

UNIVERSIDADE PRESBITERIANA MACKENZIE

ESCOLA DE ENGENHARIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS E APLICAÇÕES

GEOESPACIAIS

LADY VICTORIA ANGULO VALENCIA

**COMPORTAMENTO ESPECTRAL DAS CULTURAS DE
MILHO, ARROZ E SOJA, USANDO IMAGENS DOS
SATÉLITES SENTINEL-2, CBERS-4 E LANDSAT-8**

São Paulo

2020

LADY VICTORIA ANGULO VALENCIA

**COMPORTAMENTO ESPECTRAL DAS CULTURAS DE MILHO,
ARROZ E SOJA, USANDO IMAGENS DOS SATÉLITES SENTINEL-2,
CBERS-4 E LANDSAT-8**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências e Aplicações Geoespaciais da Universidade Presbiteriana Mackenzie, como requisito parcial à obtenção do título de Mestre em Ciências Geoespaciais.

**ORIENTADOR: PROF. DR. SERGIO VICENTE
DENSER PAMBOUKIAN**

São Paulo

2020

*À minha mãe Célica, que todos os dias me
acompanha com a benção de seu amor irrestrito
e força inspiradora sempre acreditando em mim.*

AGRADECIMENTOS

Ao meu orientador Prof. Dr. Sergio Vicente Denser Pamboukian, pela amizade, apoio e forma amigável de orientar, sempre me permitindo fazer meu próprio caminho com seus ensinamentos.

Aos professores do programa de pós-graduação em Ciências e Aplicações Geoespaciais, da Universidade Presbiteriana de Mackenzie, pelo exemplo, determinação, inspiração, suporte nos ensinamentos das matérias de mestrado e confiança a mim depositada.

Aos professores membros da banca, por ser parte da banca examinadora e pela avaliação deste trabalho.

A toda a ajuda, companheirismo, ideias e opiniões que somaram muito a minha pesquisa dos colegas e amigos do CRAAM (Centro de Rádio Astronomia e Astrofísica Mackenzie), Lucíola Russi, Yuri Netto, Ray Hidalgo, Cláudio Machado, Luís Medeiros, Eduardo Perez, Ernesto Zurbriggen, Fernando Lopez, Fernando Valle, Fabian Menezes, Jordi Tuneu, Francisco Fuller e Douglas Felix.

As minhas amigas Ana Carolina Valerio e Deysi Verónica Espinosa pela paciência, ajuda e todas as boas experiências que fizeram do Brasil um lar para mim. Um agradecimento especial para Jeferson por todo seu apoio e carinho incondicional.

E finalmente eu agradeço muito aos meus pais Cécilia de Lourdes Valencia Sória e Olmes Rodrigo Angulo Garaicoa, que revestiram minha existência com os ensinamentos necessários para poder me manter no caminho sem importar as dificuldades encontradas. Aos meus irmãos Alexandra, Cristian e Jessica por todo o carinho e apoio que me inspiraram durante todo este processo de pesquisa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e pelo programa de Bolsas do Programa de Alianzas para a Educação e Capacitação –PAEC OEA-GCUB.

“Um pouco de ciência nos afasta de Deus. Muito, nos aproxima” ...Louis Pasteur.

RESUMO

O monitoramento do estado das culturas a nível regional é fundamental na procura de uma gestão agrícola sustentável. Uma das metodologias aplicadas com esse objetivo é a Agricultura de Precisão que, em conjunto com as ferramentas e equipamentos tecnológicos (Sistemas Globais de Navegação por satélite, Sensoriamento Remoto, Sistemas de Informações Geográficas e Veículos Aéreos Não Tripulados), formam um sistema agrícola integrado baseado nas informações da produção e evolução dos cultivos. Desde a década de 1970, marcada pelo lançamento da plataforma do satélite Landsat-1, o estudo do estado das culturas foi definido pelo relacionamento entre a interação da radiação eletromagnética no solo e na vegetação e sua resposta nas diferentes faixas de comprimento de onda (medidas de refletância espectral) relacionadas com a composição química foliar dos cultivos. Nesta pesquisa, foram analisadas as assinaturas espectrais (valores de refletância espectral relacionados com o comprimento de onda) e os principais índices de vegetação (NDVI, GNDVI, SAVI e EVI) para as culturas de Milho, Arroz e Soja em uma área de cultivo de 320 hectares, localizada no município de Tremembé (SP) para o período de novembro a março dos ciclos 2017/18 e 2018/19, através do uso de imagens multiespectrais dos satélites Sentinel-2, CBERS-4 e Landsat-8. Os resultados mostram maiores respostas espectrais (especialmente na região *RedEdge* e *Near-InfraRed*) na cultura da Soja, seguida do Arroz e do Milho ao redor dos 60 a 90 dias de semeadura e uma diminuição com a aproximação da colheita, que é dada pela perda de nutrientes e clorose das folhas. Além disso, se observa uma alta correlação (0,972) no índice de vegetação aprimorado (EVI) entre as imagens dos satélites CBERS-4 e Landsat-8. O cálculo dos índices de vegetação mostra também que o ciclo da safra 2018/19 teve resultados mais homogêneos e maior porcentagem de áreas com valores elevados em comparação com o primeiro ciclo. Ademais as imagens estudadas mostram que existe uma variação da refletância devido a diversos fatores como idade da vegetação, época de cultivo, regime de chuvas, temperatura, entre outros. Apesar disso, os gráficos de refletância mostram um grande potencial para monitorar o conteúdo de nutrientes e água nos cultivos, assim como também os índices de vegetação indicam uma boa vantagem na administração de insumos e visitas de campo.

Palavras chave: Sentinel-2, CBERS-4, Landsat-8, Sensoriamento remoto, Agricultura de precisão, Assinaturas Espectrais, Refletância Espectral, Índices de Vegetação.

ABSTRACT

Monitoring crop status at regional level is critical in the pursuit of sustainable Agricultural Management. One of the methodologies applied for this purpose is Precision Farming which together with the technological tools and equipment (Global Navigation Satellite Systems, Remote Sensing, Geographic Information Systems and Unmanned Aerial Vehicles) form an integrated agricultural system based on information of crop production and evolution. Since the 1970s, marked by the launch of the Landsat-1 satellite platform, the study of crop status has been defined by the relationship between the interaction of electromagnetic radiation in soil and vegetation and its response over different wavelength ranges (measured by reflectance) related to the leaf chemical composition of the crops. In this research, we analyzed the spectral signatures (wavelength-related spectral reflectance values) and the main vegetation indices (NDVI, GNDVI, SAVI, EVI) for the Corn, Rice and Soybean crops in a cultivated area of 320 hectares, located in the municipality of Tremembé (SP) for the period from November to March of the 2017/2018 and 2018/2019 cycles, through the use of multispectral images of the Sentinel-2, CBERS-4 and Landsat-8 satellites. The results show higher spectral responses (especially in the RedEdge and Near-InfraRed region) in the soybean crop, followed by rice and corn around 60 to 90 days of sowing and a decrease with the crop approach, which is due to loss nutrients and leaf chlorosis. In addition, a high correlation (0,972) in the enhanced vegetation index (EVI) between CBERS-4 and Landsat-8 satellite images is observed. The vegetation index calculation also shows that the 2018/2019 crop cycle had more homogeneous results and a higher percentage of areas with high values compared to the first cycle. In addition, the studied images show that there is a variation of reflectance due to several factors such as vegetation age, growing season, rainfall, temperature, among others. Nevertheless, reflectance graphs show great potential for monitoring nutrient and water content in crops, as well as vegetation indices indicate a good advantage in input management and field visits.

Key words: Sentinel-2, CBERS-4, Landsat-8, Remote Sensing, Precision Agriculture, Spectral Signatures, Spectral Reflectance, Vegetation Indices.

LISTA DE ILUSTRAÇÕES

Figura 1 - Absorção específica dos principais gases da atmosfera no espectro da radiação solar, no topo da atmosfera (cinza escuro) e ao nível do mar (cinza claro).	26
Figura 2 - Espectro eletromagnético.....	27
Figura 3 - Região visível do espectro (0.4 - 0.76 μm).....	27
Figura 4 - Descrição da trajetória da radiação eletromagnética e seus componentes radiométricos (da fonte ao sensor).....	28
Figura 5 - Porção de uma ortofotocarta de São Paulo do ano 2007 (a) resolução espacial de 0,6 m (b) resolução espacial de 5 m (c) resolução espacial de 10 m.	33
Figura 6 - Imagens de quantização menor (2 bits) e quantização maior (8 bits).....	34
Figura 7 - Cena de uma imagem digital (a), grupo de pixels (b) e valores digitais (c).....	42
Figura 8 - Principais técnicas de processamento de imagens.	44
Figura 9 - Trajetória da radiação emitida como irradiância solar e recebida como radiância no sensor.	46
Figura 10 - Produção de grãos em todo o Brasil entre 1975 e 2017.	52
Figura 11 - Produção de milho por estado na safra 2013/2014 em milhões de toneladas.	54
Figura 12 - Mapa de produtividade em um talhão.	57
Figura 13 - Comparação da assinatura espectral obtida com um espectrômetro (GER IRIS) (linha curva) e com o satélite Landsat TM (linha reta).....	59
Figura 14 - Assinaturas espectrais de uma plantação de milho considerando-se a aplicação de nitrogênio.	60
Figura 15 - Localização da área de estudo (demarcada em laranja) na cidade de Tremembé.	66
Figura 16 - Distribuição das parcelas (milho - polígonos em verde, arroz - polígonos em azul e soja - polígonos em amarelo) na área de estudo (a imagem de fundo é uma combinação de bandas RGB do Sentinel-2 para o mês de novembro 2017).	68
Figura 17 - Comparação da resposta espectral dos sensores OLI (linhas pontilhadas) e MSI.	71
Figura 18 - Comparação da resposta espectral dos sensores OLI (linhas pontilhadas) e MUX.....	72
Figura 19 - Processo seguido para a obtenção dos valores de refletância na BOA para as imagens dos satélites Sentinel-2, CBERS-4 e Landsat-8.	75
Figura 20 - Resultados do comportamento espectral (usando as imagens do SENTINEL-2) dos ciclos 2017/18 (esquerda) e 2018/19 (direita) para as zonas de cultivo 10b-arroz (a e b), 10d-arroz (c e d), e 6-milho (e e f).	79
Figura 21 - Comportamento espectral das culturas de milho, arroz e soja ao redor de 60 dias de semeadura do ciclo 2017/18 (imagens SENTINEL-2).	80
Figura 22 - Comportamento espectral da parcela 2 do cultivo de Soja para o ciclo 2017/2018.	81
Figura 23 - NDVI (S2, L8 e C4) calculado para o ciclo 2017/18.	83

Figura 24 - NDVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.	84
Figura 25 - GNDVI (S2, L8 e C4) calculado para o ciclo de semeadura 2017/18.	86
Figura 26 - GNDVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.	87
Figura 27 - SAVI (S2, L8 e C4) calculado para o ciclo de semeadura 2017/18.	89
Figura 28 - SAVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.	90
Figura 29 - EVI (S2, L8 e C4) calculado para o ciclo de semeadura 2017/18.	93
Figura 30 - EVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.	94
Figura 31 - Correlação (R^2) do índice EVI entre os dias 15 e 16 d novembro de 2017 para os satélites L8 e C4 respectivamente (linha de tendência desenhada em vermelho).	97
Figura A1 - Correlação do índice NDVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	109
Figura A2 - Correlação do índice NDVI para os meses de dezembro, janeiro e março (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	110
Figura A3 - Correlação do índice GNDVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	111
Figura A4 - Correlação do índice GNDVI para os meses de dezembro, janeiro e março (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	112
Figura A5 - Correlação do índice SAVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	113
Figura A6 - Correlação do índice SAVI para os meses de dezembro, janeiro e março (ciclos 2017/2018 e 2018/2019) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	114
Figura A7 - Correlação do índice EVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	115
Figura A8 - Correlação do índice EVI para os meses de dezembro, janeiro e março (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.	116

LISTA DE QUADROS

Quadro 1 - Componentes radiométricos da trajetória REM.	28
Quadro 2 - Tipos de sistemas imageadores considerando a fonte de REM.	30
Quadro 3 - Resolução espacial e a escala de visualização da imagem de alguns satélites.	32
Quadro 4 - Características das câmeras imageadoras CBERS-4.	38
Quadro 5 - Métodos de pré-processamento de imagens.	47
Quadro 6 - Resumo das funcionalidades de alguns GIS.	51
Quadro 7 - Índices de vegetação comumente usados na AP.	61
Quadro 8 - Resumo das características da zona de estudo.	67
Quadro 9 - Resumo da rotação das culturas na área de estudo (a linha pontilhada separa os ciclos de verão a serem comparados).	69
Quadro 10 - Bandas espectrais equivalentes para os sensores OLI, MSI e MUX.	70
Quadro 11- Imagens Sentinel-2, CBERS 4 e Landsat-8 a serem usadas na pesquisa.	73
Quadro 12 - Datas das imagens processadas na pesquisa (datas em marrom não foram usadas para a correlação).	95
Quadro 13 - Resumo do R ² para os diferentes índices calculados.	96

LISTA DE TABELAS

Tabela 1 - Intervalos espectrais comumente usados pelos sensores remotos.	27
Tabela 2 - Tempo de revisita dos principais satélites.	35
Tabela 3 - Resolução espacial e espectral das plataformas de satélite comumente usadas no sensoramento remoto.	36

