolos solódicos eutróficos ao sul, bem como ao norte. Esta formação cria um triângulo imaginário formado pelas localidades de Sertânia, Arcoverde e Algodões.


O clima predominante na bacia é do tipo Bsh (Köppen), as chuvas médias anuais variam entre 500 e 1.100 milímetros, com distribuição irregular ao longo do ano, com período chuvoso de março a agosto (meses mais úmidos de maio a agosto), predominando a seca no restante do ano (meses mais secos de outubro a fevereiro). A única estação climatológica do INMET localizada no município de Arcoverde, PE, registrou uma média de 22,9 graus Celsius no período de 1961 a 1990. A ocorrência de temperaturas médias elevadas é consequência da forte radiação solar que incide na região.

3.1.2 Delimitação da Área de Estudo

A escolha da área de estudo foi estabelecida no critério que a região estivesse localizada no semiárido do Nordeste do Brasil, em seguida por a área de estudo representar bem o ambiente Caatinga, e que de acordo com a Secretaria de Ciência, Tecnologia e Meio Ambiente –SECTMA (2009)– a maior parte das demandas hídricas do estado de Pernambuco são para atendimento à irrigação, destacando-se a bacia do rio Pontal, a GI-8 e a bacia do rio Moxotó, onde a demanda para irrigação representa mais de 90% da demanda total da bacia.

Diante disso a área selecionada para este trabalho é parte da bacia hidrográfica do rio Moxotó. A delimitação da área de estudo foi a região que abrange o máximo possível das cenas de ambos os satélites OLI/Landsat-8 e MSI/Sentinel-2, e também que estivesse dentro da bacia, resultando na área em vermelho (Figura 5).

Figura 5 – Localização da área de estudo.



Fonte: O Autor (2018).

Vale salientar a grande diversidade de alvos dentro da área de estudo (trecho selecionado da bacia do Moxotó), encontram-se o Parque Nacional do Catimbau que segundo Corrêa, Cavalcanti e Lira, (2015) foi considerada uma área de grande endemismo e valor ecológico, cênico e arqueológico. O reservatório Engenheiro Francisco Sabóia, conhecido como Poço da Cruz, no qual sua bacia hidráulica cobre

uma área de 5.600 ha e com capacidade de acumulação de 504 hm³, sendo o maior reservatório interior do estado de Pernambuco. Centros urbanos a exemplo de Buíque, Ibimirim e Algodões. Além de perímetros irrigados, formações geológicas, solos expostos e recursos minerais diversos.

3.2 Escolha, Aquisição e Pré-processamento das imagens

Para a seleção das imagens buscou-se adquirir as que apresentassem menor presença de nuvens, e que as datas fossem o mais próximo possível de ambos os satélites estudados.

As cenas do Landsat-8 (*Worldwide Reference System2* – WRS-2, *Path/Row* 215/66), datadas de 15 de agosto de 2017 e 05 de dezembro de 2017, foram adquiridas do sítio do Serviço Geológico dos Estados Unidos (*United State Geological Survey* - USGS) (disponível gratuitamente em <https://www.earthexplorer.usgs.gov/>) em *Collection 1 Level-1* com correção radiométrica, geométrica e atmosférica no sistema de projeção cartográfica UTM/WGS84 (VERMOTE et al., 2016). Posteriormente as imagens foram convertidas em produto *Top-Of-Atmosphere* - TOA e em reflectância de superfície *Bottom-Of-Atmosphere* - BOA).

As cenas do Sentinel-2 foram adquiridas também na plataforma do USGS, datadas de 04 de agosto de 2017 e 07 de dezembro de 2017, onde suas cenas já são fornecidas como produto *Top-Of-Atmosphere* Nível-1C (L1C) com correção radiométrica e geométrica no sistema de projeção cartográfica UTM/WGS84. Os dados utilizados são apresentados na Tabela 1.

Tabela 1 - Imagens OLI/Landsat-8 e MSI/Sentinel-2 livres de nuvens disponíveis para a área de estudo.

Satélite	Cena	Data
Landsat-8	215/66	15/08/2017
Sentinel-2	T24LXR	04/08/2017
Landsat-8	215/66	05/12/2017
Sentinel-2	T24LXR	07/12/2017

Fonte: O Autor (2018).

Inicialmente, todas as bandas do MSI/Sentinel-2 foram importadas para a plataforma SNAP (*Sentinel Application Platform*) disponibilizada pela ESA para a correção atmosférica. Esta correção é realizada pelo processador *Sen2Cor* (MAIN-KNORN et al., 2015; MÜLLER-WILM, 2016), cuja saída do processamento é um produto de reflectância de superfície (BOA) *Level 2A*, reamostrado para uma resolução espacial de pixel igual para todas as bandas em que o usuário define com

base em três tamanhos 10m, 20m ou 60m (MÜLLERWILM, 2016). Sendo assim, considerou-se manter a resolução espacial das bandas originais.

Na Tabela 2 é apresentado como foi processado e/ou adquirido as imagens em nível de reflectância TOA e BOA dos satélites OLI/Landsat-8 e MSI/Sentinel-2.

Tabela 2 – Procedimento do nível de reflectância TOA e BOA dos satélites OLI/Landsat-8 e MSI/Sentinel-2.

Reflectância	OLI/Landsat-8	MSI/Sentinel-2
TOA	$\rho_{\lambda_i} = (M_{pi} * Q_{cal} + A_p) / \text{Sen}(\theta_{SE}) * \left(\frac{1}{d^2}\right)$	Adquiridas em www.earthexplorer.usgs.gov
BOA	Feito pedido em www.earthexplorer.usgs.gov e disponível cerca de três horas depois para download	Convertidas no SNAP, realizada pelo processador <i>Sen2Cor</i>

Onde: ρ_{λ_i} é a reflectância planetária com a correção do ângulo zenital; M_{pi} é o fator multiplicativo de cada banda, encontrado no arquivo metadados; A_p é o coeficiente de adição encontrado no arquivo metadados; i refere-se ao número da banda; Q_{cal} são os números digitais correspondentes a cada banda da imagem. θ_{SE} é o de elevação solar; d é distância Terra-Sol; presente no arquivo metadados (USGS, 2016; Ruhoff *et al.*, 2015; Silva *et al.*, 2016)


Fonte: O Autor (2018).

Mandanici e Bitelli (2016), indicaram a compatibilização da resposta espectral e radiométrica dos alvos presentes nas imagens dos sensores OLI/Landsat-8 e MSI/Sentinel-2 de acordo com as bandas espectrais correspondentes de cada sensor.

As funções de respostas espectrais médias (*Relative Spectral Response Function* – RSRF) das bandas utilizadas neste trabalho para os sensores OLI e MSI foram adquiridas através do site da USGS ([https:// landsat.usgs.gov/using-usgs-spectral-viewer](https://landsat.usgs.gov/using-usgs-spectral-viewer)) e são detalhadas na Figura 6. Em geral, as larguras de banda do OLI, na região do visível, são semelhantes as correspondentes larguras de banda do MSI.

Como pode ser observado na Figura 6 e Tabela 3, a banda vermelha do MSI apresenta a mesma variação de comprimento de onda (0,03 μm) que o sensor OLI, apesar que seu início e término sejam díspares, e apresenta regiões com menor resposta que a apresentada pelo OLI. No entanto, há uma diferença muito expressiva em relação à banda que cobre o infravermelho. A banda 8 do MSI se mostra muito mais larga e com resposta que diminui de 800 nm a 900 nm, semelhante ao Landsat-7 (She *et al.*, 2015). A largura da banda do OLI é muito mais estreita e com resposta mais uniforme e elevada.

Figura 6 – Correspondência da RSRF dos sensores OLI/Landsat-8 e MSI/Sentinel-2.



Fonte: Adaptado de USGS (2018).

Desta forma, ao se observar a semelhança da resposta espectral relativa das bandas do infravermelho próximo, do sensor OLI e da banda 8A (NIR plateau) do MSI, visto também que a banda 8 (NIR) do MSI, possui resolução espacial de 10m e que

seu intervalo espectral abrange o comprimento de onda da banda 8A, foi proposto a fusão das bandas 8 e 8A, referentes ao sensor MSI, com o objetivo de se obter uma imagem com 10m de resolução espacial, mas com informações espectrais da banda 8A, na qual se assemelha com a banda 5 do sensor OLI.

Sendo assim para este estudo, foram selecionadas as bandas do OLI/Landsat-8 e MSI/Sentinel-2 conforme a Tabela 3. Vale salientar que tanto as bandas, quanto os índices foram analisados em nível de reflectância TOA e BOA.

Tabela 3 - Bandas espectrais das imagens OLI/Landsat-8 e MSI/Sentinel-2 selecionadas.

Banda		OLI/Landsat-8		Banda	MSI/Sentinel-2	
		Comprimento de onda (μm)	Resolução Espacial		Comprimento de onda (μm)	Resolução Espacial
Azul	2	0,45 – 0,51	30 m	2	0,46 – 0,52	10 m
Verde	3	0,53 – 0,59	30 m	3	0,54 – 0,58	10 m
Vermelho	4	0,64 – 0,67	30 m	4	0,65 – 0,68	10 m
NIR	5	0,85 – 0,88	30 m	8	0,78 – 0,90	10 m
				8A	0,85 – 0,87	20 m
				BF	0,85 – 0,87	10 m
SWIR 1	6	1,57 – 1,65	30 m	11	1,56 – 1,65	20 m


BF: banda fusionada do sensor MSI.

Fonte: Elaborado pelo autor com dados extraídos de USGS (2018) e ESA (2017).

3.3 Fusão das Imagens

Nessa pesquisa a fusão das bandas 8 e 8A do sensor MSI, foram realizadas por meio do ORFEO Toolbox (OTB), um conjunto de algoritmos implementados em uma biblioteca de software, no qual pode ser incrementado no QGIS, mais detalhes sobre o processamento dos algoritmos podem ser vistos em Inglada e Christophe (2009) e ORFEO Toolbox (2017).

Em síntese os procedimentos para a fusão, consistiu em dois momentos: (1) Utilizar o *Superimpose*, que dimensiona a imagem a ser fusionada para a extensão e resolução da banda da requerida e; (2) Utilizar o *Pansharpening LMVM (Local Mean and Variance Matching)* para mesclar as cenas. Na Figura 7, é apresentado a interface do *software* dentro do ambiente QGIS.

Figura 7 – Interface do *Local Mean and Variance Matching* no ambiente QGIS.

3.4 Aplicação dos Índices Espectrais

A Tabela 4 resume os índices utilizados nesse estudo.

Tabela 4 - Índices espectrais usados neste estudo.

Índice Espectral	Fórmula OLI/Landsat-8	Resolução Espacial	Fórmula MSI/Sentinel-2	Resolução Espacial
NDVI (Rouse et al., 1973)	$(\rho_{B5} - \rho_{B4}) / (\rho_{B5} + \rho_{B4})$	30 m	$(\rho_{B8} - \rho_{B4}) / (\rho_{B8} + \rho_{B4})$ $(\rho_{BF} - \rho_{B4}) / (\rho_{BF} + \rho_{B4})$	10 m
SAVI (Huete, 1988)	$(1 + L) \times \frac{\rho_{B5} - \rho_{B4}}{\rho_{B5} + \rho_{B4} + L}$	30 m	$(1 + L) \times \frac{\rho_{B8} - \rho_{B4}}{\rho_{B8} + \rho_{B4} + L}$ $(1 + L) \times \frac{\rho_{BF} - \rho_{B4}}{\rho_{BF} + \rho_{B4} + L}$	10 m
ARVI (Kaufman e Tanré, 1992)	$\frac{\rho_{B5} - [\rho_{B4} - \gamma(\rho_{B2} - \rho_{B4})]}{\rho_{B5} + [\rho_{B4} - \gamma(\rho_{B2} - \rho_{B4})]}$	30 m	$\frac{\rho_{B8} - [\rho_{B4} - \gamma(\rho_{B2} - \rho_{B4})]}{\rho_{B8} + [\rho_{B4} - \gamma(\rho_{B2} - \rho_{B4})]}$ $\frac{\rho_{BF} - [\rho_{B4} - \gamma(\rho_{B2} - \rho_{B4})]}{\rho_{BF} + [\rho_{B4} - \gamma(\rho_{B2} - \rho_{B4})]}$	10 m
EVI (Huete, 1997)	$\frac{G \times (\rho_{B5} - \rho_{B4})}{L + \rho_{B5} + C1 \times \rho_{B4} - C2 \times \rho_{B2}}$	30 m	$\frac{G \times (\rho_{B8} - \rho_{B4})}{L + \rho_{B8} + C1 \times \rho_{B4} - C2 \times \rho_{B2}}$ $\frac{G \times (\rho_{BF} - \rho_{B4})}{L + \rho_{BF} + C1 \times \rho_{B4} - C2 \times \rho_{B2}}$	10 m
NDMI (Gao, 1996)	$(\rho_{B5} - \rho_{B6}) / (\rho_{B5} + \rho_{B6})$	30 m	$(\rho_{B8A} - \rho_{B11}) / (\rho_{B8A} + \rho_{B11})$	20m

ρ_{B2} : reflectância da banda azul; ρ_{B4} : reflectância da banda vermelho; ρ_{B5} : reflectância da banda infravermelho próximo do sensor OLI; ρ_{B6} : reflectância da banda infravermelho de ondas curtas do sensor OLI; ρ_{B8} : reflectância da banda infravermelho próximo do sensor MSI; ρ_{B8A} : reflectância da banda infravermelho próximo plateau do sensor MSI; ρ_{BF} : reflectância da banda fusionada do sensor MSI; ρ_{B11} : reflectância da banda infravermelho de ondas curtas do sensor MSI; L (SAVI) = valor constante de ajuste de solo (0,5); $\gamma = 0,5$ L (EVI) = valor constante (1,0) G = valor constante (2,5); C1 = valor constante (6,0); C2 = valor constante (7,5).