LISTA DE ABREVIATURAS E SIGLAS

AP	<i>Agricultura de Precisão</i>
BOA	<i>Bottom of atmosphere</i>
CONAB	<i>Companhia Nacional de Abastecimento</i>
CBERS	<i>China-Brazil Earth Resources Satellite</i>
EMBRAPA	<i>Empresa Brasileira de Pesquisa Agropecuária Ministério da Agricultura Pecuária e Abastecimento</i>
ERTS -1	<i>Earth Resources Technology Satellite</i>
ESRI	<i>Environmental Systems Research Institute</i>
ESA	<i>European Spatial Agency</i>
EVI	<i>Enhanced Vegetation Index</i>
INPE	<i>Instituto Nacional de Pesquisas Espaciais</i>
IRS	<i>Imageador Multiespectral e Termal</i>
GEOSS	<i>Global Earth Observation System of Systems</i>
GIS	<i>Geographic Information Systems</i>
GNSS	<i>Global Navigation Satellite Systems</i>
GNDVI	<i>Green Normalized Differenced Vegetation Index</i>
GM	<i>Green Model Index</i>
GMES	<i>Global Monitoring for Environment and Security</i>
GRVI	<i>Green-Red Vegetation Index</i>
LAI	<i>Leaf Area Index</i>
LANDSAT	<i>Land Satellites observation program</i>
LCC	<i>Leaf Chlorophyll Content</i>
LEDAPS	<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>
MAPA	<i>Ministério da Agricultura, Pecuária e Abastecimento</i>
MUX	<i>Câmera Multiespectral Regular</i>
N	<i>Nitrogênio</i>
ND	<i>Nível digital</i>
NDVI	<i>Normalized Differenced Vegetation Index</i>
NIR	<i>Near infra-red</i>

OLI	<i>Operational Land Imager</i>
PAN	<i>Câmera Pancromática e Multiespectral</i>
REM	<i>Radiação Eletromagnética</i>
Rem	<i>redEdge model</i>
REP	<i>redEdge point</i>
REChI	<i>redEdge chlorophyll index</i>
SAVI	<i>Soil-Adjusted Vegetation Index</i>
SENTINEL	<i>Earth observation mission from the Copernicus Programme</i>
SR	<i>Sensoriamento Remoto</i>
S2REP	<i>redEdge Point of Sentinel 2</i>
SWIR	<i>Short wave Infra-red</i>
TIR	<i>Thermal infra-red</i>
UTM	<i>Universal Transversal Mercator</i>
USGS	<i>United States Geological Survey</i>
VNIR	<i>Visible and near-infrared</i>
WDRVI	<i>Wide Dynamic Range Vegetation Index</i>
WFI	<i>Câmera de Campo Largo</i>
WPM	<i>Câmera Multiespectral e Pancromática de Ampla Varredura</i>

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	OBJETIVOS	18
1.1.1.	OBJETIVO GERAL.....	18
1.1.2.	OBJETIVOS ESPECÍFICOS.....	18
1.2	JUSTIFICATIVA.....	19
1.3	ESTUDOS E APLICAÇÕES DA AGRICULTURA DE PRECISÃO	20
2	EMBASAMENTO TEÓRICO.....	25
2.1	RADIAÇÃO ELETROMAGNÉTICA (REM).....	25
2.1.1.	ESPECTRO ELETROMAGNÉTICO	26
2.1.2.	RADIÂNCIA E REFLETÂNCIA.....	28
2.2	SENSORIAMENTO REMOTO	29
2.3	PLATAFORMAS ESPACIAIS.....	31
2.3.1	RESOLUÇÕES DAS IMAGENS.....	32
2.3.1.1	<i>Resolução Espacial.....</i>	32
2.3.1.2	<i>Resolução Radiométrica</i>	33
2.3.1.3	<i>Resolução Temporal.....</i>	34
2.3.1.4	<i>Resolução Espectral.....</i>	35
2.4	IMAGENS DIGITAIS	41
2.4.1	PROCESSAMENTO DE IMAGENS DE SATÉLITE	43
2.4.1.1	<i>Pré-processamento de Imagens de satélite.....</i>	44
2.4.1.1.1	Correção radiométrica	45
2.4.1.1.2	Correção Atmosférica.....	45
2.4.1.1.3	Correção Geométrica.....	47
2.5	SISTEMAS DE INFORMAÇÃO GEOGRÁFICA	48
2.5.1	PRINCIPAIS SOFTWARE GIS	49
2.6	AGRICULTURA NO BRASIL.....	51
2.6.1	SOJA.....	52
2.6.2	MILHO.....	53

2.6.3	ARROZ.....	54
2.7	AGRICULTURA DE PRECISÃO.....	55
2.7.1	A AGRICULTURA DE PRECISÃO NO BRASIL.....	56
2.8	ASSINATURAS ESPECTRAIS DA VEGETAÇÃO.....	58
2.9	ÍNDICES DE VEGETAÇÃO.....	60
2.9.1	ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADA (NDVI).....	62
2.9.2	ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA VERDE (GNDVI).....	63
2.9.3	ÍNDICE DE VEGETAÇÃO AJUSTADA PELO SOLO (SAVI).....	64
2.9.4	ÍNDICE DE VEGETAÇÃO APRIMORADO (EVI).....	64
3	MATERIAIS E MÉTODOS.....	66
3.1	DESCRIÇÃO DA AREA DE ESTUDO.....	66
3.2	INSTRUMENTAÇÃO.....	70
3.3	OBTENÇÃO E PROCESSAMENTO DE DADOS.....	72
4	RESULTADOS E DISCUSSÃO.....	77
4.1	ANÁLISE DAS ASSINATURAS ESPECTRAIS.....	77
4.2	ANÁLISE DOS ÍNDICES DE VEGETAÇÃO ESPECTRAL.....	81
4.2.1	ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADA (NDVI).....	81
4.2.2	ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA VERDE (GNDVI).....	85
4.2.3	ÍNDICE DE VEGETAÇÃO AJUSTADA PELO SOLO (SAVI).....	88
5	CONCLUSÃO.....	98
5.1	TRABALHOS FUTUTOS.....	100
	REFERÊNCIAS.....	101
	APÊNDICE A – Correlação das imagens SENTINEL-2, CBERS-4 e LANDSAT-8.....	109

1 INTRODUÇÃO

Desde o lançamento do primeiro satélite para monitoramento da superfície terrestre em 1972 (ERTS1- *Earth Resources Technology Satellite*), a identificação das mudanças na superfície do solo através do uso das imagens de satélite tem crescido, estabelecendo uma linha base de informações úteis na criação de políticas sustentáveis para um crescimento demográfico com a planificação e gerenciamento de recursos apropriados. Uma grande área de estudo e aplicação das informações coletadas através dos satélites de monitoramento terrestre encontra-se no setor agrícola, o qual baseado no conhecimento e aplicação de novas técnicas de sensoriamento remoto (usando as imagens multiespectrais dos satélites) consegue obter dados úteis para avaliar o *status* das plantações com rapidez e precisão, sem a necessidade de amostragens destrutivas e medições analíticas demoradas (CORTI, 2017).

Segundo Schlemmer *et al.* (2005) o sensoriamento remoto está evoluindo como uma ferramenta valiosa, com o potencial de avaliar uma ampla variedade de propriedades fisiológicas dos cultivos em uma grande área em um curto período de tempo.

Atualmente existe um incremento na disponibilização de fontes de dados de informação geográfica digital, assim como de plataformas que disponibilizam as imagens de satélite ao público, com melhorias nas resoluções espaciais (tamanho do pixel), espectrais (faixas de cobertura do espectro eletromagnético) e radiométricas (número de bits), tornando-se úteis para o acompanhamento das mudanças dos cultivos e apresentando dados que podem ser aplicados para melhorar os processos de produção das safras e reduzir a utilização de insumos agrícolas (MARTÍNEZ, 2017).

Com o objetivo de aumentar as possibilidades de monitoramento da Terra as agências espaciais criaram iniciativas como o Sistema Global de Sistemas de Observação da Terra (GEOSS - *Global Earth Observation System of Systems*) que, em conjunto com as missões dos satélites *Copernicus Sentinel-2 (S2)*, *Landsat*, *SPOT*, *CBERS*, *MODIS*, entre outros, formam o grupo de plataformas criadas para a obtenção consecutiva de observações sobre a superfície terrestre (PADRÓ, 2018).

As aplicações para o sensoriamento remoto na agricultura tem evoluído constantemente e, juntando-se ao desenvolvimento dos sistemas globais de posicionamento por satélite (GNSS - *Global Navigation Satellite System*), sistemas de informação geográfica (GIS - *Geographic Information System*) e equipamentos tecnológicos (drones, sensores ópticos portáteis, plataformas não tripuladas, entre outros), formam na atualidade um sistema integrado agrícola baseado nas informações da produção e evolução dos cultivos conhecido como *Agricultura de Precisão* (LIAGHAT; BALASUNDRAM, 2010). Mulla (2013) manifesta que, embora seja uma prática que começou ao redor de 1990, a agricultura de precisão tornou-se uma das dez melhores revoluções na agricultura, envolvendo o levantamento, análise e gerenciamento da informação coletada. O estabelecimento de uma agricultura sustentável é um dos objetivos da agricultura de precisão, procurando melhorar a utilização dos insumos agrícolas (fertilizantes, herbicidas, sementes, combustível) incrementando a produtividade das culturas e reduzindo os impactos adversos no meio ambiente.

A resposta da interação da Radiação Eletromagnética (REM) no solo e na vegetação é a base das aplicações do sensoriamento remoto na agricultura, que usa as informações obtidas através de diferentes plataformas (satélites, aeronaves, tratores e sensores portáteis) para coletar as medidas da radiação refletida ou emitida a partir dos campos agrícolas (BAUER e CIPRA, 1973). Sendo assim uma das magnitudes físicas mais importantes a ser obtida depois do tratamento óptico da imagem de satélite (correções atmosférica, radiométrica e geométrica) é a refletância espectral da superfície. A mesma pode ser definida como a proporção de fluxo de radiância refletido sobre o fluxo de radiância incidente em um comprimento de onda específico (NICODEMUS *et al.* 1977). O valor da refletância superficial é uma resposta essencial sobre a caracterização da cobertura do solo.

Neste trabalho, procurou-se a obtenção das assinaturas espectrais (valores de refletância espectral) em uma plantação localizada na cidade de Tremembé (SP), para as culturas de Milho, Soja e Arroz dos ciclos de semeadura de verão (meses de novembro a março) 2017/18 e 2018/19, com a finalidade de analisar o comportamento espectral nas diferentes fases e tipos de culturas. Além disso, buscou-se comparar os índices de vegetação (NDVI - *Normalized Difference Vegetation Index*, GNVI - *Green Normalized Difference Vegetation Index*, EVI - *Enhanced Vegetation Index* e SAVI -

Soil-adjusted Vegetation Index) utilizando as imagens multiespectrais dos satélites SENTINEL-2, CBERS-4 e LANDSAT-8, estabelecendo diferenças e vantagens na aplicação para estudos de agricultura de precisão.

1.1 OBJETIVOS

1.1.1. OBJETIVO GERAL

Obter as assinaturas espectrais e os principais índices de vegetação (NDVI, GNDVI, EVI e SAVI) para as culturas de Milho, Arroz e Soja usando imagens multiespectrais dos satélites SENTINEL-2, CBERS-4 e LANDSAT-8 para os ciclos de verão 2017/18 e 2018/19 período de novembro a março, na cidade de Tremembé, estado de São Paulo, Brasil, e entender como estas informações podem ser utilizadas para melhorar o gerenciamento agrícola.

1.1.2. OBJETIVOS ESPECÍFICOS

São objetivos específicos deste trabalho:

- descrever os principais satélites de observação do ambiente terrestre, seus sensores e as características das imagens disponibilizadas (resolução, bandas etc.), suas aplicações e usos mais frequentes;
- analisar as diferenças entre as assinaturas espectrais das culturas obtidas em diferentes épocas e fases das culturas para as imagens SENTINEL-2;
- calcular os principais índices de vegetação (NDVI, GNDVI, EVI e SAVI) para as diversas culturas através de imagens dos satélites SENTINEL-2, CBERS-4 e LANDSAT-8;
- correlacionar os índices de vegetação obtidos das imagens SENTINEL-2, CBERS-4 e LANDSAT-8 dos ciclos 2017/18 e 2018/19;

- estabelecer as principais diferenças e vantagens do uso das imagens dos satélites SENTINEL-2, CBERS-4 e LANDSAT-8 nos estudos de agricultura de precisão.

1.2 JUSTIFICATIVA

A agricultura de precisão procura o melhoramento das práticas agrícolas através da gestão dos recursos e sua utilização no lugar e tempo certos. Enquanto na agricultura convencional os campos recebem quantidades iguais de sementes, fertilizantes e irrigação, usando as técnicas propostas pela agricultura de precisão esses campos podem-se dividir como zonas de planejamento considerando-se a gestão histórica das plantações, tipos do solo e localização das parcelas (MULLA, 2013). Além de melhorar a gestão dos cultivos, os agricultores percebem melhoras na produtividade e lucratividade das plantações, melhor correspondência de aplicações de fertilizantes e diminuição dos impactos ao ambiente.

Liaghat e Balasundram (2010) manifestam que a importância da agricultura de precisão evoluiu no século 20 devido à pressão econômica para a automatização dos campos agrícolas extensos estabelecendo técnicas e práticas para o melhoramento da gestão e produção agrícola. Segundo Tanriverdi (2006), não é possível monitorar as culturas em intervalos frequentes com os métodos agrícolas convencionais, difundindo o uso das técnicas da agricultura de precisão (GNSS - *Global Navigation Satellite Systems*, GIS - *Geographic Information Systems*) e sensoriamento remoto) como fundamentais para a análise de uma grande quantidade de dados com sensibilidade e rapidez.

O uso das imagens de satélite para o mapeamento da produtividade e monitoramento das mudanças na cobertura e uso do solo é conhecido como uma metodologia de levantamento de informação não destrutiva. Esta metodologia, além de permitir a obtenção de informação de grandes extensões (incluindo lugares inacessíveis), é uma ferramenta fundamental para o estabelecimento dos aspectos que produzem essas mudanças e sua intervenção no meio ambiente. No aspecto agrícola a análise de imagens multiespectrais de satélite é dada usando os valores de refletância espectral da superfície (obtido usando o ND - *Nível Digital da imagem*) a fim de obter o estado fisiológico das plantações, condições hídricas, detectar doenças

potenciais e áreas dentro dos campos onde os rendimentos das colheitas podem ser melhorados ou onde ajustes nos insumos são necessários (LIAGHAT e BALASUNDRAM, 2010; TANRIVERDI, 2006).