Fonte: O Autor (2018).


3.5 Classificação *Random Forest*

De acordo com Jensen (2011), a interpretação visual de imagens orbitais de sensoriamento remoto, utiliza os métodos de fotointerpretação, em especial, as informações de reconhecimento para identificação do alvo, como forma, tonalidade, cor, localização, textura e padrão, em que o conhecimento e a experiência do analista a respeito da cena são fundamentais para resultados de boa qualidade.

A partir desses preceitos, foram definidos Regiões de Interesse (ROI) para cada uma das seguintes classes: Corpos hídricos, Área construída, Solo sem vegetação, Agricultura Irrigada, Vegetação Caatinga. Os pontos amostrais das classes foram obtidos por meio da interpretação visual e com o auxílio do *Google Earth*, do MAPBIOMAS (projeto de Mapeamento Anual de Cobertura e Uso do Solo do Brasil) e dos próprios índices espectrais.

Depois da obtenção dos índices, e com o auxílio das regiões de interesse, os mesmos foram submetidos a classificação por meio do algoritmo *Random Forest*, que está disponível no ORFEO Toolbox (OTB), que como já foi mencionado podem ser utilizados através da estrutura de processamento no QGIS. Na Figura 8, é apresentado a interface do algoritmo dentro do ambiente QGIS.

Figura 8 – Interface do Random Forest no ambiente QGIS.




Fonte: QGIS 2.14.18.

3.6 Dados Meteorológicos

Neste estudo, para o reconhecimento dos índices pluviométricos na área de estudo, utilizaram-se dados de precipitação do posto Ibimirim, obtidos através do site da APAC. Foram coletados dados diários de precipitação dos meses de maio a dezembro de 2017, referentes as datas das imagens dos sensores OLI/Landsat-8 e

MSI/Sentinel-2, e estão representadas as médias pluviométricas mensais, conforme o gráfico da Figura 9.

Figura 9 – Regime pluviométrico do posto Ibimirim com valores mensais de maio a dezembro de 2017.



Fonte: APAC (2018).

Vale salientar que entre as datas de aquisição das imagens (Tabela 1) não houve contribuição pluviométrica significativa. Dos períodos analisados apenas em agosto, no dia 07/08/2017 choveu 0,4 mm, e a aquisição da imagem Sentinel-2 foi em 04/08 e do Landsat-8 foi em 15/08, nos demais intervalos de uma imagem para outra, não houve precipitação.

Na Tabela 5 encontram-se os dados climáticos referentes as datas de aquisição das imagens. Ao se analisar os dados climatológicos, constata-se que as datas relacionadas aos períodos chuvoso e seco apresentaram condições semelhantes.

Tabela 5 – Dados climáticos referentes as datas de aquisição das imagens.

Data (Sensor)	04/08/2017 (MSI)	15/08/2017 (OLI)	05/12/2017 (OLI)	07/12/2017 (MSI)
Temperatura Média (°C)	23,35	23,85	30,70	30,25
Umidade Relativa Mínima (%)	26	29	16	15
Umidade Relativa Máxima (%)	90	94	74	72
Evapotranspiração Real	0,24	0,4	0,01	0,01
Disponibilidade de Água no Solo	5,14	7,73	0,12	0,11
Radiação Solar	24,03	22,78	23,32	26,61

Fonte: APAC (2018).

3.7 Análise Estatística

Neste estudo, antes de se obter os índices espectrais, as bandas do visível, do infravermelho próximo, infravermelho de ondas curtas e a banda fusionada (BF), foram analisadas e comparadas entre os satélites estudados, nas reflectâncias TOA e BOA, por meio dos parâmetros estatísticos, mínimo, máximo, média, desvio padrão, que foram extraídos das imagens por meio do *software* SNAP 6.0, bem como pelo coeficiente de determinação (R^2). Entretanto, as imagens Landsat-8 e Sentinel-2 tiveram que ser ajustadas entre si, para possibilitar a comparação das bandas, uma vez que um pixel da imagem Landsat-8 recobre nove pixels da imagem Sentinel-2.

Dessa forma foi proposto dividir o pixel das imagens Landsat-8, de modo que um pixel de 30 m seja convertido em 9 pixels de 10 m cada, mas com mesmo valor espectral.

Para avaliar a Classificação por meio do *Random Forest* utilizaram-se a matriz de confusão, e calculou-se a exatidão global, exatidão do usuário e produtor, e o Kappa global. A exatidão global foi calculada, dividindo-se o total de área corretamente classificada de cada classe nos mapas classificados (soma dos elementos ao longo da diagonal principal) pela área correspondente a cada classe no mapa de referência.

A exatidão do usuário indica a probabilidade que um pixel classificado na imagem de fato representa aquela categoria no campo. Ou seja, é a porcentagem de pixels que foram classificados corretamente dentro da própria classe. Já a exatidão do produtor significa a proporção nessa classe de pontos atribuídos decorrentes de erros nas outras classes (LILLESAND, KIEFER, e CHIPMAN, 2015; PEREIRA E TAVARES JÚNIOR, 2017).

O índice Kappa (CONGALTON e GREEN, 2008) se diferencia da exatidão global por incorporar os elementos fora da diagonal principal. Esse índice foi calculado por:

$$K = \frac{n * \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} * x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} * x_{+i}} \quad (3)$$

onde: K é uma estimativa do coeficiente Kappa; x_{ii} é o valor na linha i e coluna i ; x_{i+} é a soma da linha i e x_{+i} é a soma da coluna i da matriz de confusão; n é o número total de amostras e c o número total de classes.

Esse índice varia de -1 a 1, e pode ser interpretado de acordo com a Tabela 6.

Tabela 6 - Categorização de uma classificação a partir do valor do índice Kappa.

Índice Kappa	Qualidade
< 0	Péssimo
0 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Moderado a bom
0,60 – 0,80	Muito bom
0,80 – 1,00	Excelente

Fonte: LANDIS e KOCH, (1977).

Depois de obtido o índice Kappa de cada classificação, será executado o teste z para testar a significância estatística da diferença entre as classificações resultantes de cada metodologia. Atribuiu-se um nível de significância de 5% ($\alpha = 0,05$), com valor crítico de 1,96, ou seja, assumiu-se que se o valor do teste z fosse maior que o valor crítico haveria diferença significativa entre os mapeamentos. A estatística para testar a diferença entre as duas matrizes de erro é obtida pela Equação 4:

$$Z = \frac{K2 - K1}{\sqrt{\sigma^2_{K1} - \sigma^2_{K2}}} \quad (4)$$

Onde: $K1$ é o índice Kappa da imagem 1; $K2$ é o índice Kappa da imagem 2; e σ^2 é a variância do índice Kappa.

Segundo HUDSON e RAMM (1987) a variância de Kappa pode ser estimada por:

$$\sigma^2 = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} \right] + \left[\frac{2(1-\theta_1)(2\theta_1\theta_2-\theta_3)}{(1-\theta_2)^3} \right] + \left[\frac{(1-\theta_1)^2(\theta_4-4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (5)$$

$$\text{Onde: } \theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii}; \quad \theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i+} x_{+i}; \quad \theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i+} x_{+i});$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j+} x_{+j})^2$$

3.8 Softwares Utilizados

Para o desenvolvimento da pesquisa optou-se preferencialmente pelo uso de *softwares Open Source* (código aberto) que, diferentemente de programas *Freeware* (gratuitos), além de serem gratuitos não há nenhum tipo de restrição aos usuários, e possuem o código fonte de programação incluso a eles. Isto é, os usuários podem modificar as funções do *software* sem a necessidade de nenhum tipo de remuneração aos desenvolvedores. A Tabela 7, ilustra os *Softwares* utilizados e suas aplicações.

Tabela 7 – Softwares utilizados e sua aplicação na pesquisa.

Software	Aplicação
QGIS 2.14.18	Determinação da reflectância TOA no Landsat-8, dos índices espectrais e das cartas georreferenciadas. Além de ser o software que permite a integralização com os softwares GRASS e OTB.
SNAP 6.0	Processamento da reflectância de superfície (BOA) no Sentinel-2; Determinação dos gráficos: scatter plots, bem como as estatísticas das imagens.
GRASS 7.2.1	Calcular a regressão linear entre os sensores OLI e MSI pela função “r.regression.line”.
OTB Monteverdi 6.4.0	Fusão das Imagens Sentinel-2 pelo algoritmo LMVM; Classificação dos índices pelo algoritmo <i>Random Forest</i> , e Criação da Matriz de Confusão.

Fonte: O Autor (2018).

4 RESULTADOS E DISCUSSÃO

A seguir serão apresentados os resultados encontrados na execução da pesquisa.

4.1 Análise das bandas espectrais entre os sensores OLI e MSI

As bandas do visível, infravermelho próximo e de ondas curtas dos sensores OLI e MSI, foram analisadas visualmente, por interpretação de imagens, e nas Tabelas 8 e 9, são apresentados os parâmetros estatísticos das imagens dos sensores OLI e MSI, em nível de reflectância TOA, referente aos dias 15/08/17, 05/12/17 (OLI), 04/08/17 e 07/12/17 (MSI).

Tabela 8 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância TOA de cada sensor, referente a agosto/2017.

Período	Sensor	Banda	Mínimo	Máximo	Média	Desvio Padrão
15/08/17	OLI	Azul	0,069	0,461	0,108	0,014
04/08/17	MSI		0,059	0,655	0,098	0,014
15/08/17	OLI	Verde	0,037	0,462	0,101	0,020
04/08/17	MSI		0,036	0,670	0,094	0,020
15/08/17	OLI	Vermelho	0,021	0,496	0,105	0,033
04/08/17	MSI		0,019	0,699	0,093	0,035
15/08/17	OLI	NIR	0,001	0,637	0,249	0,047
04/08/17	MSI		0,015	0,723	0,221	0,045
04/08/17	MSI	NIR plateau	0,010	0,665	0,252	0,048
15/08/17	OLI	SWIR 1	0,008	0,643	0,277	0,062
04/08/17	MSI		0,006	0,773	0,263	0,060

Fonte: O Autor (2018).

Tabela 9 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância TOA de cada sensor, referente a dezembro/2017.

Período	Sensor	Banda	Mínimo	Máximo	Média	Desvio Padrão
05/12/17	OLI	Azul	0,072	0,450	0,124	0,014
07/12/17	MSI		0,068	0,558	0,124	0,016
05/12/17	OLI	Verde	0,043	0,457	0,121	0,021
07/12/17	MSI		0,046	0,575	0,124	0,022
05/12/17	OLI	Vermelho	0,030	0,482	0,145	0,033
07/12/17	MSI		0,031	0,643	0,153	0,036
05/12/17	OLI	NIR	0,010	0,616	0,246	0,044
07/12/17	MSI		0,025	0,738	0,216	0,040
07/12/17	MSI	NIR plateau	0,025	0,630	0,250	0,043
05/12/17	OLI	SWIR 1	0,004	0,757	0,353	0,061
07/12/17	MSI		0,022	0,863	0,360	0,059

Fonte: O Autor (2018).

Na Tabela 10, foi possível observar as diferenças das médias de cada banda, entre os sensores OLI e MSI nos períodos analisados.

Tabela 10 – Diferença entre as médias das bandas utilizadas, entre os sensores, em reflectância TOA nos períodos analisados.

Período	Banda	Diferença Média	Diferença Média Percentual (%)
Agosto/2017	Azul	0,010	1,0
	Verde	0,007	0,7
	Vermelho	0,012	1,2
	NIR	0,028	2,8
	NIR plateau	0,003	0,3
	SWIR 1	0,014	1,4
Dezembro/2017	Azul	0,000	0,0
	Verde	0,003	0,3
	Vermelho	0,008	0,8
	NIR	0,030	3,0
	NIR plateau	0,004	0,4
	SWIR 1	0,007	0,7

Fonte: O Autor (2018).

Ao se analisar as Tabelas 8 a 10, fica explícito que em termos médios e em nível de reflectância TOA a banda do sensor MSI, que tem uma maior discrepância em relação ao sensor OLI, é a banda do infravermelho próximo (Banda 8), essa diferença é reduzida quando comparado a banda infravermelho próximo plateau (8A), com a banda infravermelho do sensor OLI.

De acordo com Li et al. (2017), a banda NIR do sensor OLI evita a propagação por vapor d'água, usando um espectro estreito (850 - 880 nm). A resposta espectral relativa da banda NIR do MSI (banda 8), no entanto, é mais ampla que o OLI. O sensor MSI fornece a banda B8A, na qual é semelhante ao NIR do OLI (Figura 6), onde ambas estão centradas em 865 nm.


Os resultados encontrados por Li et al. (2017) e por Zhang et al. (2018), mostraram que as maiores diferenças entre os sensores OLI e MSI, em nível de reflectância TOA, foram quando compararam as bandas do infravermelho próximo, bandas (5 e 8), respectivamente, fato que corrobora com resultados dessa pesquisa.

Observando a semelhança entre as bandas do infravermelho próximo do sensor OLI com a banda infravermelho plateau (8A) do MSI, foi feita a fusão entre as bandas do infravermelho próximo (8 e 8A) do satélite Sentinel-2, por meio do algoritmo LMVM que permite a fusão coletando as informações espectrais da banda 8A, com


base na resolução espacial da banda 8. Seus resultados de correlação são mostrados na Figura 10.

Figura 10 – Gráfico de correlação entre: MSI Banda 8A × MSI Banda Fusionada, OLI Banda 5 × MSI Banda 8 e OLI Banda 5 × MSI Banda Fusionada. Reflectância TOA. A) agosto, 2017; B) dezembro, 2017.

A) Agosto de 2017



B) Dezembro de 2017



Fonte: O Autor (2018).

Ao se analisar a Figura 10, constatou-se que os menores valores do coeficiente de determinação (R^2) foi ao se comparar o sensor OLI Banda 5 com o sensor MSI Banda 8, no período de agosto de 2017, e ainda assim obteve-se um R^2 superior 0,80. De acordo com Callegari-Jacques (2003), valores de R^2 superiores a 0,8 é possível afirmar que os dados comparados possuem uma correlação forte. Nos períodos analisados, constatou-se que a banda fusionada obteve uma aderência maior que a banda 8 (MSI), quando ambas foram comparadas com a banda 5 do sensor OLI.

Nas Tabelas 11 e 12, são apresentados os parâmetros estatísticos dos sensores OLI e MSI, em nível de reflectância BOA, referente aos dias 15/08/17, 05/12/17 (OLI), 04/08/17 e 07/12/17 (MSI).

Tabela 11 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância BOA de cada sensor, referente a agosto/2017.

Período	Sensor	Banda	Mínimo	Máximo	Média	Desvio Padrão
15/08/17	OLI	Azul	0,131	0,457	0,047	0,016
04/08/17	MSI		0,001	0,839	0,044	0,020
15/08/17	OLI	Verde	0,001	0,490	0,077	0,024
04/08/17	MSI		0,001	0,856	0,074	0,027
15/08/17	OLI	Vermelho	0,000	0,520	0,094	0,038
04/08/17	MSI		0,001	0,818	0,085	0,042
15/08/17	OLI	NIR	0,009	0,643	0,248	0,049
04/08/17	MSI		0,001	0,829	0,239	0,052
04/08/17	MSI	NIR plateau	0,001	0,687	0,252	0,051
15/08/17	OLI	SWIR 1	0,010	0,666	0,289	0,065
04/08/17	MSI		0,036	0,853	0,287	0,066

Fonte: O Autor (2018).

Tabela 12 - Valores estatísticos das bandas do visível, infravermelho próximo e de ondas curtas em reflectância BOA de cada sensor, referente a dezembro/2017.

Período	Sensor	Banda	Mínimo	Máximo	Média	Desvio Padrão
05/12/17	OLI	Azul	0,059	0,443	0,062	0,017
07/12/17	MSI		0,001	0,751	0,065	0,023
05/12/17	OLI	Verde	0,058	0,481	0,098	0,026
07/12/17	MSI		0,007	0,766	0,099	0,031
05/12/17	OLI	Vermelho	0,007	0,500	0,145	0,037
07/12/17	MSI		0,001	0,780	0,152	0,044
05/12/17	OLI	NIR	0,002	0,621	0,244	0,045
07/12/17	MSI		0,005	0,878	0,253	0,048
07/12/17	MSI	NIR plateau	0,003	0,676	0,241	0,047
05/12/17	OLI	SWIR 1	0,006	0,785	0,397	0,064
07/12/17	MSI		0,018	0,898	0,398	0,067

Fonte: O Autor (2018).

Na Tabela 13, é possível observar as diferenças das médias de cada banda nos períodos analisados, em reflectância BOA.

Tabela 13 – Diferença entre as médias das bandas utilizadas, entre os sensores, em reflectância BOA nos períodos analisados.

Período	Banda	Diferença Média	Diferença Média Percentual (%)
Agosto/2017	Azul	0,003	0,3
	Verde	0,003	0,3
	Vermelho	0,009	0,9
	NIR	0,009	0,9
	NIR plateau	0,004	0,4
	SWIR 1	0,002	0,2
Dezembro/2017	Azul	0,003	0,3
	Verde	0,001	0,1
	Vermelho	0,007	0,7
	NIR	0,009	0,9
	NIR plateau	0,003	0,3
	SWIR 1	0,001	0,1

Fonte: O Autor (2018).

Ao se analisar as Tabelas 11 a 13, evidencia-se que houve uma redução ao se comparar as diferenças médias das imagens do infravermelho próximo dos sensores OLI e MSI, em nível de reflectância BOA com a reflectância no topo da atmosfera de 2,8% para 0,9% em agosto, e 3,0% para 0,9% em dezembro, entretanto a banda NIR plateau ainda obteve uma diferença média menor, em comparação a banda NIR do OLI.

Baptista (2001) encontrou, uma diferença entre imagens corrigidas e não corrigidas para os efeitos atmosféricos, da ordem de 2%, o que corrobora com os resultados obtidos por Carvalho e Baptista (2015), que avaliaram a influência da correção atmosférica na conversão dos dados de radiância para reflectância para o cálculo do EVI em imagem *RapidEye*. Fazendo jus com esses resultados encontrados nessa pesquisa.


Os resultados dessa pesquisa condizem também com Zhang et al. (2018), que obtiveram reduções em termos médios quando compararam dados dos sensores OLI e MSI, em reflectância TOA e BOA, e constaram os decréscimos das bandas 8 do MSI com a 5 do OLI, de 2,5% para 1,7%, e ao comparar com a banda 8A MSI e 5 do OLI foi de 0,12% para 0,003%, respectivamente.

Em seguida na Figura 11, são apresentados os resultados de correlação do sensor MSI Banda Fusionada com a banda 8A; OLI Banda 5 e MSI Banda 8 e OLI


Banda 5 e MSI Banda Fusionada, em termos de reflectância BOA, para os períodos estudados.

Figura 11 – Gráfico de correlação entre: MSI Banda 8A × MSI Banda Fusionada, OLI Banda 5 × MSI Banda 8 e OLI Banda 5 × MSI Banda Fusionada. Reflectância BOA. A) agosto, 2017; B) dezembro, 2017.

A) Agosto de 2017



B) Dezembro de 2017



Fonte: O Autor (2018).

Ao se analisar a Figura 11, observa-se que os menores valores do coeficiente de determinação (R^2) foi ao se comparar o sensor OLI Banda 5 com o sensor MSI Banda 8, no período de agosto de 2017, e ainda assim obteve-se um R^2 superior 0,81. Entretanto teve um leve acréscimo se comparado com a reflectância TOA, de 0,806 para 0,819, o que condiz com Zhang et al. (2018), que também observaram esse acréscimo. Destaca-se também os aumentos do R^2 quando comparados a Banda 5 do sensor OLI, com a banda fusionada, em relação a reflectância TOA.

4.2 Avaliação dos Índices Espectrais

Uma vez analisadas e verificadas as semelhanças entre as bandas dos sensores, e com a obtenção da banda fusionada, o próximo passo foi o cômputo dos

índices espectrais em nível de reflectância TOA e BOA. Nas cartas georreferenciadas dos índices espectrais foram apresentados quatro alvos distintos, com intuito da comparação visual entre os sensores. No retângulo 1 refere-se à vegetação de Caatinga preservada, localizada no Parque Nacional Vale do Catimbau, o retângulo 2 está associado ao perímetro Irrigado Moxotó, o retângulo 3 refere-se a área urbana do município de Buíque, e o retângulo 4 associa-se ao reservatório Poço da Cruz.

A seguir foi apresentado os resultados para o índice espectral NDVI, em nível de reflectância TOA, para os períodos analisados. Foi calculado o NDVI referente ao sensor OLI, utilizando as bandas 4 e 5 nomeado de $NDVI_{OLI}$. Para o sensor MSI foi realizado o cálculo utilizando as bandas (4 e 8), e (4 e a BF), nomeados de $NDVI_{MSI}$ e $NDVI_{BF}$, respectivamente. Na Tabela 14, são apresentados os parâmetros estatísticos para os NDVI mencionados, em nível de reflectância TOA.

Tabela 14 - Valores estatísticos dos NDVI em reflectância TOA de cada sensor.						
Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	$NDVI_{OLI}$	-0,946	0,869	0,461	0,121	$OLI \times MSI$
	$NDVI_{MSI}$	-0,519	0,880	0,411	0,142	0,050
	$NDVI_{BF}$	-0,965	0,884	0,465	0,133	$OLI \times BF$
Dezembro/2017	$NDVI_{OLI}$	-0,632	0,839	0,261	0,067	-0,004
	$NDVI_{MSI}$	-0,350	0,814	0,175	0,073	$OLI \times MSI$
	$NDVI_{BF}$	-0,696	0,822	0,245	0,072	0,086
						$OLI \times BF$
						0,016


Fonte: O Autor (2018).

Ao se analisar o NDVI obtido com a banda fusionada ($NDVI_{BF}$), verificou-se que em termos médios, o índice se manteve mais próximo do $NDVI_{OLI}$ com diferenças médias abaixo de $|0,016|$, enquanto que a diferença média entre o $NDVI_{MSI}$ e o $NDVI_{OLI}$ foi acima de $|0,050|$.

Li et al. (2017), mostraram que o desempenho médio do NDVI, em termos de reflectância TOA, calculado no sensor MSI, com a banda NIR plateau (8A), foi superior ao calculado com banda 8, e encontra-se mais próximo ao valor médio do NDVI obtido com o sensor OLI.


Nas Figuras 12 e 13, são apresentadas as cartas georreferenciadas do índice espectral NDVI para os períodos de agosto e dezembro de 2017.

Figura 12 – Carta georreferenciada do índice NDVI para agosto de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Figura 13 – Carta georreferenciada do índice NDVI para dezembro de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Ao se analisar as cartas referentes ao índice espectral NDVI, Figuras 12 e 13, foi possível constatar visualmente que o $NDVI_{BF}$ se manteve mais próximo ao $NDVI_{OLI}$,

fato que se deve pelo $NDVI_{BF}$ ser computado com a banda fusionada, na qual tem as características da banda 8A do sensor MSI/Sentinel-2, e sua Resposta Espectral Relativa (Figura 6), é próxima a banda 5 do sensor OLI/Landsat-8.

Em relação ao $NDVI_{MSI}$, este foi o que manteve maior diferença visual entre os demais. No período de agosto, sua diferença em relação ao $NDVI_{OLI}$ foi mais sutil, fato que pode ser explicado pela contribuição pluviométrica significativa antecedente ao mês de agosto (Figura 9), que fez com que a vegetação tivesse um teor fotossintético maior, com isso a vegetação na Caatinga tende a ficar mais verde, e assim não apresentando tanta diferença visual em relação ao $NDVI_{OLI}$.

Em dezembro, devido a contribuição da precipitação antecedente ter sido reduzida por se tratar do período sem chuvas da região, e levando em consideração que os índices estão em nível de reflectância TOA, efeitos atmosféricos podem ter influenciado na banda 8, e ter contribuído para as diferenças visuais entre o $NDVI_{MSI}$ e $NDVI_{OLI}$, uma vez que a Resposta Espectral Relativa (Figura 6), da banda 8 é muito mais ampla que a banda 5 do sensor OLI/Landsat-8, e dessa maneira estando mais propícia aos efeitos atmosféricos.

A seguir apresentaram-se os resultados para o índice espectral SAVI, em nível de reflectância TOA, para os períodos analisados. Foi calculado o SAVI referente ao sensor OLI, utilizando as bandas 4 e 5 nomeado de $SAVI_{OLI}$. Para o sensor MSI foi realizado o cálculo utilizando as bandas (4 e 8), e (4 e a BF), nomeados de $SAVI_{MSI}$ e $SAVI_{BF}$, respectivamente e o fator de ajuste ao solo (L) de 0,5. Na Tabela 15, são apresentados os parâmetros estatísticos para os SAVI mencionados, em nível de reflectância TOA.

Tabela 15 – Valores estatísticos dos SAVI em reflectância TOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	$SAVI_{OLI}$	-0,267	0,751	0,263	0,077	$OLI \times MSI$ 0,029
	$SAVI_{MSI}$	-0,259	0,748	0,234	0,084	
	$SAVI_{BF}$	-0,215	0,758	0,281	0,083	$OLI \times BF$ -0,018
Dezembro/2017	$SAVI_{OLI}$	-0,236	0,706	0,169	0,042	$OLI \times MSI$ 0,060
	$SAVI_{MSI}$	-0,188	0,661	0,109	0,043	
	$SAVI_{BF}$	-0,159	0,704	0,161	0,045	$OLI \times BF$ 0,008

Fonte: O Autor (2018).

Nas Figuras 14 e 15, são apresentadas as cartas georreferenciadas do índice espectral SAVI para os períodos de agosto e dezembro de 2017.

Figura 14 – Carta georreferenciada do índice SAVI para agosto de 2017, em reflectância TOA.





Figura 15 – Carta georreferenciada do índice SAVI para dezembro de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Ao se analisar os valores estatísticos do SAVI (Tabela 15), constatou-se que o índice obtido com a banda fusionada se manteve mais próximo em termos médios daquele obtido com o sensor OLI.

Nas cartas referentes ao índice espectral SAVI, Figuras 14 e 15, foi possível constatar visualmente que o fator de ajuste ao solo, pôde minimizar a reflectância do solo. Foi possível observar também que os intervalos de classes dos índices SAVI_{OLI} e SAVI_{BF} em ambos os períodos analisados ficaram próximos.

Os valores médios no índice SAVI, para o período chuvoso da região (agosto) corroboram com Ballén, Souza e Lima, (2016), que obtiveram valores médios para esse índice igual a 0,29 na Área de Proteção Ambiental (APA) do Cariri, para o ano de 2005.

Os valores médios no índice SAVI_{OLI} e SAVI_{BF}, para o período seco (dezembro) condizem com Bezerra et al. (2017), que encontraram valores médios de 0,147 e 0,155 para o alto da bacia do rio Moxotó, onde analisaram os anos de 2009 e 2017 também referente ao período seco.

A seguir apresentam-se os resultados para o índice espectral ARVI, em nível de reflectância TOA, para os períodos analisados. Foi calculado o ARVI referente ao sensor OLI, utilizando as bandas 2, 4 e 5 nomeado de ARVI_{OLI}. Para o sensor MSI foi realizado o cálculo utilizando as bandas (2, 4 e 8), e (2, 4 e a BF), nomeados de ARVI_{MSI} e ARVI_{BF}, respectivamente, e o fator de ajuste (γ) de 0,5. Na Tabela 16, são apresentados os parâmetros estatísticos para os ARVI mencionados, em nível de reflectância TOA.