Assim como é manifestado em Corti (2017), podem-se desenvolver diversas técnicas de sensoriamento remoto para o levantamento de dados de refletância das culturas, acrescentando a importância de realizar estudos nos que a resposta da interação da REM (na forma de assinatura espectral) nos cultivos seja analisada, considerando fontes de dados abertas e facilmente acessíveis. Entre as plataformas de satélite que fornecem dados livres aos usuários e apresentam boas resoluções espaciais encontram-se os satélites SENTINEL-2, CBERS-4, e LANDSAT-8. Existem diversas pesquisas que relacionam os dados de plataformas de satélite como LANDSAT-8 e SENTINEL-2 na área de agricultura de precisão (PADRÓ, 2018; ZHANG, *et al.* 2018; COSTA, 2017), mas o conhecimento da usabilidade dos dados das imagens multiespectrais do satélite CBERS-4, assim como a obtenção dos valores de refletância de superfície em estudos de agricultura de precisão é ainda bastante novo.

1.3 ESTUDOS E APLICAÇÕES DA AGRICULTURA DE PRECISÃO

A constante evolução no desenvolvimento de novas tecnologias de sensoriamento remoto tem criado o potencial de transformar as formas pelas quais os produtores gerenciam suas terras e programam suas colheitas, procurando como objetivo principal resolver os problemas da desuniformidade nas lavouras (PINTER *et al.* 2003). O uso das imagens de satélite tem sido considerado como uma das fontes principais para monitoramento da vegetação, apresentando diversas vantagens em comparação com as campanhas extensas de campo para o mapeamento das culturas. As imagens de satélite de livre acesso que apresentam melhor resolução espacial na atualidade são as classificadas como imagens de resolução média (tamanho do pixel entre 10 a 30 m), que são as correspondentes aos satélites SENTINEL-2, CBERS-4, e LANDSAT-8 (KORHONEN, 2017). Um dos grandes benefícios do uso de imagens de satélite encontra-se na obtenção de informações de grandes extensões de terreno em pouco tempo, coletando dados de diferentes

parâmetros do solo e da vegetação, os mesmos que com uma correta interpretação permitem entender o estado do desenvolvimento das culturas e administrar o uso adequado dos insumos em cada porção de terreno capturado. Por esse motivo, existem várias pesquisas que procuram entender o comportamento da resposta espectral dos cultivos à REM medida no sensor do satélite e traduzida em informação binária nos dados da imagem (usados na obtenção das assinaturas espectrais).

Como mencionado em Bauer (1975 apud PINTER *et al.* 2003) e em Corti (2017) existe uma acentuada diferença nas propriedades de reflexão da vegetação entre os comprimentos de onda visíveis (refletância e transmitância muito baixas entre os 400 e 700 nm) e infravermelho próximo (NIR – *Near InfraRed*) (refletância e transmitância geralmente altas entre 700 e 1300 nm) o que sustenta a maioria das pesquisas para monitorar a resposta espectral da vegetação nessas faixas do espectro.

As variações do comportamento da refletância entre as porções do espectro visível e NIR são amplamente utilizadas para o desenvolvimento de índices espectrais que são baseados em razões de valores de refletância nessas faixas. Os índices de vegetação servem de base para a obtenção de diferentes propriedades das culturas, assim como: biomassa, conteúdo de clorofila, Nitrogênio (N) e outras.

O estudo de Schlemmer *et al.* (2005) avalia os efeitos da refletância espectral em talhões de milho expostos a condições distintas de água e nitrogênio, concluindo-se que os diferentes níveis de água conseguem alterar a estrutura celular das folhas e, portanto, mudam a absorção, transmissão e reflexão da energia na porção infravermelha próxima do espectro. Nos resultados obtidos por Schlemmer *et al.* (2005) os talhões com déficit hídrico apresentaram maior refletância na região espectral dos 740 a 800 nm, do que aqueles que tinham quantidades de água adequadas. Enquanto que, as influências dos tratamentos de N podem-se observar nos comprimentos de onda de 525 a 680 nm, nos quais a refletividade da folha aumenta com o aumento do estresse de N, assim como no aumento do estresse hídrico. Outro fato interessante apresentado no estudo de Schlemmer *et al.* (2005) é a manifestação de que a forma das curvas de refletância pode ser mais uma função de N do que da água. Nos dados estudados, os resultados mostram que a declinação de 600 a 680 nm parece variar apenas com os tratamentos de N, assim como a variação da posição da borda vermelha (ponto de inflexão na região de transição de

vermelho para infravermelho próximo - *redEdge*). Nos níveis de N mais baixos, a borda vermelha ocorreu perto de 695 nm (sem variações produzidas pela quantidade de água) e nas áreas de N mais elevado, a borda vermelha ocorreu perto de 730 nm. Uma explicação para essa mudança nos valores da borda vermelha é dada pelo fato de que a clorofila absorve a energia fortemente em torno da região de 670 nm, e quando o conteúdo de clorofila aumenta, a região de absorção começa a se espalhar, movendo a borda vermelha em direção a 730, entendendo que a monitoração da localização desse ponto de inflexão (*redEdge*) pode fornecer uma medida do estresse da vegetação, que resulta na degradação da clorofila.

Enquanto à análise do conteúdo de clorofila Frampton *et al.* (2013) mostraram o potencial do sensor SENTINEL-2 MSI na estimativa do conteúdo de clorofila do dossel, o índice de área foliar (LAI - *Leaf Area Index*) e a concentração foliar de clorofila (LCC - *Leaf Chlorophyll Content*). O conhecimento da quantidade de clorofila do dossel e da concentração foliar de clorofila (LCC) pode indicar a saúde da planta e a produtividade bruta potencial, enquanto o índice de área foliar (LAI) pode fornecer uma visão da função e estrutura do dossel. O uso dos métodos baseados nos índices de vegetação para a determinação das variáveis biofísicas da vegetação tem o benefício de serem computacionalmente simples e mais universalmente aplicáveis. O trabalho de Frampton *et al.* (2013) apresenta um novo método para estimar variáveis biofísicas da vegetação usando dados do sensor SENTINEL-2 MSI, o índice proposto é o S2REP (posição da borda vermelha do SENTINEL-2), que mostra uma versão da estimativa do REP (*redEdge point*) para SENTINEL-2 usando interpolação linear. O S2REP obteve uma forte correlação com a concentração de clorofila foliar com R^2 de 0,91 em comparação com dados das campanhas no campo. O trabalho mostra que o índice S2REP é sensível à variação no conteúdo da clorofila nas folhas, apresentando valores de REP de 711–728 nm para valores de LCC de 0,16 – 0,41 g /m² respectivamente, o que vai de acordo com as afirmações de Boochs *et al.* (1990) e Schlemmer *et al.* (2005).

No caso do comportamento diferenciado da assinatura espectral das plantações, o trabalho de Martinez (2017) avalia a relação do estado nutricional com a assinatura espectral de algumas culturas (milho, arroz, soja, cana-de-açúcar, óleo de palma, seringueira, cajueiro, gramíneas) medidas com espectrorradiômetro e as assinaturas obtidas usando imagens do satélite SENTINEL-2. Martinez (2017),

apresenta que as culturas com menores quantidades de N tiveram menores valores na primeira derivada da curva de refletância (o que significa uma menor taxa de câmbio na assinatura) e um menor valor de REP (próximo a 700 nm), enquanto aquelas culturas com maiores quantidades de N tiveram valores mais elevados da primeira derivada e o REP foi mais próximo de 725 nm e apresentou um pico mais agudo. Na mesma pesquisa os índices de vegetação espectral, apresentaram as melhores correlações com a quantidade de clorofila medida no espectrorradiômetro naqueles que envolviam parte do espectro de borda vermelha em seu cálculo, como GM (*green model index*), Rem (*redEdge model*), REChI (*redEdge chlorophyll index*). Esses resultados mostram um bom potencial das imagens do SENTINEL-2 para avaliar o estado nutricional das culturas, em relação ao N, e na detecção da variabilidade espacial e temporal.

Quanto ao estudo dos índices de vegetação nas aplicações de agricultura de precisão, Escolà *et al.* (2017) correlaciona 4 índices de vegetação (NDVI, WDRVI, GRVI e GNDVI) com dados na produção e rendimento da colheita de um campo de cevada. Os melhores coeficientes de correlação foram obtidos com os índices de vegetação de base verde (GRVI e GNDVI), este estudo não consegue apresentar uma alta correlação usando os índices que medem o vigor das plantas com os dados de produtividade da colheita, mas mostra a utilidade do uso das imagens SENTINEL-2 para o agricultor entender e quantificar a variabilidade espacial do vigor e produtividade nas lavouras ao longo de toda a temporada, e como, uma vez identificadas as diferentes áreas de vigor, ações de fertilização e proteção de cultivos específicas do local podem ser consideradas no próximo ciclo. O estudo propôs também a aplicação dos índices que envolvem a faixa da borda do vermelho o *redEdge* assim como se mostra nas pesquisas de Frampton *et al.* (2013) e Schlemmer *et al.* (2005).

Alguns dos trabalhos que são mencionados nesta seção estudam a resposta espectral de diversas culturas à interação com a REM, utilizando diferentes meios de captura de informação, no caso de Schlemmer *et al.* (2005) e Corti (2017), a informação é obtida através de um espectrorradiômetro. Nos trabalhos de Frampton *et al.* (2013), Martinez (2017) e Escolà *et al.* (2017) se apresenta o uso das imagens do satélite SENTINEL-2 (sensor MSI) como métodos para estimar variáveis biofísicas da vegetação através dos cálculos de diferentes índices. Pesquisas como Boelter et



al. (2019), já tentam relacionar os resultados obtidos usando imagens de duas plataformas de satélite (CBERS-4 e LANDSAT-8) comparando os índices NDVI e SAVI de uma região agrícola, mostra maiores valores para o índice SAVI e melhores resultados na classificação feita usando o satélite CBERS-4.

Considerando-se alguns dos trabalhos resumidos na seção, e alguns outros analisados (BLACKBURN, 2007; ZHANG, 2018; WILSON, 2014; ORYCH, 2013), que mostram as diferentes respostas espectrais e a correlação de diversos índices para caracterizar a vegetação e a variabilidade das assinaturas a diferentes tratamentos experimentais, pode-se dizer que o trabalho apresentado nesta pesquisa propõe um análise diferenciado que procura estabelecer as principais vantagens e diferenças no uso das principais plataformas de satélite com resolução espacial média de livre acesso (SENTINEL-2, CBERS-4, e LANDSAT-8), correlacionando as respostas para cada uma das plataformas aos índices mais conhecidos na determinação do vigor da vegetação (NDVI, GNDVI, SAVI, EVI). Além de grande parte dos trabalhos aplicados à agricultura de precisão que estudam a aplicabilidade das imagens do satélite SENTINEL-2 e dos resultados apresentados no trabalho de Boelter et al. (2019), que correlaciona os índices obtidos usando imagens dos satélites CBERS-4 e LANDSAT-8, esta pesquisa correlaciona os resultados de 4 índices de vegetação amplamente usados para caracterização das culturas (NDVI, GNDVI, SAVI, EVI) obtidos usando as imagens dos satélites SENTINEL-2, CBERS-4, e LANDSAT-8, adicionando informações na quantidade de pesquisas aplicadas à agricultura de precisão usando imagens do satélite CBERS-4.



2 EMBASAMENTO TEÓRICO

2.1 RADIAÇÃO ELETROMAGNÉTICA (REM)

O conceito de radiação eletromagnética (REM) engloba um comportamento dual (onda e energia), isso quer dizer que a REM que se propaga pelo espaço vazio, é, ao mesmo tempo, uma forma de onda e de energia. Portanto, define-se o conceito de uma onda eletromagnética como a oscilação dos campos E (elétrico) e M (magnético), segundo um padrão harmônico de ondas (ondas espaçadas repetitivamente no tempo). As ondas eletromagnéticas propagam-se no vácuo na velocidade da luz (aproximadamente 300.000 km/s), a medida da distância entre dois picos sucessivos de ondas, determina o comprimento ou tamanho da onda (λ) (MENESES e ALMEIDA, 2012).

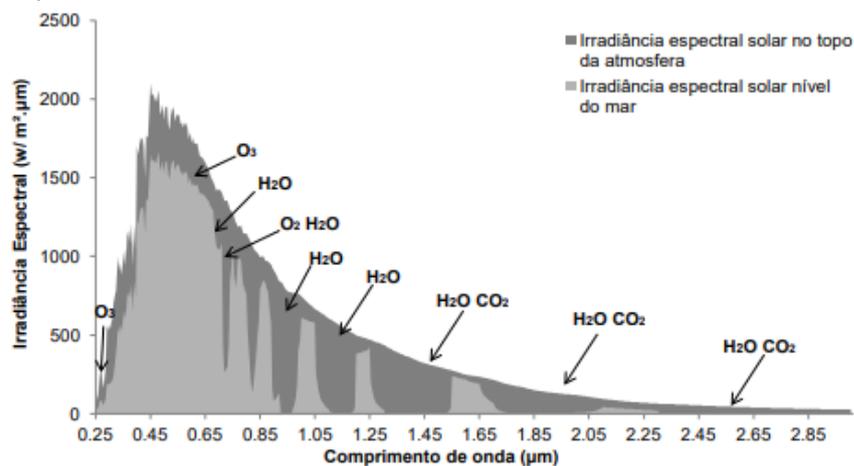
As radiações eletromagnéticas das ondas do visível e do infravermelho da luz solar possuem tamanhos menores (de 0,4 a 2,5 μm) que o tamanho médio das moléculas de vapor de água que compõem uma nuvem (30 μm), conseqüentemente um sensor registrará a intensidade da refletância da nuvem, formando uma imagem da nuvem e não dos objetos que estão sobre a superfície terrestre. Mas existem sensores que podem ultrapassar as moléculas de vapor de água contidas nas nuvens, esses sensores trabalham com micro-ondas e são denominados de radar.