Tabela 16 – Valores estatísticos dos ARVI em reflectância TOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	ARVI _{OLI}	-0,825	0,995	0,426	0,153	OLI × MSI -0,057
	ARVI _{MSI}	-0,517	0,994	0,483	0,181	
	ARVI _{BF}	-0,935	0,997	0,435	0,170	OLI × BF -0,009
Dezembro/2017	ARVI _{OLI}	-0,482	0,896	0,235	0,084	OLI × MSI 0,099
	ARVI _{MSI}	-0,366	0,875	0,136	0,091	
	ARVI _{BF}	-0,559	0,881	0,207	0,091	OLI × BF 0,028

Fonte: O Autor (2018).


Nas Figuras 16 e 17, são apresentadas as cartas georreferenciadas do índice espectral ARVI para os períodos de agosto e dezembro de 2017.

Figura 16 – Carta georreferenciada do índice ARVI para agosto de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Figura 17 – Carta georreferenciada do índice ARVI para dezembro de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Por meio da análise da Tabela 16 e Figuras 16 e 17, observou-se que assim como o NDVI e SAVI, o ARVI obtido por meio da banda fusionada se manteve mais próximo do obtido com OLI, onde foram encontradas diferenças médias abaixo de $|0,028|$, enquanto que a diferença média entre o $ARVI_{MSI}$ e o $ARVI_{OLI}$ foi acima de $|0,057|$.

A seguir apresentam-se os resultados para o índice espectral EVI, em nível de reflectância TOA, para os períodos analisados. Foi calculado o EVI referente ao sensor OLI, utilizando as bandas 2, 4 e 5 nomeado de EVI_{OLI} . Para o sensor MSI foi realizado o cálculo utilizando as bandas (2, 4 e 8), e (2, 4 e a BF), nomeados de EVI_{MSI} e EVI_{BF} , respectivamente, e os fatores de ajuste (L) de 1,0, (G) de 2,5, (C1) de 6,0 e (C2) de 7,5. Na Tabela 17, são apresentados os parâmetros estatísticos para os EVI mencionados, em nível de reflectância TOA.

Tabela 17 – Valores estatísticos dos EVI em reflectância TOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	EVI_{OLI}	-0,282	1,214	0,342	0,120	$OLI \times MSI$ 0,032
	EVI_{MSI}	-0,431	1,139	0,310	0,126	
	EVI_{BF}	-0,599	1,158	0,365	0,128	$OLI \times BF$ -0,023
Dezembro/2017	EVI_{OLI}	-0,250	1,096	0,215	0,059	$OLI \times MSI$ 0,082
	EVI_{MSI}	-0,208	1,978	0,133	0,059	
	EVI_{BF}	-0,229	1,519	0,198	0,063	$OLI \times BF$ 0,017

Fonte: O Autor (2018).

Nas Figuras 18 e 19, são apresentadas as cartas georreferenciadas do índice espectral EVI para os períodos de agosto e dezembro de 2017.

Figura 18 – Carta georreferenciada do índice EVI para agosto de 2017, em reflectância TOA.





Figura 19 – Carta georreferenciada do índice EVI para dezembro de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Assim como os índices calculados anteriormente, o EVI calculado com a banda fusionada novamente se manteve mais próximo em termos médios do índice obtido com o sensor OLI.

Ribeiro et al. (2016), em estudo multitemporal encontraram valores médios do índice EVI, variando de 0,21 a 0,33, utilizando o sensor MODIS, na bacia hidrográfica do rio Pajeú no estado de Pernambuco, condizendo com os resultados dessa pesquisa.

A seguir apresentam-se os resultados para o índice espectral NDMI, em nível de reflectância TOA, para os períodos analisados. Foi calculado o NDMI referente ao sensor OLI, utilizando as bandas 5 e 6 nomeado de $NDMI_{OLI}$. Para o sensor MSI foi realizado o cálculo utilizando as bandas (8A, e 11), nomeado de $NDMI_{MSI}$.

Neste índice especificamente não foi utilizado a banda fusionada, pois a banda 11 (infravermelho de ondas curtas) encontra-se na resolução espacial de 20m, podendo assim ser utilizado diretamente a banda 8A. Na Tabela 18, são apresentados os parâmetros estatísticos para os NDMI mencionados, em nível de reflectância TOA.


Tabela 18 – Valores estatísticos dos NDMI em reflectância TOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	$NDMI_{OLI}$	-0,705	0,890	-0,048	0,117	$OLI \times MSI$
	$NDMI_{MSI}$	-0,485	0,815	0,017	0,122	-0,065
Dezembro/2017	$NDMI_{OLI}$	-0,573	0,745	-0,178	0,063	$OLI \times MSI$
	$NDMI_{MSI}$	-0,529	0,607	-0,179	0,060	0,001

Fonte: O Autor (2018).


Nas Figuras 20 e 21, são apresentadas as cartas georreferenciadas do índice espectral NDMI para os períodos de agosto e dezembro de 2017.

Figura 20 – Carta georreferenciada do índice NDMI para agosto de 2017, em reflectância TOA.



Fonte: O Autor (2018).

Figura 21 – Carta georreferenciada do índice NDMI para dezembro de 2017, em reflectância TOA.




Fonte: O Autor (2018).

Bezerra et al. (2018), em estudo observaram valores médios do índice NDMI de -0,047, na região do entorno do reservatório de Itaparica, localizado na região do Submédio do São Francisco. Albuquerque et al. (2014), encontraram valores médios para o NDMI no Município de Sousa-PB entre -0,16 e 0,23 evidenciando valores próximos aos encontrados nesse estudo.

Na Figura 22 foi possível através da espacialização gráfica as médias referentes aos índices espectrais obtidos com os sensores OLI, MSI e com a banda fusionada de ambos os períodos estudados. E ao analisar o gráfico notou-se que em termos médios os índices obtidos com a banda fusionada, se mantiveram mais próximos aos índices do sensor OLI.

Figura 22 – Representação gráfica das médias dos índices espectrais em nível de reflectância TOA.



Fonte: O Autor (2019).

A seguir é apresentado os resultados para os índices espectrais, para os períodos analisados, em reflectância BOA. Na Tabela 19, são apresentados os parâmetros estatísticos para os NDVI em reflectância BOA.


Tabela 19 - Valores estatísticos dos NDVI em reflectância BOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	NDVI _{OLI}	-0,917	0,962	0,461	0,138	OLI × MSI 0,035
	NDVI _{MSI}	-0,984	0,996	0,496	0,164	
	NDVI _{BF}	-0,881	0,997	0,489	0,159	OLI × BF 0,028
Dezembro/2017	NDVI _{OLI}	-0,533	0,903	0,292	0,079	OLI × MSI 0,065
	NDVI _{MSI}	-0,482	0,926	0,227	0,088	
	NDVI _{BF}	-0,441	0,822	0,256	0,089	OLI × BF 0,036

Fonte: O Autor 2018.


Nas Figuras 23 e 24, são apresentadas as cartas georreferenciadas do índice espectral NDVI para os períodos de agosto e dezembro de 2017, em reflectância BOA, vale salientar que foram utilizados os mesmos intervalos de classe dos índices espectrais calculados em reflectância TOA.

Figura 23 – Carta georreferenciada do índice NDVI para o período de agosto de 2017, em reflectância BOA.



Fonte: O Autor 2018.

Figura 24 – Carta georreferenciada do índice NDVI para o período de dezembro de 2017, em reflectância BOA.



Fonte: O Autor 2018.

Ao se analisar o NDVI obtido com a banda fusionada ($NDVI_{BF}$), verificou-se que em termos médios (Tabela 19), o índice se manteve mais próximo do $NDVI_{OLI}$, assim como aconteceu com os dados em reflectância TOA. Em relação as cartas do NDVI em nível de reflectância BOA, o $NDVI_{MSI}$ teve uma redução significativa se comparado com mesmo índice em nível TOA, apresentando-se mais semelhante ao $NDVI_{OLI}$ e $NDVI_{BF}$, o que sugere que de fato no período seco da região a banda 8 do sensor MSI, sofre mais como os efeitos atmosféricos.

Nas Tabelas 20 a 23, são apresentados os parâmetros estatísticos para os índices SAVI, ARVI, EVI e NDMI em reflectância BOA, para os períodos estudados.

Tabela 20 - Valores estatísticos dos SAVI em reflectância BOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	$SAVI_{OLI}$	-0,285	0,792	0,275	0,082	$OLI \times MSI$ -0,026
	$SAVI_{MSI}$	-0,298	0,829	0,301	0,094	$OLI \times BF$ -0,007
	$SAVI_{BF}$	-0,262	0,805	0,282	0,926	
Dezembro/2017	$SAVI_{OLI}$	-0,255	0,748	0,185	0,045	$OLI \times MSI$ 0,040
	$SAVI_{MSI}$	-0,230	0,781	0,145	0,051	$OLI \times BF$ 0,018
	$SAVI_{BF}$	-0,227	0,784	0,167	0,052	

Fonte: O Autor (2018).

Tabela 21 - Valores estatísticos dos ARVI em reflectância BOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	$ARVI_{OLI}$	-0,919	0,940	0,374	0,159	$OLI \times MSI$ -0,033
	$ARVI_{MSI}$	-0,969	0,996	0,407	0,185	$OLI \times BF$ -0,027
	$ARVI_{BF}$	-0,99	0,997	0,401	0,181	
Dezembro/2017	$ARVI_{OLI}$	-0,865	0,884	0,180	0,086	$OLI \times MSI$ 0,054
	$ARVI_{MSI}$	-0,550	0,910	0,126	0,095	$OLI \times BF$ 0,024
	$ARVI_{BF}$	-0,760	0,945	0,156	0,098	

Fonte: O Autor (2018).

Tabela 22 - Valores estatísticos dos EVI em reflectância BOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	EVI _{OLI}	-0,238	0,971	0,268	0,092	OLI × MSI 0,027
	EVI _{MSI}	-0,650	0,995	0,295	0,104	OLI × BF -0,009
	EVI _{BF}	-0,955	0,965	0,277	0,102	
Dezembro/2017	EVI _{OLI}	-0,215	0,856	0,171	0,046	OLI × MSI 0,039
	EVI _{MSI}	-0,612	0,975	0,132	0,053	OLI × BF 0,009
	EVI _{BF}	-0,975	0,975	0,162	0,054	

Fonte: O Autor (2018).

Tabela 23 - Valores estatísticos dos NDMI em reflectância BOA de cada sensor.

Período	Índice	Mínimo	Máximo	Média	Desvio Padrão	Diferença Média
Agosto/2017	NDMI _{OLI}	-0,810	0,982	-0,071	0,118	OLI × MSI 0,012
	NDMI _{MSI}	-0,994	0,816	-0,059	0,125	
Dezembro/2017	NDMI _{OLI}	-0,720	0,763	-0,202	0,063	OLI × MSI 0,180
	NDMI _{MSI}	-0,871	0,604	-0,222	0,061	


Fonte: O Autor (2018).

Ao se comparar as médias dos índices em reflectância BOA, em relação a reflectância TOA, constatou-se que os índices NDVI e SAVI obtidos com a reflectância de superfície apresentaram médias superiores em relação a reflectância no topo da atmosfera. Os índices ARVI, EVI e NDMI, em reflectância de superfície apresentaram médias inferiores em relação aos obtidos em reflectância TOA.

Nas Figuras 25 a 32, são apresentadas as cartas georreferenciadas dos índices espectrais SAVI, ARVI, EVI e NDMI para os períodos de agosto e dezembro de 2017, em reflectância BOA.

Nelas pode-se perceber que entre alguns índices a mudança visualmente não foi muito perceptível, ao se comparar com os índices em reflectância TOA, a exemplo dos índices SAVI, ARVI_{MSI} EVI_{MSI}, para o período de agosto e o NDMI_{OLI} para o período de dezembro. Os demais índices espectrais demonstraram ter uma maior variação qualitativamente.

Figura 25 – Carta georreferenciada do índice SAVI para o período de agosto de 2017, em reflectância BOA.



Fonte: O Autor 2018.

Figura 26 – Carta georreferenciada do índice SAVI para o período de dezembro de 2017, em reflectância BOA.





Figura 27 – Carta georreferenciada do índice ARVI para o período de agosto de 2017, em reflectância BOA.



Fonte: O Autor 2018.

Figura 28 – Carta georreferenciada do índice ARVI para o período de dezembro de 2017, em reflectância BOA.




Figura 29 – Carta georreferenciada do índice EVI para o período de agosto de 2017, em reflectância BOA.




Figura 30 – Carta georreferenciada do índice EVI para o período de dezembro de 2017, em reflectância BOA.






Figura 31 – Carta georreferenciada do índice NDMI para o período de agosto de 2017, em reflectância BOA.



Fonte: O Autor 2018.


Figura 32 – Carta georreferenciada do índice NDMI para o período de dezembro de 2017, em reflectância BOA.



Fonte: O Autor 2018.

Na Figura 33 é possível observar, através da espacialização gráfica, as médias referentes aos índices espectrais obtidos com os sensores OLI, MSI e com a banda fusionada em nível de reflectância BOA.

Figura 33 – Representação gráfica das médias dos índices espectrais em nível de reflectância BOA.



Fonte: O Autor (2019).

Analisando o gráfico nota-se que em termos médios os índices obtidos com a banda fusionada, se mantiveram mais próximos aos índices do OLI, entretanto ao se observar os índices calculados com o sensor MSI, em reflectância BOA estes obtiveram seu desempenho mais próximo ao OLI, quando comparado em reflectância TOA (Figura 22).

Foi perceptível que após a utilização da correção atmosférica, obtendo-se a reflectância BOA, as cartas dos índices espectrais apresentaram uma sensível melhora visual dos alvos, o que facilita na interpretação visual das imagens, para a classificação supervisionada, pois os valores dos pixels são calibrados retirando ruídos e distorções. Estes resultados condizem com Anjos (2017), que em estudo obteve resultados visualmente distintos dos índices NDVI, SAVI e ARVI com e sem correção atmosférica.