Quando uma onda eletromagnética atinge a superfície terrestre, começa a interagir com a matéria por meio de trocas de energia (entre a energia que carrega e a energia contida nos átomos e moléculas da matéria). Para haver uma troca ou interação da energia da radiação da onda com a energia da matéria, é preciso que a REM incidente seja em parte absorvida pelos elétrons ou moléculas, e a parte que não é absorvida seja refletida para o sensor. Como resultado, as imagens medem a radiação refletida, mas, indiretamente, se avalia o que foi absorvido pelos materiais. Os materiais de diferentes composições (constituições variadas de elementos químicos, átomos e moléculas) têm absorções e refletâncias diferentes, definindo algumas informações sobre a composição dos alvos terrestres nas imagens de sensoriamento remoto (FIGUEIREDO, 2005).

Portanto, para se discriminar ou diferenciar nas imagens de sensoriamento remoto um objeto do outro, deve-se ter imagens nos comprimentos de onda de alta

energia (menores longitudes de onda), que possam interagir com os minerais constituintes. Nos casos em que se procura obter as diferenças das texturas, é aconselhável capturar imagens em comprimentos de onda maiores (radar), onde a textura da superfície é quem comanda as intensidades de refletância (MENESES e ALMEIDA, 2012). A porção da REM que interage diretamente com a atmosfera sofre dois efeitos, que são, absorção e espalhamento da radiação. Existem vários comprimentos de onda nos quais a atmosfera absorve total ou parcialmente a REM solar (Figura 1). Essas absorções são o motivo dos sensores mostrarem descontinuidades nos comprimentos de onda entre bandas contíguas.

Figura 1 - Absorção específica dos principais gases da atmosfera no espectro da radiação solar, no topo da atmosfera (cinza escuro) e ao nível do mar (cinza claro).

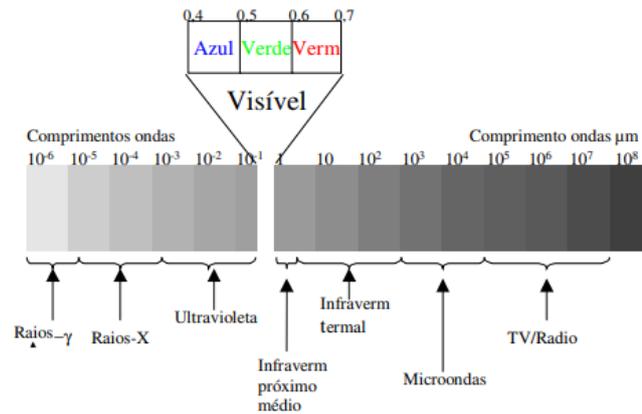


Fonte: Barbosa et al. 2019.

2.1.1. ESPECTRO ELETROMAGNÉTICO

Denomina-se espectro eletromagnético as regiões espectrais da REM que vão desde os comprimentos de onda dos raios cósmicos aos comprimentos de corrente alternada emitidos pelas redes de alta tensão. A REM é vista como um espectro contínuo, que se divide em intervalos de comprimentos de onda com base nos mecanismos físicos geradores da energia eletromagnética e nos mecanismos físicos de sua detecção (FIGUEIREDO, 2005). A Figura 2 mostra as diferentes faixas do espectro eletromagnético.

Figura 2 – Espectro eletromagnético.



Fonte: Figueiredo, 2005.

Meneses e Almeida (2012, p.20) apresentam os valores de cada comprimento de onda nos quais se podem obter imagens a partir de sensores instalados em aeronaves ou satélites (Tabela 1).

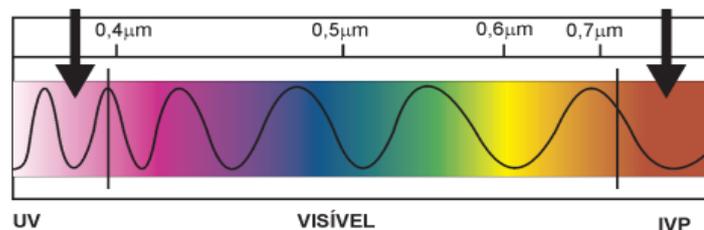
Tabela 1 - Intervalos espectrais comumente usados pelos sensores remotos.

0,45-0,76μm visível	0,76-1,2μm Infravermelho próximo	1,2-3,0μm Infravermelho de ondas curtas	3,0-5,0 infravermelho médio	5,0μm-1mm Infravermelho termal	1mm-100cm Micro-ondas
toda faixa	0,76-0,91 1,00-1,12	1,19-1,34 1,55-1,75 2,05-2,40	3,5-4,2 4,5-5,0	8,0-9,2 10,2-12,5	3,0-100

Fonte: Meneses e Almeida, 2012.

A região conhecida como visível é denominada dessa forma porque faz referência à faixa que o olho humano é capaz de detectar. A Figura 3 mostra um esquema representativo da dispersão da luz branca formando o espectro visível.

Figura 3 - Região visível do espectro (0.4 - 0.76 μm).

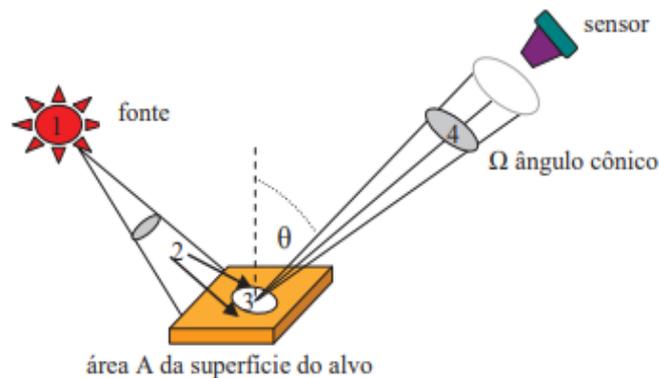


Fonte: Di Maio et al. 2018.

2.1.2. RADIÂNCIA E REFLETÂNCIA

Quando o sensor detecta e mede a radiação que deixa a superfície dos objetos, o sensor está fazendo uma medição radiométrica. A trajetória que a REM faz até o alvo e sua resposta medida pelo sensor envolvem diferentes conceitos que serão descritos no Quadro 1. Além disso, a Figura 4 apresenta a identificação dos componentes a serem descritos (os valores 1-4 na Figura 4, serão usados na identificação dos componentes).

Figura 4 - Descrição da trajetória da radiação eletromagnética e seus componentes radiométricos (da fonte ao sensor).



Fonte: Meneses e Almeida, 2012.

Quadro 1 - Componentes radiométricos da trajetória REM.

ID	Componente	Definição	Fórmula
1	Energia radiante (Q)	Energia que se propaga da fonte na forma de ondas eletromagnéticas, medida em Joule (J).	
2	Fluxo radiante (Φ)	Taxa na qual a energia radiante é transferida de um ponto ou superfície para outra superfície (por um tempo definido), medida em watts (W).	$\partial Q / \partial t$
3	Irradiância (Eλ)	Fluxo radiante solar incidente na superfície do terreno por área de superfície, medido em watts por metro quadrado (W/m ²).	$\Phi/\Delta A$
4	Radiância (Lλ)	Medida feita pelo sensor da densidade de fluxo radiante que deixa um elemento de área da superfície do terreno, e que se propaga em uma direção definida por um cone elementar de um ângulo sólido contendo aquela direção (W/m ² sr μm).	$\Phi/\Delta\Omega \Delta A \cos T$

Fonte: Meneses e Almeida, 2012.

As componentes descritas no Quadro 1 e as mostradas na Figura 4, estão ligadas na medida da radiação pelo sensor, e formam a definição de radiância. Por conseguinte, a imagem formada no sensor é uma imagem dos valores de radiância, valores que são interpretados pelo sensor como valores digitais, gerando a imagem digital. No caso da refletância, é definida como a razão entre a intensidade da luz refletida em uma amostra e a intensidade da luz incidente nela, em outras palavras, o fator que mede a capacidade de um objeto de refletir a energia radiante indica a sua refletância, esta é medida por espectrofotômetros de reflexão que são compostos por uma fonte de luz e um prisma para separar a luz em diferentes ondas (KUMAR et al. 1974).

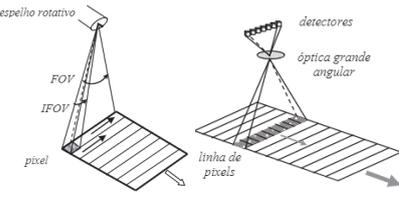
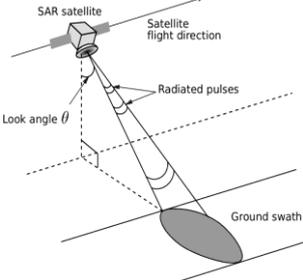
2.2 SENSORIAMENTO REMOTO

Uma das grandes fontes de informação espacial está no uso do sensoriamento remoto como ferramenta para medição da energia emitida ou refletida por diferentes alvos na superfície terrestre. De acordo com Diker (1998) e Seyhan (2004), e conforme citado por Tanriverdi (2006), o sensoriamento remoto é definido como um método para obter informação de diferentes objetos por meio de instrumentos que não estão em contato físico com aqueles objetos. Uma definição mais científica para o sensoriamento remoto é dada por Meneses e Almeida (2012) como “Uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres”. De maneira geral, os instrumentos usados com este objetivo são conhecidos como sensores remotos (plataformas de satélite, câmeras multiespectrais, espectrorradiômetros, scanners mecânicos, e outros).

Os sensores remotos podem ser diferenciados por duas categorias (pela fonte e pelo produto), pela fonte de REM que usam são os sensores ativos (fonte própria) e passivos (fonte exterior) e pelo produto que geram, são os sensores imageadores e não-imageadores. O produto gerado no caso dos imageadores é uma imagem digital em duas dimensões dos objetos imageados e no caso dos espectrorradiômetros (não-imageadores), um conjunto de medidas da intensidade de radiação (tabelas de dados ou gráficos) numa ampla faixa de comprimentos de onda. O Quadros 2 resume os

principais tipos de sensores remotos, assim como suas categorizações em função de algumas características específicas.

Quadro 2 - Tipos de sistemas imageadores considerando a fonte de REM.

SISTEMAS IMAGEADORES PASSIVOS	DESCRIÇÃO	EXEMPLOS
Sistema de varredura (<i>scanning</i>)	<p>Obtenção da imagem em várias faixas (aquisição sequencial).</p> <ul style="list-style-type: none"> - <i>Varredura mecânica</i>: possuem um único sensor para varrer a cena em duas direções (Whiskbroom). - <i>Varredura eletrônica</i>: usa um arranjo linear de sensores (Pushbroom). 	 <p>Whiskbroom Pushbroom</p>
Sistema de quadro (<i>framing</i>)	Obtenção da imagem em um mesmo quadro (ao mesmo tempo).	
Sistema fotográfico	Usado pelas plataformas aéreas.	
SISTEMAS IMAGEADORES ATIVOS	DESCRIÇÃO	EXEMPLOS
Radares imageadores (SAR)	Sensor de rádio frequência que permite derivar informações sobre características físicas (geometria, forma) e elétricas dos alvos. O sensor tem a capacidade de prover imagens de elevada resolução espacial, de modo independente de condições atmosféricas e fonte solar.	
SISTEMAS NÃO IMAGEADORES PASSIVOS	DESCRIÇÃO	EXEMPLOS
Espectrorradiômetros	Instrumento para medição de dados espectrais da radiação, como resposta em diferentes faixas do espectro.	
Estação Total	Instrumento eletrônico usado na medida de distâncias e ângulos.	

Fonte: Moreira, 2012.

2.3 PLATAFORMAS ESPACIAIS

As aplicações dos sensores remotos na agricultura de precisão estão relacionadas com os tipos de plataformas usadas pelo sensor na aquisição de dados. As plataformas são o suporte encarregado do transporte do sensor e podem ser classificadas como terrestres, aéreas ou espaciais. A habilidade para o levantamento de dados nas plataformas aéreas e espaciais encontra-se limitada pela quantidade de nuvens na atmosfera terrestre, mas as plataformas terrestres não são afetadas nesse aspecto, essas têm outra limitação em função da quantidade e área de cobertura dos sensores. Quanto às diversas aplicações, cada uma das plataformas apresenta vantagens e desvantagens em certa área, sendo as mais mencionadas suas resoluções espaciais (tamanho do pixel imageado), espectrais (faixas do espectro cobertas) e temporais (tempo de revisita do sensor) (DI MAIO, 2018).

Inicialmente, os levantamentos aerofotogramétricos eram utilizados com fins militares, mas os usos com fins civis foram realmente reconhecidos desde o lançamento dos satélites imageadores. As vantagens do uso de satélites e imagens de plataformas aéreas foram descobertas desde os primeiros estudos usando esses dados no começo da década de 1970. Bauer e Cipra (1973) apresentam um dos primeiros trabalhos aplicados à área agrícola classificando paisagens do Meio Oeste dos EUA em campos de milho e soja, usando imagens do satélite Landsat-1 (lançado em 1972 a 920 km de altura, e com resolução espacial de 76 metros) (MULLA, 2013). Do programa americano Landsat seguiram-se outros, europeus, canadenses, asiáticos e sul americanos, cada um procurando atender, cada vez mais, necessidades específicas.