4.3 Classificação Supervisionada pelo método *Random Forest*

Os tópicos a seguir trazem a apresentação e discussão dos dados obtidos pela classificação através do método *Random Forest* para os índices espectrais obtidos com os sensores estudados, seguido da análise do índice Kappa e do teste z para avaliar a significância estatística entre as classificações resultantes de cada índice espectral.

4.3.1 Classificação dos Índices Espectrais em reflectância TOA


A classificação pelo método do *Random Forest* para os índices estudados para o período de agosto de 2017 e dezembro de 2017 pode ser visto na Figura 34 e 35.

Figura 34 – Classificação pelo *Random Forest* dos índices espectrais em reflectância TOA, agosto de 2017.



Fonte: O Autor 2019.

Figura 35 – Classificação pelo *Random Forest* dos índices espectrais em reflectância TOA, dezembro de 2017.



Fonte: O Autor 2019.

Na Tabela 24, encontram-se desempenho geral, e o índice Kappa da classificação de cada índice espectral, em nível de reflectância TOA, para o período de agosto de 2017 e dezembro de 2017.

Tabela 24 - Estatísticas gerais da classificação *Random Forest* em nível de reflectância TOA, para o período de agosto de 2017 e dezembro de 2017.

Período	Índice	Desempenho Geral	Índice Kappa	Qualidade
Agosto/2017	NDVI _{OLI}	0,88	0,85	Excelente
	NDVI _{MSI}	0,87	0,83	Excelente
	NDVI _{BF}	0,90	0,87	Excelente
	SAVI _{OLI}	0,93	0,91	Excelente
	SAVI _{MSI}	0,89	0,86	Excelente
	SAVI _{BF}	0,91	0,89	Excelente
	ARVI _{OLI}	0,86	0,82	Excelente
	ARVI _{MSI}	0,72	0,64	Muito bom
	ARVI _{BF}	0,67	0,58	Bom
	EVI _{OLI}	0,89	0,86	Excelente
	EVI _{MSI}	0,87	0,83	Excelente
	EVI _{BF}	0,90	0,87	Excelente
	NDMI _{OLI}	0,67	0,59	Bom
	NDMI _{MSI}	0,72	0,64	Muito bom
Dezembro/2017	NDVI _{OLI}	0,95	0,94	Excelente
	NDVI _{MSI}	0,92	0,90	Excelente
	NDVI _{BF}	0,91	0,88	Excelente
	SAVI _{OLI}	0,92	0,90	Excelente
	SAVI _{MSI}	0,87	0,83	Excelente
	SAVI _{BF}	0,87	0,83	Excelente
	ARVI _{OLI}	0,89	0,86	Excelente
	ARVI _{MSI}	0,81	0,75	Muito bom
	ARVI _{BF}	0,81	0,76	Muito bom
	EVI _{OLI}	0,94	0,92	Excelente
	EVI _{MSI}	0,88	0,85	Excelente
	EVI _{BF}	0,85	0,81	Excelente
	NDMI _{OLI}	0,74	0,67	Muito bom
	NDMI _{MSI}	0,77	0,71	Muito bom

Fonte: O Autor (2019).

Ao se analisar a Tabela 24, observa-se que as classificações pelo *Random Forest* dos índices espectrais em nível de reflectância TOA, obtiveram sua qualidade em sua maioria de acordo com o índice Kappa, como excelente. Os menores valores do índice Kappa foram dos índices ARVI_{BF} e NDMI_{OLI} (0,58 e 0,59) ambos do período de agosto de 2017, e obtiveram qualidade classificada como bom.

Na Tabela 25, é expresso o teste z para avaliar a significância estatística entre as classificações dos sensores, ao nível de significância de 5%, com valor crítico tabelado de 1,96.

Tabela 25 - Teste z para significância da classificação *Random Forest* de diferentes índices espectrais em nível de reflectância TOA.

Período	Índice	Z calculado
Agosto/2017	NDVI _{OLI} × NDVI _{MSI}	0,70 ^{ns}
	NDVI _{OLI} × NDVI _{BF}	0,50 ^{ns}
	SAVI _{OLI} × SAVI _{MSI}	1,63 ^{ns}
	SAVI _{OLI} × SAVI _{BF}	0,57 ^{ns}
	ARVI _{OLI} × ARVI _{MSI}	4,60 [*]
	ARVI _{OLI} × ARVI _{BF}	6,03 [*]
	EVI _{OLI} × EVI _{MSI}	0,84 ^{ns}
	EVI _{OLI} × EVI _{BF}	0,23 ^{ns}
	NDMI _{OLI} × NDMI _{MSI}	1,18 ^{ns}
Dezembro/2017	NDVI _{OLI} × NDVI _{MSI}	1,62 ^{ns}
	NDVI _{OLI} × NDVI _{BF}	1,62 ^{ns}
	SAVI _{OLI} × SAVI _{MSI}	2,30 [*]
	SAVI _{OLI} × SAVI _{BF}	2,31 [*]
	ARVI _{OLI} × ARVI _{MSI}	3,25 [*]
	ARVI _{OLI} × ARVI _{BF}	3,10 [*]
	EVI _{OLI} × EVI _{MSI}	2,46 [*]
	EVI _{OLI} × EVI _{BF}	3,64 [*]
	NDMI _{OLI} × NDMI _{MSI}	1,00 ^{ns}

z estatístico = 1,96: significativo a 95% de probabilidade; * diferença significativa; ns= não-significante.


Fonte: O Autor (2019).

Na Tabela 25 percebe-se que algumas classificações diferiram significativamente ao nível de 95%, entre elas o índice ARVI para o período de agosto, e para o período de dezembro os índices SAVI, ARVI e EVI. Embora os índices NDMI, apresentaram seus Kappas no intervalo de 0,59 a 0,71 eles não apresentaram diferença significativa entre os sensores.

4.3.2 Classificação dos Índices Espectrais em reflectância BOA


O método de classificação pelo *Random Forest* para os índices estudados para o período de agosto de 2017 e dezembro de 2017 pode ser visto na Figura 36 e 37 respectivamente.

Figura 36 – Classificação pelo *Random Forest* dos índices espectrais em reflectância BOA, agosto de 2017.



Fonte: O Autor (2019).

Figura 37 – Classificação pelo *Random Forest* dos índices espectrais em reflectância BOA, dezembro de 2017.



Fonte: O Autor (2019).

Na Tabela 26, encontram-se desempenho geral, e o índice Kappa da classificação de cada índice espectral, em nível de reflectância BOA, para o período de agosto de 2017 e dezembro de 2017.

Tabela 26 - Estatísticas gerais da classificação *Random Forest* em nível de reflectância BOA, para o período de agosto de 2017 e dezembro de 2017.

Período	Índice	Desempenho Geral	Índice Kappa	Qualidade
Agosto/2017	NDVI _{OLI}	0,85	0,81	Excelente
	NDVI _{MSI}	0,87	0,84	Excelente
	NDVI _{BF}	0,89	0,86	Excelente
	SAVI _{OLI}	0,91	0,88	Excelente
	SAVI _{MSI}	0,89	0,86	Excelente
	SAVI _{BF}	0,92	0,89	Excelente
	ARVI _{OLI}	0,84	0,79	Muito bom
	ARVI _{MSI}	0,83	0,78	Muito bom
	ARVI _{BF}	0,83	0,78	Muito bom
	EVI _{OLI}	0,86	0,83	Excelente
	EVI _{MSI}	0,89	0,86	Excelente
	EVI _{BF}	0,91	0,88	Excelente
	NDMI _{OLI}	0,63	0,54	Bom
	NDMI _{MSI}	0,69	0,60	Muito bom
Dezembro/2017	NDVI _{OLI}	0,89	0,87	Excelente
	NDVI _{MSI}	0,91	0,89	Excelente
	NDVI _{BF}	0,91	0,88	Excelente
	SAVI _{OLI}	0,93	0,91	Excelente
	SAVI _{MSI}	0,91	0,89	Excelente
	SAVI _{BF}	0,89	0,87	Excelente
	ARVI _{OLI}	0,94	0,93	Excelente
	ARVI _{MSI}	0,89	0,86	Excelente
	ARVI _{BF}	0,87	0,83	Excelente
	EVI _{OLI}	0,92	0,89	Excelente
	EVI _{MSI}	0,90	0,87	Excelente
	EVI _{BF}	0,88	0,84	Excelente
	NDMI _{OLI}	0,78	0,72	Muito bom
	NDMI _{MSI}	0,67	0,58	Bom

Fonte: O Autor (2019).

Ao se analisar a Tabela 26, observa-se que as classificações pelo *Random Forest* dos índices espectrais em nível de reflectância BOA, obtiveram sua qualidade em sua maioria de acordo com o índice Kappa, como excelente. Os menores valores do índice Kappa foram dos índices NDMI_{OLI} e NDMI_{MSI} (0,54 e 0,58) do período de

agosto e dezembro de 2017, respectivamente e obtiveram qualidade classificada como bom.

Na Tabela 27, é expresso o teste z para avaliar a significância estatística entre as classificações dos sensores, ao nível de significância de 5%, com valor crítico de 1,96.

Tabela 27 - Teste z para significância da classificação *Random Forest* de diferentes índices espectrais em nível de reflectância BOA.

Período	Índice	Z calculado
Agosto/2017	NDVI _{OLI} × NDVI _{MSI}	0,89 ^{ns}
	NDVI _{OLI} × NDVI _{BF}	1,82 ^{ns}
	SAVI _{OLI} × SAVI _{MSI}	0,52 ^{ns}
	SAVI _{OLI} × SAVI _{BF}	0,52 ^{ns}
	ARVI _{OLI} × ARVI _{MSI}	0,38 ^{ns}
	ARVI _{OLI} × ARVI _{BF}	0,26 ^{ns}
	EVI _{OLI} × EVI _{MSI}	1,06 ^{ns}
	EVI _{OLI} × EVI _{BF}	1,95 ^{ns}
	NDMI _{OLI} × NDMI _{MSI}	1,28 ^{ns}
Dezembro/2017	NDVI _{OLI} × NDVI _{MSI}	0,89 ^{ns}
	NDVI _{OLI} × NDVI _{BF}	0,62 ^{ns}
	SAVI _{OLI} × SAVI _{MSI}	0,57 ^{ns}
	SAVI _{OLI} × SAVI _{BF}	1,51 ^{ns}
	ARVI _{OLI} × ARVI _{MSI}	2,39*
	ARVI _{OLI} × ARVI _{BF}	3,22*
	EVI _{OLI} × EVI _{MSI}	0,90 ^{ns}
	EVI _{OLI} × EVI _{BF}	1,77 ^{ns}
	NDMI _{OLI} × NDMI _{MSI}	3,35*

z estatístico = 1,96: significante a 95% de probabilidade; * diferença significativa; ns= não-significante.

Fonte: O Autor (2019).

Na Tabela 27 percebe-se que as classificações derivadas dos índices espectrais, computados com a banda 8 do sensor MSI, não apresentaram diferença significativa estatística, ao ser comparada com os índices obtidos com o sensor OLI, com exceção das classificações nos índices ARVI, e NDMI do período de dezembro que diferiram significativamente. As demais comparações entre as classificações não obtiveram diferença significativa.

Foi notório que após a utilização da correção atmosférica, obtendo-se a reflectância BOA, as classificações do *Random Forest* obtiveram um melhor desempenho, ao aplicar o teste z. Esses resultados condizem com Ganem et al.

(2017), que em estudo obtiveram melhores classificações quando utilizaram a correção atmosférica em relação aos dados TOA, na área de estudo de Bom Jesus da Lapa – BA.

Nas Tabelas 28 e 29 encontra-se a exatidão do produtor e do usuário, correspondentes aos índices espectrais que obtiveram o melhor desempenho no índice Kappa, em reflectância BOA, para ambos os períodos estudados.

Tabela 28 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por *Random Forest*, agosto de 2017, reflectância BOA.

ROI	Corpos Hídricos		Área Construída		Solo sem vegetação		Agricultura Irrigada		Vegetação Caatinga	
	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu
NDVI _{OLI}	1,00	1,00	0,95	0,62	0,52	0,92	0,86	0,99	0,98	0,78
NDVI _{MSI}	1,00	1,00	0,93	0,87	0,76	0,84	0,90	0,83	0,78	0,87
NDVI _{BF}	1,00	1,00	0,95	0,91	0,83	0,89	0,89	0,86	0,81	0,86
SAVI _{OLI}	0,96	1,00	0,95	0,74	0,63	0,92	0,95	0,99	0,98	0,93
SAVI _{MSI}	0,85	1,00	0,97	0,75	0,74	0,95	0,94	0,94	0,90	0,91
SAVI _{BF}	0,84	0,98	0,93	0,84	0,89	0,89	0,95	0,97	0,93	0,93
EVI _{OLI}	0,92	1,00	0,92	0,64	0,54	0,86	0,93	0,97	0,95	0,90
EVI _{MSI}	0,90	1,00	1,00	0,72	0,67	1,00	0,91	0,96	0,92	0,87
EVI _{BF}	0,86	1,00	0,98	0,74	0,73	0,97	0,95	0,98	0,94	0,93

Fonte: O Autor (2019).

Na Tabela 28, foi possível concluir que entre os índices analisados o NDVI, foi o que obteve a melhor exatidão do produtor para a classe corpo hídrico, apontando que 100% dos pixels coletados foram realmente classificados como tal, e melhor exatidão do usuário, onde 100% das vezes que um observador visualizar um pixel referente a água, realmente esse pixel estará classificado como água.

Ao observar a classe área construída, o índice que conseguiu representar melhor dentro dos sensores analisados, foi o NDVI, com exatidões do produtor de 0,95; 0,93 e 0,95 para cálculos com OLI, MSI e BF, representando que no mínimo 93% dos pixels coletados foram classificados como área construída. E obteve uma exatidão do usuário de 0,62; 0,87 e 0,91, o que representa que ao menos 62% que um observador visualizar um pixel referente a área construída, realmente esse pixel estará classificado como esta classe.

A classe solo sem vegetação foi melhor representada com o índice SAVI, apresentando exatidões do produtor (0,63; 0,75 e 0,89) e usuário (0,92; 0,95 e 0,89), nas três variações OLI, MSI e BF.

De acordo com Pereira e Tavares Júnior (2017), as classes de área urbana e solo sem vegetação tendem a apresentar valores espectrais semelhantes, o que vem a ocasionar os baixos valores de exatidão do produtor dessas classes.

Em relação as classes Agricultura Irrigada e Vegetação Caatinga, os índices EVI e SAVI foram os que melhor as representaram respectivamente.

Tabela 29 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por *Random Forest*, dezembro de 2017, reflectância BOA.

ROI	Corpos Hídricos		Área Construída		Solo sem vegetação		Agricultura Irrigada		Vegetação Caatinga	
Índice	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu
NDVI _{OLI}	1,00	1,00	1,00	0,59	0,51	1,00	1,00	1,00	1,00	1,00
NDVI _{MSI}	0,96	1,00	0,91	0,75	0,62	0,84	1,00	0,99	0,99	1,00
NDVI _{BF}	0,96	0,98	0,91	0,73	0,60	0,86	1,00	0,99	0,99	1,00
SAVI _{OLI}	0,98	1,00	0,98	0,73	0,62	0,97	1,00	1,00	1,00	1,00
SAVI _{MSI}	0,83	1,00	0,98	0,69	0,68	0,97	1,00	0,99	0,99	1,00
SAVI _{BF}	0,79	1,00	1,00	0,61	0,64	0,95	1,00	1,00	0,96	1,00
EVI _{OLI}	0,96	1,00	0,88	0,85	0,64	0,73	1,00	1,00	1,00	0,94
EVI _{MSI}	0,83	1,00	0,93	0,66	0,62	0,89	1,00	0,99	0,99	1,00
EVI _{BF}	0,92	1,00	0,98	0,59	0,54	0,86	1,00	1,00	0,88	0,99

Fonte: O Autor (2019).

Ao se analisar a Tabela 29, constatou-se que a classe corpo hídrico foi melhor representada pelo índice NDVI, onde o menor valor de exatidão do produtor foi 0,96 e exatidão do usuário 0,98, considerando as três variantes desse índice OLI, MSI e BF.

A classe área construída por sua vez foi das regiões de interesse que obteve menor exatidão do usuário valores no intervalo de 0,59 a 0,85. Entretanto sua exatidão do produtor variou de 0,88 a 1,00. Ou seja embora, muitos dos pixels amostrais tenham sido classificados como essa classe, à medida que o observador contempla a classificação apenas 59% a 85% condiz com a realidade. O inverso ocorre na classe Solo sem vegetação a exatidão do usuário variou de 0,73 a 1,00 enquanto que a


exatidão do produtor variou de 0,51 a 0,68. O que implica que houve muita confusão entre as classes, nesse caso área urbanizada e solo sem vegetação.

A classe agricultura irrigada foi bem representa pelos 3 índices e na classe Vegetação Caatinga o índice NDVI foi o que apresentou melhor classificação.

De acordo com Fonseca et al. (2017) e França, Tavares Junior e Moreira (2012), as combinações coloridas usando índices espectrais destacam melhor os alvos quando comparados com as combinações do visível.


Neste sentido foi proposto a combinação de alguns dos índices aqui estudados, para avaliação do classificador *Random Forest*. Foram avaliadas as composições dos índices espectrais em reflectância BOA: (SAVI; ARVI; EVI), (SAVI; NDMI; EVI), (SAVI; ARVI; NDMI) e a composição de todos os índices espectrais. Suas classificações pelo *Random Forest* podem ser vistas nas Figuras 38 e 39.

Figura 38 – Classificação pelo *Random Forest* das combinações dos índices espectrais em reflectância BOA, agosto de 2017.



Fonte: O Autor (2019).

Figura 39 – Classificação pelo *Random Forest* das combinações dos índices espectrais em reflectância BOA, dezembro de 2017.



Fonte: O Autor (2019).

Na Tabela 30, encontram-se desempenho geral, e o índice Kappa da classificação de cada combinação, em nível de reflectância BOA, para o período de agosto de 2017 e dezembro de 2017.

Tabela 30 - Estatísticas gerais da classificação *Random Forest* em nível de reflectância BOA, para o período de agosto de 2017 e dezembro de 2017.

Período	Combinação de Índices	Desempenho Geral	Índice Kappa	Qualidade
Agosto/2017	(SAVI;ARVI;EVI) _{OLI}	0,91	0,88	Excelente
	(SAVI;ARVI;EVI) _{MSI}	0,90	0,87	Excelente
	(SAVI;ARVI;EVI) _{BF}	0,95	0,93	Excelente
	(SAVI;NDMI;EVI) _{OLI}	0,91	0,88	Excelente
	(SAVI;NDMI;EVI) _{MSI}	0,90	0,87	Excelente
	(SAVI;NDMI;EVI) _{BF}	0,91	0,89	Excelente
	(SAVI;ARVI;NDMI) _{OLI}	0,91	0,88	Excelente
	(SAVI;ARVI;NDMI) _{MSI}	0,91	0,89	Excelente
	(SAVI;ARVI;NDMI) _{BF}	0,93	0,91	Excelente
	(Todos os índices) _{OLI}	0,94	0,92	Excelente
	(Todos os índices) _{MSI}	0,90	0,88	Excelente
	(Todos os índices) _{BF}	0,94	0,93	Excelente
Dezembro/2017	(SAVI;ARVI;EVI) _{OLI}	0,96	0,95	Excelente
	(SAVI;ARVI;EVI) _{MSI}	0,92	0,90	Excelente
	(SAVI;ARVI;EVI) _{BF}	0,91	0,88	Excelente
	(SAVI;NDMI;EVI) _{OLI}	0,95	0,93	Excelente
	(SAVI;NDMI;EVI) _{MSI}	0,92	0,90	Excelente
	(SAVI;NDMI;EVI) _{BF}	0,88	0,85	Excelente
	(SAVI;ARVI;NDMI) _{OLI}	0,96	0,95	Excelente
	(SAVI;ARVI;NDMI) _{MSI}	0,94	0,93	Excelente
	(SAVI;ARVI;NDMI) _{BF}	0,91	0,89	Excelente
	(Todos os índices) _{OLI}	0,99	0,99	Excelente
	(Todos os índices) _{MSI}	0,94	0,92	Excelente
	(Todos os índices) _{BF}	0,98	0,97	Excelente

Fonte: O Autor (2019).

Ao se analisar a Tabela 30, observou-se que as classificações pelo *Random Forest* das combinações dos índices espectrais em nível de reflectância BOA, obtiveram sua qualidade de acordo com o índice Kappa, como excelente. O menor valor do índice Kappa (0,85) foi na combinação (SAVI;NDMI;EVI)_{BF} do período de dezembro.

Na Tabela 31, é expresso o teste z para avaliar a significância estatística entre as classificações dos sensores, ao nível de significância de 5%, com valor crítico de 1,96.

Tabela 31 - Teste z para significância da classificação *Random Forest* de diferentes combinações dos índices espectrais em nível de reflectância BOA.

Período	Índice	Z calculado
Agosto/2017	$(SAVI;ARVI;EVI)_{OLI} \times (SAVI;ARVI;EVI)_{MSI}$	0,13 ^{ns}
	$(SAVI;ARVI;EVI)_{OLI} \times (SAVI;ARVI;EVI)_{BF}$	2,21*
	$(SAVI;NDMI;EVI)_{OLI} \times (SAVI;NDMI;EVI)_{MSI}$	0,54 ^{ns}
	$(SAVI;NDMI;EVI)_{OLI} \times (SAVI;NDMI;EVI)_{BF}$	0,12 ^{ns}
	$(SAVI;ARVI;NDMI)_{OLI} \times (SAVI;ARVI;NDMI)_{MSI}$	0,25 ^{ns}
	$(SAVI;ARVI;NDMI)_{OLI} \times (SAVI;ARVI;NDMI)_{BF}$	1,13 ^{ns}
	$(Todos\ os\ índices)_{OLI} \times (Todos\ os\ índices)_{MSI}$	1,73 ^{ns}
	$(Todos\ os\ índices)_{OLI} \times (Todos\ os\ índices)_{BF}$	0,16 ^{ns}
Dezembro/2017	$(SAVI;ARVI;EVI)_{OLI} \times (SAVI;ARVI;EVI)_{MSI}$	2,20*
	$(SAVI;ARVI;EVI)_{OLI} \times (SAVI;ARVI;EVI)_{BF}$	3,02*
	$(SAVI;NDMI;EVI)_{OLI} \times (SAVI;NDMI;EVI)_{MSI}$	1,42 ^{ns}
	$(SAVI;NDMI;EVI)_{OLI} \times (SAVI;NDMI;EVI)_{BF}$	2,99*
	$(SAVI;ARVI;NDMI)_{OLI} \times (SAVI;ARVI;NDMI)_{MSI}$	1,28 ^{ns}
	$(SAVI;ARVI;NDMI)_{OLI} \times (SAVI;ARVI;NDMI)_{BF}$	2,63*
	$(Todos\ os\ índices)_{OLI} \times (Todos\ os\ índices)_{MSI}$	4,42*
	$(Todos\ os\ índices)_{OLI} \times (Todos\ os\ índices)_{BF}$	1,84 ^{ns}

z estatístico = 1,96: significante a 95% de probabilidade; * diferença significativa; ns= não-significante.

Fonte: O Autor (2019).

Ao se analisar as Tabelas 30 e 31, observa-se que apesar da classificação combinada dos índices espectrais ter aumentado o valor do índice Kappa, ainda houve diferença significativa entre os modelos avaliados quando comparados ao sensor OLI, a exemplo dos: $(SAVI;ARVI;EVI)_{BF}$ no período de agosto, e $(SAVI;ARVI;EVI)_{MSI}$, $(SAVI;ARVI;EVI)_{BF}$, $(SAVI;NDMI;EVI)_{BF}$, $(SAVI;ARVI;NDMI)_{BF}$, e $(Todos\ os\ índices)_{MSI}$ do período de dezembro.

Nas Tabelas 32 e 33 encontra-se a exatidão do produtor e do usuário, correspondentes as combinações que obtiveram o melhor desempenho no índice Kappa, em reflectância BOA, para ambos os períodos estudados.

Na Tabela 32, foi possível observar que o menor valor de exatidão do produtor foi de 0,69 na classe Solo sem Vegetação. E o menor valor de exatidão do usuário foi

de 0,76 na classe Área Construída. Notou-se que se apesar da combinação dos índices ter aumentado o valor das exatidões do produtor e usuário ainda houve confusão nas classes Área construída e Solo sem vegetação.

Tabela 32 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por *Random Forest*, agosto de 2017, reflectância BOA.

ROI	Corpos Hídricos		Área Construída		Solo sem vegetação		Agricultura Irrigada		Vegetação Caatinga	
	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu
(SAVI;NDMI;EVI) _{OLI}	0,94	1,00	0,97	0,78	0,69	0,95	0,97	0,94	0,92	0,96
(SAVI;NDMI;EVI) _{MSI}	0,85	1,00	0,96	0,76	0,76	0,92	0,94	0,95	0,91	0,91
(SAVI;NDMI;EVI) _{BF}	0,80	1,00	0,97	0,76	0,83	0,95	0,96	0,97	0,93	0,94
(SAVI;ARVI;NDMI) _{OLI}	1,00	1,00	0,96	0,82	0,69	0,92	0,95	0,93	0,90	0,93
(SAVI;ARVI;NDMI) _{MSI}	0,98	1,00	0,96	0,89	0,83	0,92	0,93	0,91	0,86	0,90
(SAVI;ARVI;NDMI) _{BF}	1,00	1,00	0,97	0,89	0,83	0,95	0,91	0,98	0,94	0,87
(Todos os índices) _{OLI}	1,00	1,00	0,97	0,88	0,78	0,95	0,97	0,95	0,93	0,96
(Todos os índices) _{MSI}	1,00	1,00	0,97	0,80	0,69	0,95	0,95	0,92	0,88	0,93
(Todos os índices) _{BF}	1,00	1,00	0,99	0,87	0,78	0,97	0,97	0,96	0,93	0,96

Fonte: O Autor (2019).

Vale destacar, os bons valores das classificações da composição com todos os índices espectrais, onde apenas a exatidão do produtor da classe solo sem vegetação teve um intervalo de 0,69 a 0,78. Nas demais classes tanto a exatidão do produtor como do usuário foram superiores a 0,80.

Na Tabela 33, observa-se que o menor valor de exatidão do produtor foi de 0,59 na classe Solo sem Vegetação. E o menor valor de exatidão do usuário foi de 0,58 na classe Área Construída, ambos na composição (SAVI;NDMI;EVI)_{BF}. A melhor combinação para representação das classes foi a com todos os índices espectrais, onde o menor valor de exatidão do produtor foi de 0,74, e o menor valor de exatidão do usuário foi de 0,80 na classe Área construída, ambos no computo com o sensor MSI. Nos demais casos da combinação com todos os índices espectrais os valores de exatidões do produtor e usuário foram superiores a 0,83.

Tabela 33 - Exatidão do produtor (Kcp) e usuário (Kcu) da classificação por *Random Forest*, dezembro de 2017, reflectância BOA.