As plataformas espaciais podem coletar vários dados para serem usados na agricultura de precisão. Os estudos nesta área geralmente estão focados em aspectos como: necessidade de irrigação, produção das culturas, saúde das plantas, áreas com ervas daninhas, prevenção da seca e classificação do tipo de culturas (HERBEI et al. 2016). A interpretação da resposta do solo e da vegetação à interação com a REM é a base da análise empregada na agricultura de precisão. A quantidade de radiação refletida sobre as culturas é inversamente proporcional à radiação absorvida pelos pigmentos vegetais (clorofila, antocianinas, carotenoides). Segundo Pinter et al. (2003) pigmentos como a clorofila conseguem absorver a radiação fortemente no

visível (400 nm a 700 nm), mas ao contrário do visível os valores de refletância são maiores no infravermelho próximo (700 nm a 1300 nm), dado pela densidade foliar e a estrutura do dossel.

2.3.1 RESOLUÇÕES DAS IMAGENS

Atualmente, há dezenas de sensores orbitais imageando a superfície da Terra em todas as faixas espectrais possíveis, que podem variar nas características das imagens obtidas (resolução espacial, espectral e radiométrica) e tempo de revisita do sensor (resolução temporal).

2.3.1.1 Resolução Espacial

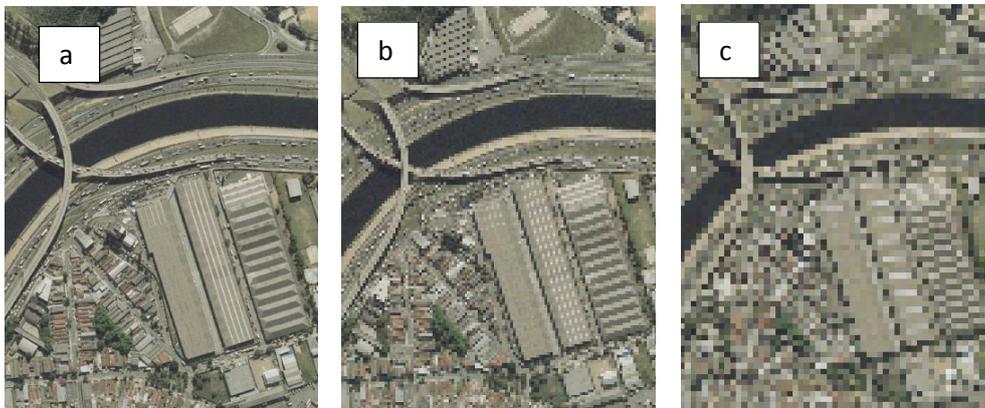
A resolução espacial determina o tamanho do menor objeto que pode ser identificado em uma imagem (Ver Figura 5). Na maioria dos sensores, a resolução espacial define as áreas de aplicação das imagens, por exemplo, para usos cadastrais a exigência seria um sensor com resolução espacial de poucos metros. A escala de visualização da imagem está relacionada ao valor da resolução espacial do sensor, alguns desses valores são mostrados no Quadro 3.

Quadro 3 - Resolução espacial e a escala de visualização da imagem de alguns satélites.

Escala	Resolução espacial (m)	Sensor
1:<10.000	1	Ikonos pancromático
1:10.000	2,5	Spot pancromático
1:20.000	5	Ikonos XS
1:40.000	10	Spot HRG
1:75.000	20	CBERS
1:100.000	30	Landsat (faixa óptica)
1:200.000	60	Landsat (TIR)
1:350.000	90	Aster (TIR)

Fonte: Meneses e Almeida, 2012.

Figura 5 - Porção de uma ortofotocarta de São Paulo do ano 2007 (a) resolução espacial de 0,6 m (b) resolução espacial de 5 m (c) resolução espacial de 10 m.



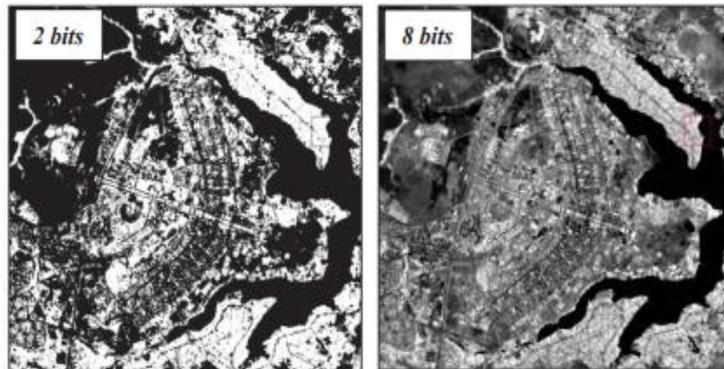
Fonte: adaptado de Empresa Paulista de Planejamento Metropolitano S.A. (EMPLASA), 2007.

A Figura 5, mostra diferentes exemplos de resolução espacial para uma porção de uma ortofotocarta do ano de 2007 da cidade de São Paulo, a porção (a) é para uma resolução espacial de 0,6 m, a porção (b) é para uma resolução espacial de 5 m e a porção (c) apresenta uma resolução espacial de 10 m, enquanto maior é o valor da resolução espacial, menor é o detalhe de informação capturada pelo sensor. No caso da Figura 5, pode-se distinguir a diferença na qualidade do detalhe das imagens com menor resolução espacial (a) em comparação com as de maior resolução espacial (b e c). É importante esclarecer que as imagens da Figura 5 indicam somente a diferença na resolução espacial, apresentando a mesma resolução espectral e radiométrica para todos os casos.

2.3.1.2 Resolução Radiométrica

A resolução radiométrica é definida como a medida pelos detectores da intensidade de radiância da área de cada pixel unitário. Maior será a resolução radiométrica, quanto maior for a capacidade do detector para medir as diferenças de intensidades dos níveis de radiância. Quanto maior é a resolução radiométrica (quantização), maior será a qualidade visual da imagem (Figura 6), a quantização é normalmente expressa em termos de números de dígitos binários (bits).

Figura 6 - Imagens de quantização menor (2 bits) e quantização maior (8 bits).



Fonte: Star et al. 1987.

Na Figura 6, observa-se uma diferenciação entre a qualidade visual de uma imagem de baixa resolução radiométrica (2 bits) e uma imagem de resolução radiométrica alta (8 bits). A imagem de 2 bits possui apenas 4 níveis de cinza ($2^2=4$), e a imagem de 8 bits possui 256 níveis de cinza ($2^8=256$), e em consequência tem detalhes visuais melhores.

2.3.1.3 Resolução Temporal

A resolução temporal é a frequência com que o sensor revisita uma área, periodicidade de revisita ao longo de sua vida útil (Ver Tabela 2). A maioria dos satélites imageadores possuem órbitas heliosíncronas, que são casos particulares de órbitas semipolares (plano de órbita é sempre fixo e ortogonal ao sentido de rotação da Terra), desta forma o satélite passa sobre o mesmo ponto da superfície da Terra na mesma hora.

Para aplicações como a agricultura de precisão e estudos de desastres ambientais, a resolução temporal é fundamental para acompanhar as mudanças dos alvos dinâmicos.

Tabela 2 - Tempo de revisita dos principais satélites.

Principais plataformas de satélite	Resolução Temporal (dias)
Landsat-8	16
Sentinel-2	5
CBERS-4	26
ASTER	15
RapidEye	5,5
SPOT 6 E 7	1
Worldview 2	1,1
PLEIADES	1

Fonte: Elaboração própria

2.3.1.4 Resolução Espectral

A propriedade mais importante dos sensores imageadores é a capacidade de obtenção de imagens em várias faixas do espectro (bandas espectrais). O termo resolução espectral envolve os seguintes parâmetros de medida: o número de bandas que o sensor possui, a largura em comprimento de onda das bandas, e as posições nas que as bandas estão situadas no espectro eletromagnético. Quer dizer que um sensor tem melhor resolução espectral se ele possui maior número de bandas situadas em diferentes regiões espectrais e com larguras estreitas de comprimentos de onda. A Tabela 3 compara as resoluções espectrais de alguns dos principais satélites usados para o monitoramento da vegetação através de imagens de livre acesso e comerciais (acesso baixo pagamento).

Tabela 3 - Resolução espacial e espectral das plataformas de satélite comumente usadas no sensoriamento remoto.

LANDSAT-8 OLI	SENTINEL-2 MSI	CBERS-4	ASTER	RAPIDEYE	SPOT 6 E 7	WORLDVIEW 2	PLEIADES
						B2 (CostalBlue) - 2 - (400-450)	
^a B2 (Blue) - 30 - (452-512)	B2 -10 - (458-523)	B2 ^b -20 - (450-520)		B2 - 5 - (440-510)	B2 - 6 - (455-525)	B3 - 2 - (450-510)	B0 - 2 - (450-530)
B3 (Green) - 30 - (533-590)	B3 -10 - (543-578)	B3 ^b -20 - (520-590)	B1 - 15 - (520-600)	B3 - 5 - (520-590)	B3 - 6 - (530-590)	B4 - 2 - (510-580)	B1 - 2 - (510-590)
						B5 (Yellow) - 2 - (585-625)	
B4 (Red) - 30 - (636-673)	B4 -10 - (650-680)	B4 ^b -20 - (630-690)	B2 - 15 - (630-690)	B4 - 5 - (630-685)	B4 - 6 - (625-695)	B6 - 2 - (630-690)	B2 - 2 - (620-700)
	B5 (RedEdge 1) - 20 - (689,1-719,1)			B5 (RedEdge) - 5 - (690-730)		B7(RedEdge) - 2 - (705-745)	
	B6 (RedEdge 2) -20 - (725,5-755,5)						
	B7 (RedEdge 3) -20 - (762,8-802,8)						
B5 (NIR) - 30 - (851-879)	B8 -10 - (785-900)	B8 ^b - 20 - (770- 890)	B3 - 15 - (760-860)	B6 - 5 - (760- 850)	B6 - 6 - (760- 890)	B8 (NIR1) - 2 - (770-895)	B3 (NIR) - 2 - (775-915)
	B8A (RedEdge 4) - 20 - (843,7-885,7)					B9 (NIR2) - 2 - (860-1040)	
	B9 (WaterVapor) - 60 - (843,7-885,7)						
B6 (SWIR1) - 30 - (1566-1651)	B11 - 20 - (1565-1655)	B10 ^c - 40 - (1550- 1750)	B4 - 30 - (1600-1700)				
B7 (SWIR2) - 30 - (2107-2294)	B12 - 20 - (2100-2280)	B11 ^c - 40 - (2080- 2350)	B5 - 30 - (2145- 2185)				
			B6 - 30 - (2185- 2225)				
			B7 - 30 - (2235- 2285)				
			B8 - 30 - (2295- 2365)				
			B9 - 30 - (2360- 2430)				
B8 (PAN) - 15 - (500-680)		B1(PAN) - 5 - (510 - 850)			B1(PAN) - 1,5 - (450 - 745)	B1(PAN) - 0,5 - (450 - 800)	B4(PAN) - 0,5 - (480 - 820)

^a Número de banda (nome) – resolução espacial (m) – comprimento de onda (nm), ^bCâmera MUX, ^cCâmera IRS

Continua

LANDSAT-8 OLI	SENTINEL-2 MSI	CBERS-4	ASTER	RAPIDEYE	SPOT 6 E 7	WORLDVIEW 2	PLEIADES
B9 (CIRRUS) – 30 - (1360–1390)	B10 - 60 - (1342,5- 1404,5)	B12 ^c - 80 - (10400- 12500)	B10 (TIR) – 90 - (8125 - 8475) B11 (TIR) – 90 - (8475 - 8825) B12 (TIR) – 90 - (8925 - 9275) B13 (TIR) – 90 - (10250 - 10950) B14 (TIR) – 90 - (10950 - 11650)				

^a Número de banda (nome) – resolução espacial (m) – comprimento de onda (nm), ^bCâmera MUX, ^cCâmera IRS
 Fonte: Adaptado de Portal Directory (Sharing Earth Observation Resources), 2019.

A Tabela 3 resume a maioria das bandas (faixas de cobertura do espectro eletromagnético) nas quais os sensores (câmeras imageadoras) das plataformas de satélite trabalham. Sendo que as regiões vão desde as faixas do visível (400-700 nm), a borda do vermelho ou redEdge (700-800 nm), infravermelho próximo NIR (800-900 nm), regiões do infravermelho de onda curta SWIR (Short wave infrared) (1500-2500 nm), até as regiões do infravermelho termal TIR (10000-12000 nm). Além das faixas nomeadas, existe a região do Cirrus (1300-1400 nm) útil na elaboração de modelos atmosféricos. Alguns sensores apresentam também a banda pancromática (que possui melhor resolução espacial) que permite obter informação na região do visível e corrigir as imagens com a finalidade de melhorar a resolução espacial das outras bandas em um processo digital conhecido como fusão de imagens.

No caso do satélite CBERS-4 que possui 4 sensores imageadores, dos quais são unicamente apresentados os sensores MUX (Câmera Multiespectral Regular) e IRS (Imageador Multiespectral e Termal) na Tabela 3, apresenta-se o Quadro 4, que resume os valores para as faixas do espectro cobertas pelas câmeras restantes (PAN- Câmera Pancromática e Multiespectral e WFI- Câmera de Campo Largo), junto a outras características do satélite.

Quadro 4 - Características das câmeras imageadoras CBERS-4.

CARACTERÍSTICAS	PAN5M	PAN10M	MUX	WFI	IRS
Bandas Espectrais	B1: 510 - 850 nm		B5: 450 - 520 nm	B13:450-520 nm	
		B2: 520 - 590 nm	B6: 520 - 590 nm	B14:520-590 nm	
		B3: 630 - 690 nm	B7: 630 - 690 nm	B15:630-690 nm	
		B4: 770 - 890 nm	B8: 770 - 890 nm	B16:770-890 nm	
Largura da Faixa Imageada	60 km	60 km	120 km	866 km	120 km
Resolução Espacial	5 m	10 m	20 m	64 m	40 m - PAN e SWIR 80 m Termal
Visada Lateral de Espelho	± 32°	± 32°	Não		
Distância focal efetiva	1.010 mm	1.010 mm	505,8 mm	149,85 mm	1.400 mm (B1, B2 e B3) 700 mm (B4)
Revisita	Não	Não	26 dias	5 dias	26 dias
Confiabilidade	0,945	0,945	0,955	0,943	
Vida útil	3 anos em órbita	3 anos em órbita			

Fonte: INPE, 2005.