ROI	Corpos		Área		Solo sem		Agricultura		Vegetação	
	Hídricos		Construída		vegetação		Irigada		Caatinga	
Índice	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu	Kcp	Kcu
(SAVI;NDMI;EVI) _{OLI}	0,96	1,00	1,00	0,80	0,71	1,00	1,00	1,00	1,00	1,00
(SAVI;NDMI;EVI) _{MSI}	0,83	1,00	1,00	0,71	0,70	1,00	1,00	0,99	0,99	1,00
(SAVI;NDMI;EVI) _{BF}	0,79	1,00	0,98	0,58	0,59	0,97	1,00	1,00	1,00	0,99
(SAVI;ARVI;NDMI) _{OLI}	0,98	1,00	1,00	0,86	0,77	1,00	1,00	1,00	1,00	1,00
(SAVI;ARVI;NDMI) _{MSI}	0,98	1,00	1,00	0,79	0,69	1,00	1,00	0,99	0,99	1,00
(SAVI;ARVI;NDMI) _{BF}	0,79	1,00	0,97	0,69	0,72	0,97	1,00	1,00	1,00	0,99
(Todos os índices) _{OLI}	1,00	1,00	1,00	0,99	0,97	1,00	1,00	1,00	1,00	1,00
(Todos os índices) _{MSI}	0,92	1,00	0,96	0,80	0,74	0,92	1,00	0,99	0,97	1,00
(Todos os índices) _{BF}	0,94	1,00	0,97	0,88	0,83	0,95	1,00	0,99	0,99	1,00

Fonte: O Autor (2019).

5 CONCLUSÃO

A presente pesquisa revelou que as características radiométricas e espectrais dos sensores OLI e MSI - embora semelhantes - não são idênticas e podem produzir diferenças consideráveis. Ao avaliar as bandas do visível, infravermelho próximo e infravermelho médio, das imagens entre os sensores OLI e MSI, nos níveis de reflectância TOA e BOA, os resultados apontaram que as maiores diferenças médias, entre os sensores estão na região do infravermelho próximo. Entretanto essa diferença foi reduzida ao se comparar a 5 do OLI com a 8A do MSI.

Neste estudo foi proposto a fusão das imagens 8 e 8A do sensor MSI, pelo método LMVM. Os resultados mostraram que a banda fusionada obteve coeficientes de R^2 superiores a 0,837, ao se comparar com a banda 5 do OLI em termos de reflectância TOA, e superiores a 0,856 em reflectância BOA. Os índices espectrais computados com a banda fusionada se mantiveram mais próximos dos índices obtidos com o sensor OLI, tanto em termos médios como visualmente. Os índices obtidos com a reflectância BOA, obtiveram melhora visual dos alvos.

Em relação às classificações através do *Random Forest*, as piores qualidades do coeficiente Kappa foram para os índices ARVI e NDMI, os demais índices tiveram sua qualidade como excelente em reflectância TOA e BOA. Ao aplicar o teste z, verificou-se que as classificações pelo *Random Forest* dos índices espectrais, mostraram-se melhor em reflectância BOA, e os índices obtidos com o sensor MSI, comparados com os índices do sensor OLI, não diferiram estatisticamente, exceto o ARVI e NDMI em dezembro.

Nas exatidões do produtor e usuário constatou-se que as maiores confusões foram nas classes Solo sem vegetação e Área urbanizada uma vez que, as respostas espectrais dessas classes são semelhantes.

A classificação *Random Forest* foi aplicada com as combinações dos índices espectrais, e constatou-se que a qualidade do coeficiente Kappa foi como excelente. A composição, que obteve melhor representação das classes, foi a composta com todos os índices espectrais.

Por fim, é possível concluir que o Sentinel-2 tem grande potencial de uso e estudos com o sensor MSI vão contribuir para o monitoramento e gestão do meio ambiente, com maior fidedignidade e precisão dos alvos. Estudos com multisensores destacam características individuais de cada sensor, e vem a colaborar no desenvolvimento do Sensoriamento Remoto.

6 SUGESTÃO DE TRABALHOS FUTUROS

Ademais, seria interessante que trabalhos futuros adotassem procedimentos baseados na classificação *Random Forest*, em outras regiões semiáridas, visto que o algoritmo possui um bom potencial de classificação em vegetações complexas, como a Caatinga, e permite a incorporação de uma elevada quantidade de dados com baixo tempo de processamento.

Outro trabalho sugerido seria a inserção de outros sensores a exemplo do LiDAR e de imagens de luz noturna da Administração Nacional Oceânica e Atmosférica (NOAA), juntamente com composição dos índices espectrais, com intuito de se obter uma melhor distinção entre solo sem vegetação e área urbana, e avaliar o comportamento dessa classificação.

REFERÊNCIAS

- ALBUQUERQUE, E. M. et al. Análise do comportamento do NDVI e NDWI sob diferentes intensidades pluviométricas no município de Sousa-PB. **Revista Estudos Geoambientais**, v. 1, n. 1, 2014.
- ANJOS, C. S. **O Sensoriamento Remoto como Ferramenta para Planejamento de Inventários Florestais por Índices de Vegetação**. 2017. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação) - Universidade Federal de Pernambuco, 2017.
- APAC – Agência Pernambucana de Águas e Climas. **Sistema de Informação Geográfica**. Disponível em: <<http://www.apac.pe.gov.br/sighpe/>>. Acesso em: 09 set. 2018.
- ASCHBACHER, J.; MILAGRO-PÉREZ, M. P. The european Earth monitoring (GMES) programme: status and perspectives. **Remote Sensing of Environment**, v. 120, n. 2012, p. 3-8, 2012.
- BALLÉN, L. A. C.; SOUZA, B. I.; LIMA, E. R. V. Análise espaço-temporal da cobertura vegetal na área de proteção ambiental do cariri, paraíba, brasil. **Boletim Goiano de Geografia**, v. 36, n. 3, p. 555-571, 2016.
- BAPTISTA, G. M. M. **Mapeamento e quantificação da relação Caulinita/ (Caulinita+Gibbsita) de solos tropicais, por meio dos dados do sensor AVIRIS (JPL/NASA)**. 2001. 278 f. Tese (Doutorado). Instituto de Geociências Aplicadas, Universidade de Brasília, 2001.
- BETHUNE, S.; MULLER, F.; BINARD, M. **Adaptive intensity matching filters: a new tool for multiresolution data fusion**. 1997. Disponível em: <<https://www.fabrice-muller.be/pdf-download/publications/agard.pdf>>. Acesso em: 09 set. 2018.
- BEZERRA, U. A. et al. Multitemporal analysis of vegetation indices for the superior region of the Moxotó River hydrographic basin. **Journal Of Hyperspectral Remote Sensing**, v. 7, p. 272-283, 2017.
- BEZERRA, U. A. et al. Análise de índices de umidade no entorno do reservatório de Itaparica - PE. In: XIV SRHNE - Simpósio de Recursos Hídricos do Nordeste, 2018, Maceio - AL. **ANAIS XIV SRHNE**, 2018.
- BOKE-OLÉN, N. et al. Remotely sensed soil moisture to estimate savannah NDVI. **PloS one**, v. 13, n. 7, p. e0200328, 2018.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.
- CALLEGARI-JACQUES, S.M. **Bioestatística: princípios e aplicações**. Porto Alegre, Artmed. 255 p. 2003.
- CARVALHO, A. A.; BAPTISTA, G. M. Influência da correção atmosférica na conversão dos dados de radiância para reflectância para o cálculo do EVI em imagem rapideye. **Revista Brasileira de Cartografia**, v. 67, n. 7, 2015.

CASTRO, R. A.; FABRICANTE, J. R.; SIQUEIRA FILHO, J. A. A importância da palmeira *syagrus coronata* (mart.) Beec. para a conservação da riqueza e diversidade de espécies epífitas vasculares na caatinga. **Revista Árvore**, v. 40, n. 1, p. 1-12, 2016.

CHAVEZ, P. et al. Comparison of three different methods to merge multiresolution and multispectral data- Landsat TM and SPOT panchromatic. **Photogrammetric Engineering and remote sensing**, v. 57, n. 3, p. 295-303, 1991.

CHEN, X. et al. Cross-sensor comparisons between Landsat 5 TM and IRS-P6 AWiFS and disturbance detection using integrated Landsat and AWiFS time-series images. **International Journal Remote Sensing**, v. 34, n. 7, p. 2432-2453, 2013

CLICHE, F. Integration of the SPOT panchromatic channel into its multispectral mode for image sharpness enhancement. **Photogrammetric Engineering and Remote Sensing**, v. 51, n. 3, p. 311-316, 1985.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. CRC press, 137p. 2008.

CORRÊA, A. C. B.; CAVALCANTI, L. C. S; LIRA, D. R. Stone and Sand Ruins in the Drylands of Brazil: The Rustic Landscapes of Catimbau National Park. **Landscapes and Landforms of Brazil**. Springer, Dordrecht, p. 243-251, 2015.

DELEGIDO, J. et al. Brown and green LAI mapping through spectral indices. **International Journal of Applied Earth Observation and Geoinformation**, v. 35, p. 350-358, 2015.

DONG, T. et al. Modified vegetation indices for estimating crop fraction of absorbed photosynthetically active radiation. **International Journal of Remote Sensing**, v. 36, n. 12, p. 3097-3113, 2015.

DRUSCH, M. et al. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. **Remote Sensing of Environment**, v. 120, p. 25-36, 2012.

DUBE, T. et al. Estimating soil organic and aboveground woody carbon stock in a protected dry Miombo ecosystem, Zimbabwe: Landsat 8 OLI data applications. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 105, p. 154-160, 2018.

DURAN, J. et al. A survey of pansharpening methods with a new band-decoupled variational model. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 125, p. 78-105, 2017.

EMDE, C. et al. The libradtran software package for radiative transfer calculations (version 2.0.1). **Geoscientific Model Development**, v. 9, n. 5, p. 1647-1672, 2016.

ESA - European Space Agency. 2013. "**Sentinel-1 User Handbook**". Disponível em: <https://sentinel.esa.int/documents/247904/685163/Sentinel1_User_Handbook/06fa0b55-9eca-47ff-a45f-242012951564>. Acesso em: 18 nov. 2017.

ESA - European Space Agency. **Sentinels Scientific Data Hub**, 2017. Disponível em: <<https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>>. Acesso em: 08 mar. 2018.

FAN, H. et al. Phenology-based vegetation index differencing for mapping of rubber plantations using Landsat OLI data. **Remote Sensing**, v. 7, n. 5, p. 6041-6058, 2015.

FLOOD, N. Comparing Sentinel-2A and Landsat 7 and 8 Using Surface Reflectance over Australia. **Remote Sensing**, v. 9, n. 7, p.659, 2017.

FONSECA, L. M.; MANJUNATH, B. S. Registration techniques for multisensor remotely sensed imagery. **Photogrammetric Engineering & Remote Sensing**, v. 62, n. 9, p. 1049-1056, 1996.

FONSECA, R. C.; CANDEIAS, A.L.B; SOUZA, R. S ; SIQUEIRA, E. S ; SILVA, R.L . Índices NDVI, NDBI e NDWI para realce da água, culturas irrigadas e solo exposto no entorno do reservatório de Itaparica. **Anais do 9º Encontro Internacional das Águas**, 2017.

FRAMPTON, W. J. et al. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS J. Photogramm. Remote Sensing**, v. 82, p. 83-92, 2013.

FRANCISCO, P. R. M. et al. Mapeamento da Caatinga com Uso de Geotecnologia e Análise da Umidade Antecedente em Bacia Hidrográfica. **Revista Brasileira de Geografia Física**, v. 5, n. 3, p. 676-693, 2012.

FRANÇA, A. F.; TAVARES JUNIOR, J. R.; MOREIRA FILHO, J. C.C. Índices NDVI, NDWI E NDBI como ferramentas ao mapeamento temático do entorno da lagoa olho d'água, em Jaboatão dos Guararapes-PE. **IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, Recife, PE, 2012.

GANEM, K. et al. Comparação entre dados com e sem correção atmosférica na classificação da cobertura da terra de uma área da caatinga utilizando o Google Earth Engine. **Revista Brasileira de Cartografia**, v. 69, n. 6.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996.

GROSSO, C. et al. Mapping Maize Evapotranspiration at Field Scale Using SEBAL: A Comparison with the FAO Method and Soil-Plant Model Simulations. **Remote Sensing**, v. 10, n. 9, p. 1452, 2018.

HALABISKY, M.; BABCOCK, C.; MOSKAL, L. Harnessing the Temporal Dimension to Improve Object-Based Image Analysis Classification of Wetlands. **Remote Sensing**, v. 10, n. 9, p. 1467, 2018.

HARDISKY, M. A.; KLEMAS, V.; SMART, M. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of. **Spartina alterniflora**, v. 49, p. 77-83, 1983.

HE, D. et al. Temporal and Spatial Characteristics of EVI and Its Response to Climatic Factors in Recent 16 years Based on Grey Relational Analysis in Inner Mongolia Autonomous Region, China. **Remote Sensing**, v. 10, n. 6, p. 961, 2018.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

HUETE, A. R. A soil adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295-309, 1988.

HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for MODIS-EOS. **Remote Sensing of Environment**, v. 59, p. 440-451, 1997.

HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

INGLADA, J.; CHRISTOPHE, E. The Orfeo Toolbox remote sensing image processing software. In: **Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009**. p. IV-733-IV-736, 2009.

JACKSON, R.D.; HUETE, A. R. Interpreting vegetation indices. **Journal of Preventive Veterinary Medicine**, v. 11, p. 185-200, 1991.

JARCHOW, C. J. et al. Application and Comparison of the MODIS-Derived Enhanced Vegetation Index to VIIRS, Landsat 5 TM and Landsat 8 OLI Platforms: A Case Study in the Arid Colorado River Delta, Mexico. **Sensors**, v. 18, n. 5, p. 1546, 2018.

JENSEN, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos, SP: Parêntese editora, 2011, 672p.

JI, L. et al. On the terminology of the spectral vegetation index $(NIR - SWIR)/(NIR + SWIR)$. **International journal of remote sensing**, v. 32, n. 21, p. 6901-6909, 2011.