Como informação adicional, vamos destacar que no dia 20 de dezembro de 2019 foi lançado a sexta versão do satélite CBERS produto da parceria China - Brasil, a plataforma de satélite conhecida como CBERS-4A, foi programada para ir operar numa órbita sol-síncrona ao redor dos 628,6 km de altitude, com uma repetição do ciclo de 31 dias. A sol-sincronicidade do CBERS 04A, que assegura uma uniformidade de iluminação durante o imageamento (ângulo entre o plano da órbita e a linha que une o centro da Terra ao Sol é mantido constante durante toda a missão). O intervalo de três dias entre faixas adjacentes mantém o mesmo padrão de imageamento dos CBERS anteriores, e permite que fenômenos que ocorram em áreas contíguas a duas faixas de imageamento possam ser visualizados num curto intervalo de tempo. Com o novo satélite (CBERS 04A), além das Câmeras MUX e WFI já utilizadas nos CBERS 3 e 4, entra em atividade a câmera imageadora WPM (Câmera Multiespectral e Pancromática de Ampla Varredura), ajudando na captação de imagens de desmatamento da Amazônia, mapeamento de queimadas, e fornecimento de dados à agricultura (INPE, 2019).

Atualmente encontra-se um abundante conjunto de plataformas espaciais (Tabela 3), porém existe uma ampla gama de aplicações dos dados coletados. No caso da agricultura de precisão algumas das restrições do uso de imagens de satélites são: o tempo de revisita de alguns satélites, a cobertura de nuvens (é preciso obter imagens com pouca cobertura de nuvens na área), o preço de uma cena de resolução espacial sub-métrica (que pode ir desde 10 a 19 dólares por km², sendo na maioria dos casos necessária uma aquisição mínima de 25 km²), o desconhecimento sobre a disponibilização e pré-processamento dos dados, entre outras, que podem dificultar o uso das imagens para os pequenos agricultores. As mencionadas e várias outras razões são suficientes para direcionar mais esforços na investigação e detalhamento das técnicas necessárias para o processamento de imagens de satélite, suas aplicações e acessibilidade às informações disponíveis sem custo. Algumas das características adicionais dos sensores mencionados na Tabela 3 estão listadas a seguir:

- *LANDSAT-8*: Satélite do Serviço geológico dos Estados Unidos (USGS- *United States Geological Survey*). Iniciado em 1972, o programa Landsat permite gerar imagens de 15 m coloridas por fusão digital. O Landsat-8 com seu sensor OLI (*Operational Land Imager*) foi lançado em 11 de fevereiro de 2013 em uma órbita heliosíncrona de 705 km de altitude, o que garante

um tempo de revisita de 16 dias. As imagens do Landsat-8 apresentam uma resolução radiométrica de 16 bits por pixel. As principais aplicações são para detecção de nuvens, cálculo de cobertura vegetal e monitoramento ambiental;

- **SENTINEL-2:** Projeto de missão de imagem operacional multiespectral no âmbito do programa GMES - COPERNICUS (*Global Monitoring for Environment and Security*), implementado conjuntamente pela CE (*European comission*) e pela ESA (*European Space Agency*). Iniciou a transmissão em junho de 2015, possui uma órbita síncrona a 786 km, o que garante uma resolução temporal de 5 dias, com imagens de 12 bits. É um satélite de observação global da terra (estudos sobre vegetação, solo e cobertura de água para terra, vias navegáveis interiores e áreas costeiras, e também para fornecer correções de dados de absorção atmosférica e distorção);
- **CBERS-4:** Satélite de recursos terrestres China-Brasil (*China-Brazil Earth-Resources Satellite*) lançado em 07 de dezembro de 2014, com uma órbita síncrona de 778 km, apresenta um tempo de revisita de 26 dias, e uma resolução radiométrica de imagens de 8 bits (MUX) e 10 bits (WFI), as principais aplicações são no apoio a levantamentos de solos e geológicos, identificação de áreas de florestas, identificação de campos agrícolas, quantificação de áreas e monitoramento de fenômenos dinâmicos;
- **ASTER:** Satélite do programa ESE (*Earth Science Enterprise*) da NASA (*National Aeronautics and Space Administration*) colaboração entre Estados Unidos, Japão e Canadá. O satélite foi lançado em 18 dezembro de 1999, com uma órbita síncrona de 705 km, com um tempo de revisita de 12 dias e uma resolução radiométrica de 8 bits (VNIR- *visible near infrared* e SWIR- *short wave infrared*) e 12 bits (TIR- *Termal infrared*) por pixel. As aplicações dos satélites do programa TERRA são para a elaboração de modelos atmosféricos;
- **RAPIDEYE:** Satélite Alemão que gera imagens multiespectrais coloridas, foi lançado em 29 agosto de 2008, em uma órbita síncrona de 630 km, tendo um tempo de revisita de 5,5 dias, com imagens de 12 bits de resolução radiométrica. O satélite apresenta uma resolução espacial de 5 m, o que

ajuda nas aplicações de Agricultura, silvicultura, exploração de petróleo e gás, energia, engenharia e construção, governos, cartografia e mineração;

- *SPOT 7*: Satélite de imagem óptica lançado em 30 junho 2014 com uma órbita Heliosíncrona de 694 km de altitude. A resolução radiométrica das imagens é de 12 bits por pixel e 6m de resolução espacial. As aplicações principais conhecidas são para defesa, agricultura, desmatamento, monitoramento ambiental, vigilância costeira, engenharia, petróleo, gás e indústrias de mineração;
- *WORLDVIEW -2*: É um satélite de imagens comerciais da DigitalGlobe Inc. Lançado em 08 de outubro de 2009, com uma, órbita síncrona de 770 km de altitude. A resolução espacial do satélite é de 2 m e 1.1 dias de revisita, produzindo imagens de 11 bits de resolução radiométrica. As imagens deste satélite são amplamente usadas em aplicativos de monitoramento e cadastro;
- *PLEIADES 1A e 1B*: Com 180 graus de diferença na mesma órbita os satélites da constelação são considerados os mais eficientes dentre os satélites de altíssima resolução. Capazes de estereoscopia e triestereoscopia. Pléiades é um satélite francês lançado em 17 de dezembro de 2011 – 1A e 2 de dezembro de 2012 - 1B. Possui uma órbita circular heliosíncrona de 695 km, com um tempo de revisita de 1 dia e uma resolução radiométrica de 12 bits. Entre as aplicações comumente conhecidas para este satélite temos a cartografia, agricultura, silvicultura, hidrologia e prospecção geológica;

2.4 IMAGENS DIGITAIS

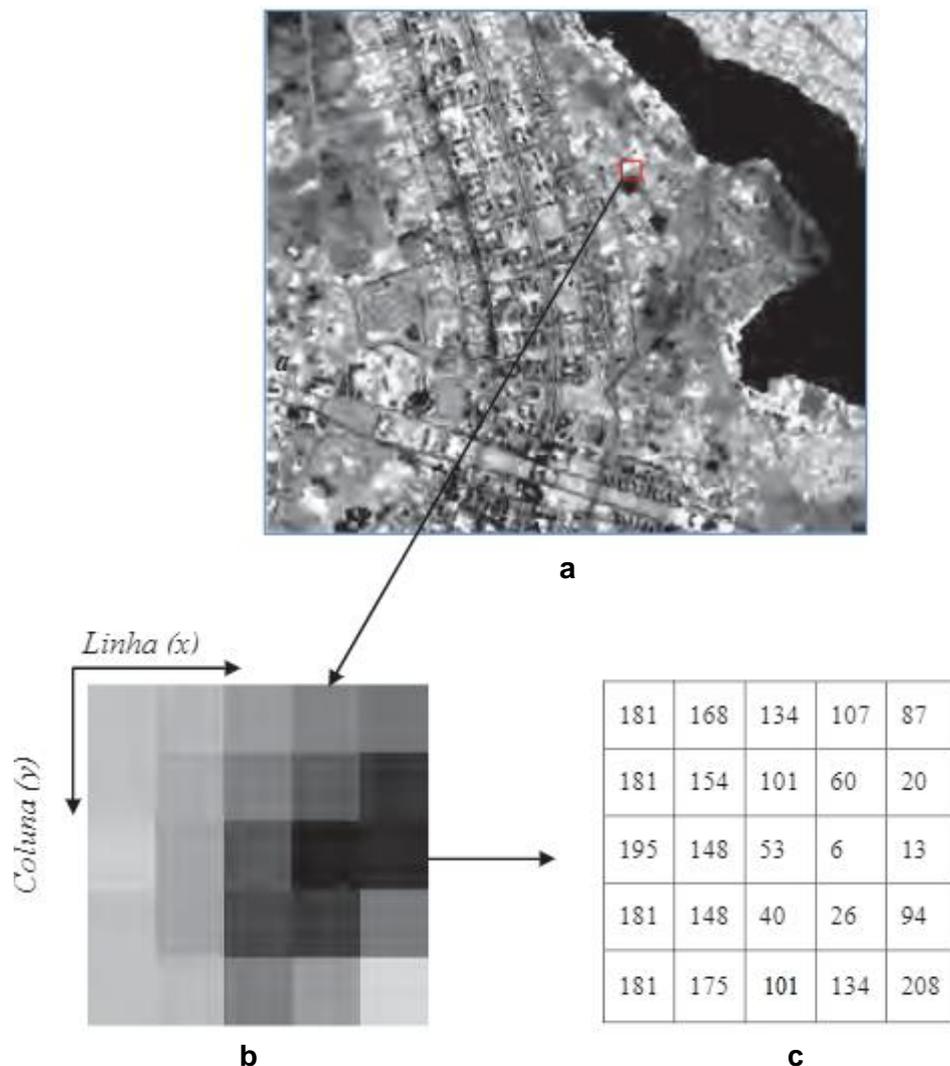
Na área do sensoriamento remoto as imagens digitais são registros de cenas focalizadas por sensores, que representam, em escala e sobre um plano 2D, os acidentes e as feições naturais e artificiais da superfície terrestre a partir da medição de um processo físico da radiação eletromagnética. No sensor, um conversor analógico/digital converte a informação (analógica dos objetos) em um valor digital, codificado por uma unidade denominada *pixel (picture element)*, formando um arranjo de elementos sob a forma de uma malha ou grade. Uma imagem finalmente é

constituída como uma matriz de dados, onde cada célula (x,y) da matriz é a posição do *pixel* da imagem digital (CRÓSTA, 2002).

O valor do pixel, correspondente ao valor de radiância, emitância ou de retroespalhamento dos diferentes alvos imageados, é convertido no sensor para um valor digital discreto e finito (Nível Digital “ND”) (LEÃO, 2001).

Observa-se na Figura 7, uma cena de imagem digital (a), assim como também seu arranjo matricial (b) como conjunto de linhas e colunas que iniciam desde a esquina superior esquerda, identificando finalmente os valores digitais (ND) de cada um dos *pixels* da imagem.

Figura 7 - Cena de uma imagem digital (a), grupo de *pixels* (b) e valores digitais (c).



Fonte: Leão, 2001.

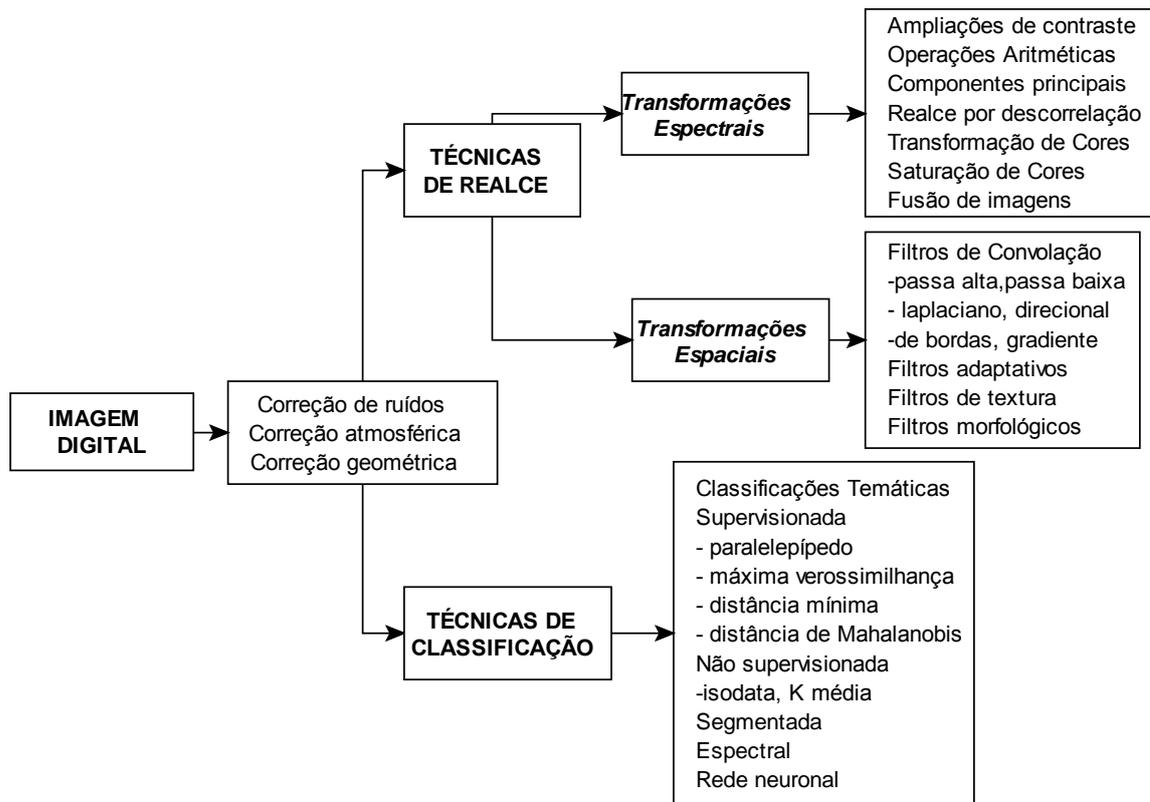
2.4.1 PROCESSAMENTO DE IMAGENS DE SATÉLITE

Atualmente, existem diversas técnicas usadas para o tratamento das imagens digitais e sua transformação em imagens de melhor qualidade espectral e espacial. A interpretação final dos dados contidos na imagem sempre caberá ao usuário, já que os algoritmos aplicados tratam matematicamente a imagem como um dado diretamente relacionado ao processo físico que o criou. Porém, a representação e o processamento matemático da imagem não é 100% a representação do mundo real.

A maioria dos softwares especializados em processamento de imagens de sensoriamento remoto divide as técnicas de processamento digital em dois tipos básicos: realce (transformações espectrais e espaciais) e classificação (supervisionada e não supervisionada), que são antecedidas por uma fase de pré-processamento (correção de ruídos, correção atmosférica e correção radiométrica), cujo objetivo é corrigir preliminarmente os erros que os dados originais possam apresentar. As principais técnicas de processamento que os softwares dispõem são apresentadas na Figura 8. Enquanto às técnicas de pré-processamento de imagens são, essencialmente, funções operacionais para remover ou corrigir os erros e as distorções introduzidos nas imagens pelos sistemas sensores devidos a erros instrumentais (ruídos falsos), às interferências da atmosfera (erros radiométricos) e à geometria de imageamento (distorções geométricas) (MENESES e ALMEIDA, 2012).

As técnicas de processamento mostradas na Figura 8, são um grande esforço para tornar mais acessível, a extração de informações das imagens digitais. As correções das distorções presentes nas imagens digitais fazem parte do conjunto de funções de processamento que se denomina de pré-processamento (correção de ruídos, correção atmosférica e correção radiométrica).

Figura 8 - Principais técnicas de processamento de imagens.



Fonte: Adaptado de Meneses e Almeida, 2012.

2.4.1.1 Pré-processamento de Imagens de satélite

Para uma interpretação confiável da informação obtida nas imagens de satélite é necessário remover os efeitos que podem ser produzidos pelos erros ou defeitos dos sensores, sejam dados pelas perdas na estabilidade da plataforma ou pela intervenção de fontes externas. Os erros ou distorções nas imagens de satélite sempre vão se apresentar como: deformações de escala, incorreções nas posições espaciais dos pixels, perda de contraste entre os alvos ou registros incorretos dos valores digitais dos pixels (FIGUEIREDO, 2005).

É necessário o uso de processamentos computacionais que permitam extrair a informação contida nas imagens de satélite e dessa forma facilitar a interpretação dos valores traduzidos como dados de refletância ou emitância dos alvos ou matérias de interesse. Com o uso de diversas técnicas de processamento de imagens, procura-se tornar mais acessível a extração de informação dos diferentes objetos ou

materiais que naturalmente mostram baixos contrastes espectrais de refletância, emitância e retroespalhamento da radiação eletromagnética.

2.4.1.1.1 Correção radiométrica

A Correção radiométrica tenta corrigir problemas mecânicos no sensor que geram valores errôneos em pixels específicos ou erros coerentes de linhas de pixels que, normalmente, se mostram como pixels ou linhas com valores saturados (claros), ou sem sinal (escuros), e são denominados de ruídos. Os ruídos, normalmente, se apresentam em três formas: como linhas ruidosas, pixels ruidosos ou conjunto sistemático de linhas ruidosas, que se denomina de *striping*.

O método mais usado para corrigir ou recompor linhas de pixels ruidosos é substituir a linha ruim pelo valor médio dos pixels correspondentes das linhas anterior e posterior.

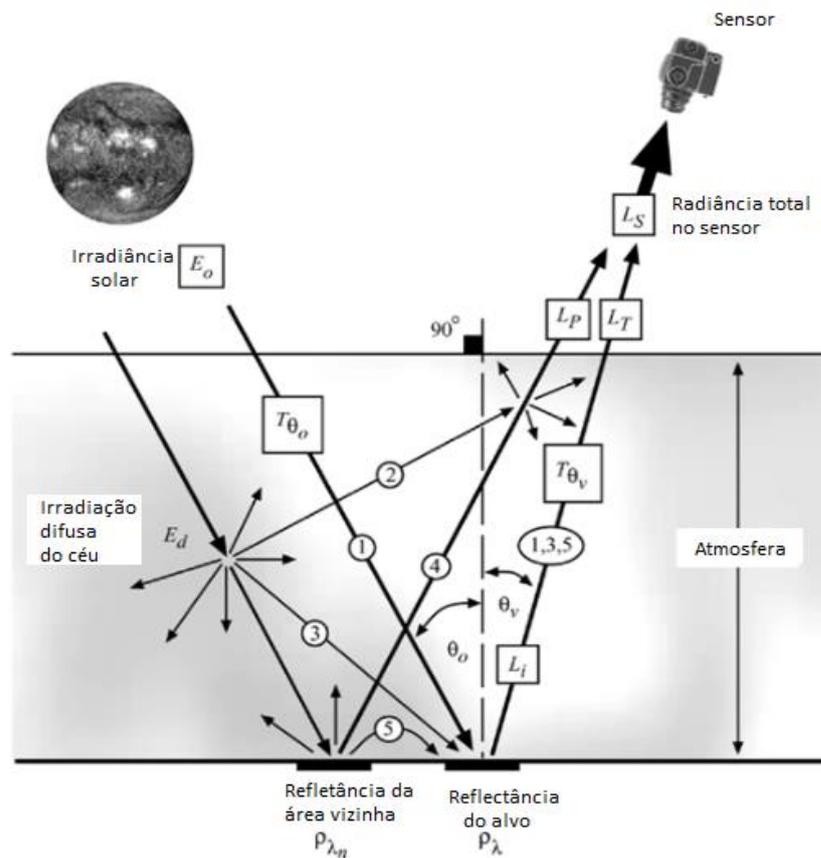
2.4.1.1.2 Correção Atmosférica.

Antes de entrar na descrição dos diferentes métodos de correção atmosférica é preciso entender as muitas interações que envolve o caminho da radiação solar para a Terra e depois para um sensor de satélite no espaço. Uma das fontes de erro que consegue alterar por completo a radiância medida na imagem é a atmosfera, que pode atuar como, um refletor, adicionando uma radiância extra ao sinal e como um absorvedor, atenuando a intensidade de energia que ilumina o alvo na superfície (Jensen, 2007). A Figura 9 mostra a interação da irradiância solar com os objetos na superfície terrestre e sua resposta como medidas de radiância medidas no sensor.

Para melhorar a compreensão da Figura 9 é preciso apresentar os seguintes termos: **L_s**, que é a radiância total no sensor, que adiciona, **L_p**, sendo a medida de radiância dos caminhos 2 e 4. Sendo o caminho 2 a irradiância difusa ou espalhamento, o caminho 4 a refletância das áreas vizinhas (radiação adjacente). Além disso, **L_t** é a radiância total da superfície de interesse. O caminho 1 é a irradiância que foi reduzida antes de atingir a superfície. O caminho 3 é a irradiância que foi espalhada para baixo na área de interesse. O caminho 5 é a radiação que foi refletida de uma área vizinha e depois espalhada na área de estudo. No geral, o resultado das interações da radiação solar na atmosfera é erroneamente adicionado

à refletância TOA (Top of Atmosphere), que é a razão entre a radiação total no sensor (L_s) e o total de radiação recebida no topo da atmosfera onde está localizado o sensor de satélite.

Figura 9 – Trajetória da radiação emitida como irradiância solar e recebida como radiação no sensor.



Fonte: Jensen, 2007.

Portanto, o objetivo da correção e conversão das imagens de satélite em valores de refletância da superfície (BOA – *Bottom of Atmosphere*) é recuperar valores de refletância semelhantes aos valores medidos na superfície (como os obtidos pelos dispositivos portáteis que medem com maior precisão a proporção da radiação recebida e a quantidade refletida). Conhecer com exatidão os parâmetros que caracterizam o estado atmosférico da área no momento em que o sensor adquiriu a imagem seria o ideal para realização das correções atmosféricas da imagem. Existem diversos métodos para correção do espalhamento atmosférico, podem ser divididos em métodos alternativos e métodos físicos. Os métodos alternativos não dependem de parâmetros atmosféricos ou de dados da superfície, e sim das informações da

própria imagem (ND). Nos métodos físicos, é crucial o conhecimento das propriedades óticas da atmosfera bem como do processo de interação da radiação com a atmosfera e com a superfície. O Quadro 5 resume alguns dos métodos mais conhecidos para o pré-processamento de imagens de satélite.

Quadro 5- Métodos de pré-processamento de imagens.

Método	Descrição e aplicação	Proposto por
DOS (<i>Dark Object Subtraction</i>)	Método de correção que estima a interferência atmosférica diretamente a partir dos números digitais (ND) da imagem de satélite, sendo ignorada a absorção atmosférica (transmitância da atmosfera). Assume-se a existência de alvos (<i>pixels</i>) escuros nas imagens (sombras ou corpos de água), os quais deveriam apresentar um ND muito baixo na imagem, equivalente a cerca de 1% de refletância. Para a aplicação da correção DOS, um valor de pixel escuro é escolhido da banda com menor comprimento de onda. Em seguida, um modelo de espalhamento atmosférico é selecionado e o valor de espalhamento é estimado por banda espectral, sendo os valores de espalhamento estimados normalizados de acordo com os ganhos e <i>offsets</i> usados pelo sistema imageador para coletar os dados. A correção é feita pela subtração dos valores estimados para toda a imagem, assumindo um espalhamento uniforme em toda a cena.	Chavez, J. em 1988
DOS1	Visando corrigir ambos os efeitos aditivos e multiplicativos da atmosfera, foi proposta uma modificação no método DOS, ao invés de se adotar o valor um, a transmitância da atmosfera passou a ser estimada pelo cosseno do ângulo zenital.	Chavez, J. em 1996
6S (<i>Second Simulation of Satellite Signal in the Solar Spectrum</i>)	Também considera o processo de absorção da radiação eletromagnética, o que implica em valores de refletância de superfície mais confiáveis. O método é usado pelo software da USGS chamado LEDAPS (<i>Landsat Ecosystem Disturbance Adaptive Processing System</i>). O software LEDAPS processa o modelo de transferência radiativa 6S a partir da inserção de dados como vapor de água, altura geopotencial, espessura óptica de aerossóis, elevação digital, juntamente com os dados Landsat originais para gerar a refletância no topo da atmosfera (ToA - <i>Top of Atmosphere</i>) e refletância de superfície, entre outros produtos.	Vermote <i>et al.</i> , em 1997

Fonte: Sanches *et al.*, 2011

2.4.1.1.3 Correção Geométrica

Trata-se da remoção de erros sistemáticos presentes nas imagens, essa correção é feita em duas etapas. Na primeira etapa de correção são eliminadas as

distorções geométricas sistemáticas que são introduzidas no momento de aquisição das imagens devidas à rotação, inclinação e curvatura da Terra, ou em alguns casos devida à instabilidade da plataforma. A primeira etapa depende de uma série de parâmetros da exatidão de posicionamento da plataforma e fica a cargo dos laboratórios de produção de imagens. Na segunda etapa do processo, para se corrigir as distorções geradas pela visada cônica dos sensores, o usuário deve dar à imagem um sistema de referência, o que significa inserir na imagem um sistema de projeção para se estabelecer um referencial de coordenadas que possibilite localizar na imagem a posição geográfica dos alvos (FIGUEIREDO, 2005).

A evolução ocorrida no campo da computação gráfica permitiu a criação de vários programas (software) comerciais e de domínio público que são utilizados para o processamento de imagens, esses programas usam operações e algoritmos definidos para cada satélite, alguns desses softwares serão descritos mais adiante.

2.5 SISTEMAS DE INFORMAÇÃO GEOGRÁFICA

Os Sistemas de Informação Geográfica (SIG, em inglês, GIS - *Geographic Information Systems*) são amplamente utilizados na caracterização da variação espacial de um determinado campo por meio de uma estrutura de grade celular na qual a área é particionada em células de grade regulares (imagem digital), ou usando um conjunto de pontos, linhas e polígonos (vetor). As últimas melhorias no software GIS e no hardware de GNSS (*Global Navigation Satellite Systems*) forneceram técnicas de pré-processamento e processamento de imagens mais eficientes, que facilitam o desenvolvimento de procedimentos mais rápidos de análise nas diferentes aplicações (agricultura de precisão, cadastro, monitoramento ambiental, e outras) (TANRIVERDI, 2006).

Formalmente Burrough (1986), define os Sistemas de informação Geográfica (GIS) como um conjunto de ferramentas computacionais compostas de equipamentos e programas que por meio de técnicas, integram dados, pessoas e instituições, facilitando a coleta, armazenamento, processamento, análise e disponibilização de dados georeferenciados de informação, para uma maior agilidade nas atividades humanas referentes ao monitoramento, planejamento e estabelecimento de decisões relativas ao espaço geográfico.

De maneira geral, as principais características de um GIS são: integrar, em uma única base de dados, informações espaciais provenientes de dados cartográficos, dados cadastrais, imagens de satélite, redes e modelos numéricos de terreno; combinar as várias informações, através de algoritmos de manipulação, para gerar mapeamentos derivados; e consultar, recuperar, visualizar e plotar o conteúdo da base de dados geocodificados (ARONOFF, 1989).