JOLY, Gérard. **Traitements des fichiers-images**. 1986.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, n.4, p.1228-1249, 1998.

KACZYNSKI, R.; DONNAY, J. P.; MULLER, F. Satellite image maps of Warsaw in the scale 1: 25,000. **EARSeL Advances in Remote Sensing**, v. 4, p. 100-102, 1995.

KARAKIZI, C. et al. Detailed Land Cover Mapping from Multitemporal Landsat-8 Data of Different Cloud Cover. **Remote Sensing**, v. 10, n. 8, p. 1214, 2018.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.

KONDA, V. G. R. K. et al. Vegetation damage assessment due to Hudhud cyclone based on NDVI using Landsat-8 satellite imagery. **Arabian Journal of Geosciences**, v. 11, n. 2, p. 35, 2018.

- KUIAWSKI, A. C. M. B. et al. Vegetation indexes and delineation of management zones for soybean. **Pesquisa Agropecuária Tropical**, v. 47, n. 2, p. 168-177, 2017.
- LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. *Biometrics*. **International Biometric Society**, v. 33, n. 1, p. 159-174, 1977.
- LARY, D. J. et al. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016.
- LEITE, A. C. S. et al. Comparison of methods of Humidity Index processing in the Irrigated Perimeter Nilo Coelho, Northeast of Brazil. **Journal of Hyperspectral Remote Sensing**, v. 7, n. 6, p. 315-323, 2017.
- LI, P.; JIANG, L.; FENG, Z. Cross-comparison of vegetation indices derived from Landsat-7 enhanced thematic mapper plus (ETM+) and Landsat-8 operational land imager (OLI) sensors. **Remote Sensing**, v. 6, n. 1, p. 310-329, 2014.
- LI, S. et al. Sentinel-2 MSI Radiometric Characterization and Cross-Calibration with Landsat-8 OLI. **Advances in Remote Sensing**, v. 6, n. 2, p. 147-159. 2017.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 7a ed. Hoboken: Wiley, 2015.
- LIU, M. et al. Heavy metal-induced stress in rice crops detected using multi-temporal Sentinel-2 satellite images. **Science of the Total Environment**, v. 637, p. 18-29, 2018.
- LOBO, F. et al. Mapping Mining Areas in the Brazilian Amazon Using MSI/Sentinel-2 Imagery (2017). **Remote Sensing**, v. 10, n. 8, p. 1178, 2018.
- LOUIS, J. et al. Sentinel-2 Sen2Cor: L2A Processor for Users. In: **Living Planet Symposium**. 2016. p. 91.
- LU, D., LI, G., MORAN, E., & HETRICK, S. Spatiotemporal analysis of land-use and land-cover change in the Brazilian Amazon. **International journal of remote sensing**, v. 34, n. 16, p. 5953-5978, 2013.
- MANDANICI, E.; BITELLI, G. Preliminary comparison of Sentinel-2 and Landsat 8 Imagery for a combined use. **Remote Sensing**, v. 8, n. 12, p. 1014, 2016.
- MANABE, V.; MELO, M.; ROCHA, J. Framework for Mapping Integrated Crop-Livestock Systems in Mato Grosso, Brazil. **Remote Sensing**, v. 10, n. 9, p. 1322, 2018.
- MARKOGIANNI, V. et al. An Appraisal of the Potential of Landsat 8 in Estimating Chlorophyll-a, Ammonium Concentrations and Other Water Quality Indicators. **Remote Sensing**, v. 10, n. 7, p. 1018, 2018.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International journal of remote sensing**, v. 17, n. 7, p. 1425-1432, 1996.
- MELO, C. R. **Análise do eixo leste da transposição do rio São Francisco fase aos cenários de uso previstos**. Dissertação (Mestrado) – Universidade Federal de

Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil, Recife: UFPE, 2010.

MMA (Ministério do Meio Ambiente). Plano Diretor de Recursos Hídricos da Bacia do Rio Moxotó, Volume III – Documento Síntese. IICA – Agência de Cooperação Técnica do Brasil, v. 9, 10p. 1998.

MOUSIVAND, A. et al. Multi-temporal, multi-sensor retrieval of terrestrial vegetation properties from spectral-directional radiometric data. **Remote Sensing of Environment**, v. 158, p. 311-330. 2015.

MUELLER-WILM, U.; DEVIGNO, O.; PESSIOT, L. **S2 MPC L2A Product Definition Document**. Paria: ESA, 2015. 35p.

MÜLLER-WILM, U. Sentinel-2 MSI – level-2A prototype processor installation and user manual. **European Space Agency**, (Special Publication) ESA SP, v. 49, n. 2.2, p. 1–51, 2016.

NIKOLAKOPOULOS, K.; OIKONOMIDIS, D. Quality assessment of ten fusion techniques applied on Worldview-2. **European Journal of Remote Sensing**, v. 48, n. 1, p. 141-167, 2015.

OLIVEIRA, K. N. A. Extração Direta de Informação Cartográfica de Média Escala para Base de Dados Geográfica. **Revista Brasileira de Geografia Física**, v. 8, n. 2, p. 283-302, 2015.

OrfeoToolbox. **OTB Cook Book**, Disponível em: <<https://www.orfeo-toolbox.org/CookBook/>>. Acesso em: 13 set. 2018.

OSHIRO, T. M. **Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica**. 2013. Tese de Doutorado. Universidade de São Paulo. 2013.

PADRÓ, J. C. et al. Radiometric Correction of Simultaneously Acquired Landsat-7/Landsat-8 and Sentinel-2A Imagery Using Pseudoinvariant Areas (PIA): Contributing to the Landsat Time Series Legacy. **Remote Sensing**, v. 9, n. 12, p. 1319, 2017.

PASTICK, N. J.; WYLIE, B. K.; WU, Z. Spatiotemporal Analysis of Landsat-8 and Sentinel-2 Data to Support Monitoring of Dryland Ecosystems. **Remote Sensing**, v. 10, n. 5, p. 791, 2018.

PEREIRA, J. A. S.; TAVARES JUNIOR, J. R. Classificação supervisionada e saldo de radiação para discriminação de alvos de superfície no entorno do reservatório de Itaparica-PE. **Revista Brasileira de Cartografia**, v. 69, n. 6, 2017.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da vegetação**. 2 Ed. São Paulo: Oficina de Textos, v.11, n.3-4. 164p. 2012.

RAMOELO, A. et al. Potential of Sentinel-2 spectral configuration to assess rangeland quality. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 94096, 2015.

REN, H.; ZHOU, G.; ZHANG, F. Using negative soil adjustment factor in soil-adjusted vegetation index (SAVI) for aboveground living biomass estimation in arid grasslands. **Remote Sensing of Environment**, v. 209, p. 439-445, 2018.

RIBEIRO, E. P. et al. Estimativa dos índices de vegetação na detecção de mudanças ambientais na bacia hidrográfica do rio Pajeú. **Geosul**, v. 31, n. 62, p. 59-92, 2016.

ROBINSON, N. P. et al. Dynamic Landsat Derived Normalized Difference Vegetation Index (NDVI) Product for the Conterminous United States. **Remote Sensing**, 9, 863. 2017.

ROUSE JR, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In **Proceedings of the Third Earth Resources Technology Satellite-1 Symposium**, Washington, DC, USA, p. 10-14. 1973.

ROY, D. P. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote sensing of Environment**, v. 145, p. 154-172, 2014.

RUHOFF, A.L.; SILVA, B.B.; ROCHA, H.R. Determinação da irradiância solar no topo da atmosfera para cálculo do albedo e balanço de energia a partir de imagens LANDSAT 8 OLI. In: **Simpósio Brasileiro De Sensoriamento Remoto-SBSR**, 17, João Pessoa, PB, 2015. Resumos Expandidos, João Pessoa, INPE 4495-5402. 2015.

SAMPAIO, E.V.S.B.; GIULIETTI, A.M.; VIRGINIO, J.; GAMARRA-ROJAS, C.F.L. (Ed.). **Vegetação e flora da caatinga**. Recife: Associação Plantas do Nordeste; Centro Nordestino de Informação sobre Plantas, 2002. 176p

SANTOS, G. D.; FRANCISCO, C. N.; ALMEIDA, C. M. Mineração de dados aplicada à discriminação da cobertura da terra em imagem LANDSAT 8 OLI. **Boletim de Ciências Geodésicas**, v. 21, n. 4, 2015.

SCHEPERS, L. et al. Burned area detection and burn severity assessment of a heathland fire in Belgium using Airborne Imaging Spectroscopy (APEX). **Remote Sensing**, v. 6, n. 3, p. 1803-1826, 2014.

SECTMA. Demanda e Oferta Hídrica em Pernambuco: Uma Abordagem Indicativa. Recife: Secretaria de Ciência, Tecnologia e Meio Ambiente - SECTMA, 2009.

SIBANDA, M.; MUTANGA, O.; ROUGET, M. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 110, p. 55-65, 2015.

SILVA, B. B. et al. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 1, p. 3-8, 2016.

SIVAGAMI, R. et al. Review of image fusion techniques and evaluation metrics for remote sensing applications. **Indian Journal of Science and Technology**, v. 8, n. 35, 2015.

SILVEIRA, H. F. **Uso de dados do sensor MSI/Sentinel-2 e de LiDAR aerotransportado para mapeamento de fitofisionomias de Caatinga e estudo das relações com atributos físico-químicos dos solos.** Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

SILVEIRA, H. L. F. et al. Use of MSI/Sentinel-2 and airborne LiDAR data for mapping vegetation and studying the relationships with soil attributes in the Brazilian semi-arid region. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 179-190, 2018.

SHARMA, A. et al. Irrigation history estimation using multitemporal Landsat satellite Images: application to an intensive groundwater irrigated agricultural watershed in India. **Remote Sensing**, v. 10, n. 6, p. 893, 2018.

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 Data to Map Sucessional Forest Stages in a Subtropical Forest in Southern Brazil. **Remote Sensing**, v. 9, p. 838. 2017a.

SOTHE, C.; LIESENBERG, V.; DE ALMEIDA, C. M.; SCHIMALSKI, M. B. Abordagens para classificação do estágio sucessiona da vegetação do parque nacional de são Joaquim empregando imagens landsat-8 e rapidez. **Boletim de Ciências Geodésicas**, v. 23, n. 3, 2017b.

SOUZA, A. et al. Use of SMOS L3 Soil Moisture Data: Validation and Drought Assessment for Pernambuco State, Northeast Brazil. **Remote Sensing**, v. 10, n. 8, p. 1314, 2018.

TEILLET, P. M. et al. Impacts of Spectral Band Difference Effects on Radiometric Cross-Calibration Between Satellite Sensors in the Solar-Reflective Spectral Domain. **Remote Sensing of Environment**, v. 110, p. 393-409, 2007.

TEIXEIRA, A. M. A.; CANDEIAS, A. L. B.; TAVARES JUNIOR, J. R. Comparação dos índices de vegetação para imagens TM/Landsat 5, com correção e sem correção atmosférica. **Revista Brasileira de Geomática**, v. 5, p. 524-542, 2017.

URBAN, M. et al. Surface Moisture and Vegetation Cover Analysis for Drought Monitoring in the Southern Kruger National Park Using Sentinel-1, Sentinel-2, and Landsat-8. **Remote Sensing**, v. 10, n. 9, p. 1482, 2018.

USGS (2016). **Landsat 8 (L8) Data Users Handbook**, 2016, LSDS-1574, version 2.0. Sioux Falls, USA: USGS EROS. Disponível em <<https://landsat.usgs.gov/sites/default/files/documents/Landsat8DataUsersHandbook.pdf>> Acesso em: 08 out. 2018.

VERMOTE, E. et al. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46-56, 2016.

WANG, J. et al. Mapping Spartina alterniflora Biomass Using LiDAR and Hyperspectral Data. **Remote Sensing**, v. 9, n. 6, p. 589, 2017.

WANG, D. et al. Evaluating the Performance of Sentinel-2, Landsat 8 and Pléiades-1 in Mapping Mangrove Extent and Species. **Remote Sensing**, v. 10, n. 9, p. 1468, 2018.

WEI, J. et al. An assessment of Landsat-8 atmospheric correction schemes and remote sensing reflectance products in coral reefs and coastal turbid waters. **Remote Sensing of Environment**, v. 215, p. 18-32, 2018.

WELCH, R.; EHLERS, M. Merging multiresolution SPOT HRV and Landsat TM data. **Photogrammetric Engineering & Remote Sensing**, v. 53, n. 3, p. 301-303, 1987.

WESSEL, M.; BRANDMEIER, M.; TIEDE, D. Evaluation of Different Machine Learning Algorithms for Scalable Classification of Tree Types and Tree Species Based on Sentinel-2 Data. **Remote Sensing**, v. 10, n. 9, p. 1419, 2018.

WILSON, N. R.; NORMAN, L. M. Analysis of vegetation recovery surrounding a restored wetland using the normalized difference infrared index (NDII) and normalized difference vegetation index (NDVI). **International Journal of Remote Sensing**, v. 39, n. 10, p. 3243-3274, 2018.

WITHARANA, C.; CIVCO, D. L.; MEYER, T. H. Evaluation of pansharpening algorithms in support of earth observation based rapid-mapping workflows. **Applied Geography**, v. 37, p. 63-87, 2013.

YANG, X. et al. Mapping of urban surface water bodies from Sentinel-2 MSI imagery at 10 m resolution via NDWI-based image sharpening. **Remote Sensing**, v. 9, n. 6, p. 596, 2017.

ZHANG, H. K. et al. Characterization of Sentinel-2A and Landsat-8 top of atmosphere, surface, and nadir BRDF adjusted reflectance and NDVI differences. **Remote Sensing of Environment**, v. 215, p. 482-494, 2018.

ZHU, Z.; WOODCOCK, C.E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, v. 144, p. 152-171, 2014.