2.5.1 PRINCIPAIS SOFTWARE GIS

Cada um dos GIS oferece ferramentas próprias, úteis em diferentes áreas de aplicação. No resumo dos principais softwares GIS, considerou-se apenas os sistemas que atendem os requisitos de aplicações de sensoriamento remoto, ambientais e cadastrais mais conhecidos, e podem ser diferenciados como GIS comerciais (com licenciamento) e GIS livres (código aberto) e são:

- ARC/INFO: desenvolvido pela ESRI (*Environmental Systems Research Institute*). O pacote básico é composto de subsistemas (ARCEDIT, ARCPLOT, TABLES, LIBRARIAN), que possibilitam a importação de diversos formatos matriciais e vetoriais, ferramentas de edição e gerência de base de dados espaciais, análises e gerências de dados *raster*, análise de modelo de elevação digital, entre outros;
- ARC/VIEW: desenvolvido pela ESRI (*Environmental Systems Research Institute*), para ambientes PC/Windows, originalmente com uma interface dirigida para apresentação de dados produzidos no ARC/INFO, e atualmente as extensões são: análise matricial, análise de rede, digitalização, leitura de imagens, análise 3D, e *business-geographic*;
- AutoCadMap: sistema para mapeamento cadastral, desenvolvido pela Autodesk (EUA), com base na funcionalidade do AutoCAD;
- EASI/PACE: sistema para processamento digital de imagens de satélite, desenvolvido pela PCI Remote Sensing Corp., do Canadá;
- ERDAS: sistema modular de processamento digital de imagens e análise espacial, desenvolvido pela ERDAS Inc. (EUA), com os seguintes módulos principais: Viewer, Import, Image Catalog, Image Interpreter, Data Prep, Vector, Map Composer e Model Maker;

- ER Mapper: sistema para processamento de imagens de satélite, desenvolvido pela Earth Resources Mapping Ltd., da Austrália;
- Idrisi: sistema de análise geográfica e processamento de imagens para ambiente PC, desenvolvido pela Clark University (EUA);
- MapInfo: software para ambientes PC/Windows, desenvolvido pela MapInfo Corp., EUA, com módulos: consulta a banco de dados geográficos, “business geographic”, modelagem numérica de terreno;
- Modular GIS Environment (MGE): desenvolvido pela Integrgraph, possui vários módulos para as várias funções de Geoprocessamento;
- SPRING: desenvolvido pela Divisão de Processamento de Imagens do Instituto Nacional de Pesquisas Espaciais (INPE) software gratuito que foi tornado *open source* (código aberto) a partir de maio de 2018. SPRING é um sistema de análise geográfica e processamento de imagens desenvolvido para os ambientes Windows e UNIX (incluindo Linux);
- QGIS: o Quantum GIS é um dos softwares livres (código aberto) mais conhecidos para o geoprocessamento de imagens e dados vectoriais, é totalmente multiplataforma, sendo instalado nos Sistemas Operacionais Windows, Linux, Mac OS X e sistemas UNIX. Uma de suas principais características é a possibilidade de suporte à *plugins*, que podem complementar suas funções, aumentando a capacidade deste software SIG. Além disso, o QGIS permite integração com outros softwares, como o Grass GIS e o PostGIS;
- gvSIG: O gvSIG é um software livre que permite a aquisição, armazenamento, gerenciamento, manipulação, processamento, exibição e publicação de dados e informações geográficas, podendo trabalhar com diferentes formatos vectoriais e *raster*, bases de dados e serviços remotos.
- GRASS GIS: poderoso software GIS multiplataforma de código aberto usado para gerenciamento e análise de dados espaciais, processamento de imagem, produção de gráficos e mapas, modelagem espacial e visualização.

Câmara (1999) apresenta um resumo das principais funcionalidades dos GIS, que são descritos no Quadro 6.

Quadro 6 - Resumo das funcionalidades de alguns GIS.

SISTEMA	ANG	PDI	MNT	RED	BDG	MAP	GEO
ARC/VIEW	✓*	✓*	✓*	✓*	✓	✓	-
ARC/INFO	✓✓	-	✓	✓	✓✓	✓	-
AutoCAD Map	-	-	-	✓	✓	✓	-
EASI/PACE	-	✓✓	-	-	-	✓	✓
ENVI	-	✓	-	-	-	(✓)	-
ERDAS	✓	✓	✓	-	-	✓	✓
ER-Mapper	-	✓	-	-	-	✓	-
Idrisi	✓	✓	-	-	✓	(✓)	-
MapInfo	✓	-	✓*	-	✓	-	-
MGE	✓	✓	✓	✓	✓✓	✓✓	✓
SPRING	✓	✓✓	✓	-	✓	✓	-

Fonte: Adaptado de Câmara, 1999.

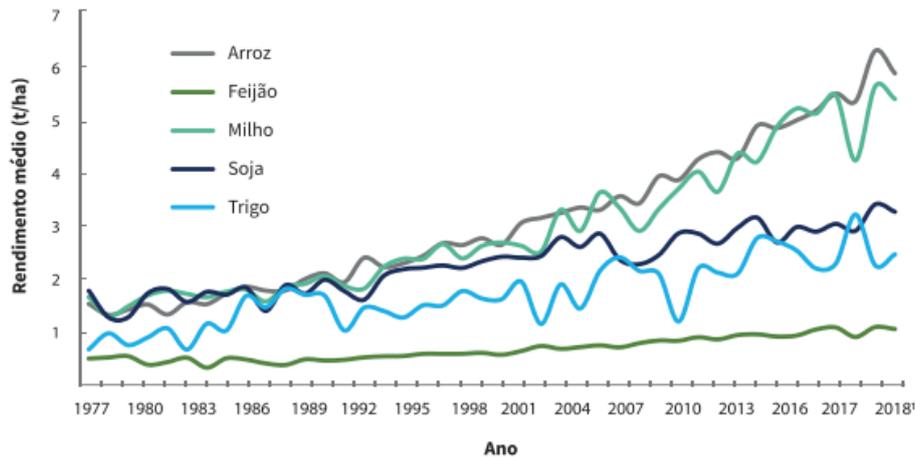
O Quadro 6, contém os códigos e símbolos que vão ser descritos para seu entendimento a seguir: ANG = análise geográfica, PDI = processamento digital de imagens, MNT = modelos numéricos de terreno, RED = modelagem de redes, MAP = produção cartográfica, GEO = geodésia e fotogrametria, BDG = consulta a bancos de dados georreferenciado. As legendas são: ✓✓ = disponível com vantagem técnica, ✓ = disponível (pacote básico), ✓* = disponível em módulos adicionais, (✓) = disponível com limitações, solução especial, - = não disponível.

2.6 AGRICULTURA NO BRASIL

Nos últimos 40 anos, o Brasil saiu da condição de importador de alimentos para se tornar um grande provedor para o mundo, e o país se tornou um dos principais jogadores do agronegócio mundial. A Figura 10, apresenta a evolução do rendimento médio em toneladas por hectare (arroz, feijão, milho, soja e trigo) no Brasil (todas as regiões) entre 1975 e 2017, com destaque para os aumentos de rendimento de arroz e milho (CONAB, 2018). A agricultura se modernizou, mas ainda existem desafios. Há

grande concentração de riqueza em áreas reduzidas das propriedades rurais, existem milhões de hectares de solos e pastagens degradados, há grande ineficiência no uso de água na irrigação, e o uso inadequado de agroquímicos oferece riscos à saúde e ao meio ambiente, entre outros problemas.

Figura 10 - Produção de grãos em todo o Brasil entre 1975 e 2017.



Fonte: CONAB, 2018.

Deve-se reconhecer que o que fez a diferença nestes últimos 50 anos foram os investimentos em pesquisa agrícola que trouxe avanços nas ciências, tecnologias adequadas e inovações, a assertividade de políticas públicas e a competência dos agricultores, convertendo o Brasil atualmente no principal exportador de: suco de laranja, açúcar, café e carnes bovina, suína e de aves, e o segundo maior de soja e milho. A safra 2015/2016 alcançou 196,5 milhões de toneladas e estima-se que deve chegar a 255 milhões de toneladas em dez anos (CONAB, 2018). As culturas de verão, principalmente soja, milho, arroz, feijão e sorgo (milho-zaburro), ocupam anualmente, na região Sul do Brasil, cerca de 13,5 milhões de hectares, sem considerar a área do milho safrinha no Paraná. Alguns dessas culturas serão descritas a seguir.

2.6.1 SOJA

Os primeiros cultivos comerciais de soja surgiram na década de 1960, no Rio Grande do Sul, especialmente por uma razão climática: a soja é uma planta de regiões

frias e os cultivos no mundo se limitavam às proximidades do paralelo 30, que no Brasil passa por Porto Alegre. Cultivar soja em outras regiões do país era um desafio biológico e tecnológico. Porém, com técnicas de melhoramento genético, foram desenvolvidas espécies de soja adequadas às condições de solo e clima do Brasil. Eram cultivos menos sensíveis aos dias longos e mais tolerantes às pragas do mundo tropical, permitindo o plantio nos solos de cerrados, que são justamente as áreas nas que a soja ganhou terreno na agropecuária nacional. Os cultivares plantados comercialmente no país tem seus ciclos, na maioria, oscilando entre 60 e 120 dias.



Nos anos 2017 e 2018, a cultura da Soja ocupou uma área de 35.100 milhões de hectares, o que totalizou uma produção de 116.996 milhões de toneladas (segundo maior produtor mundial do grão), tendo como maiores estados produtores os do Mato Grosso, Paraná e Rio Grande do Sul (CONAB, 2018).

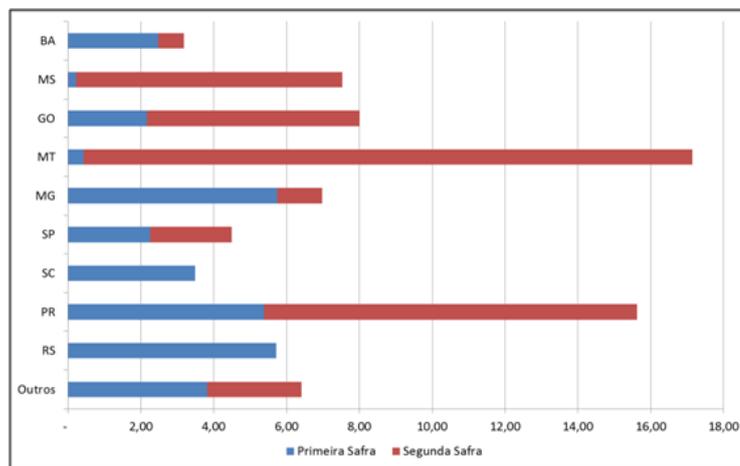
2.6.2 MILHO

A produção de milho no Brasil, juntamente com a de soja, contribui com cerca de 80% da produção de grãos e é caracterizada pelo plantio em duas épocas: primeira safra (ou safra de verão) e segunda safra (ou safrinha). Os plantios de verão são realizados em todos os estados e são colhidos com cerca de 160 a 180 dias após a semeadura, na época tradicional, durante o período chuvoso, que ocorre no final de agosto, na região Sul, até os meses de outubro/novembro, no Sudeste e Centro-Oeste. Na região Nordeste, esse período ocorre no início do ano (CONAB, 2018). A safrinha refere-se ao milho de sequeiro, plantado extemporaneamente, geralmente de janeiro a março ou até, no máximo, meados de abril, quase sempre depois da soja precoce e predominantemente na região Centro-Oeste e nos estados do Paraná, São Paulo e Minas Gerais.

Apesar das condições desfavoráveis de clima, os sistemas de produção da safrinha têm sido aprimorados e adaptados a essas condições, o que tem contribuído para elevar os rendimentos das lavouras também nessa época. Atualmente, existem no Brasil produtores que já estão obtendo rendimentos de milho superiores a 12 t/ha (200 sacos/ha) e ainda existem outros grupos de produtores que utilizam melhor tecnologia levando-os a produzirem acima de 14 t/ha.

Segundo dados da CONAB (2018) a área cultivada com o milho na primeira safra em 2013/2014 foi de 6.629,4 mil hectares, 2,3% menor que a de 2012/2013. Na segunda safra de 2014, foram plantados 8.836,5 mil hectares, ou seja, 33,2% a mais que a área plantada na primeira safra (Figura 11). Obtendo-se uma média nacional de 4.879 kg/ha, para a safra de 2013/2014, sendo 5,2% menor que a safra anterior, quando em 2012/2013 alcançou 5.149 kg/ha.

Figura 11 - Produção de milho por estado na safra 2013/2014 em milhões de toneladas.



Fonte: CONAB, 2018

2.6.3 ARROZ

O arroz se destaca pela produção e área de cultivo, desempenhando papel estratégico tanto em nível econômico quanto social. O arroz apresenta grande capacidade de adaptação a diferentes condições de solo e clima. São considerados dois grandes ecossistemas para a cultura: o de várzeas, irrigado por inundação controlada, mais comum na região Sul do Brasil, e o de terras altas, englobando todos os sistemas de cultivo de arroz no país.

A duração do ciclo do arroz é de 100 a 140 dias dependendo do cultivar. No Brasil, a maior parcela da produção de arroz do país é proveniente do ecossistema várzeas, onde a orizicultura (cultivo de arroz em lavouras) irrigada é responsável por 75% da produção nacional. Os estados de Rio Grande do Sul e Santa Catarina (região subtropical), cultivam ao redor de 63% do estoque nacional de arroz, que na safra 2016/2017 ficou em 12,3 milhões de toneladas (CONAB, 2018).

No ecossistema de várzeas o cultivo da soca (capacidade das plantas de regenerarem os perfilhos férteis após o corte dos colmos na colheita) tem se mostrado como uma das alternativas viáveis para aumentar a produtividade de grãos na região tropical. A soca de arroz apresenta menor duração do ciclo que um novo cultivo. No estado de Tocantins em áreas bem conduzidas tem-se obtido 22 sacas de 60 kg/ha, com um custo de produção equivalente de cinco a nove sacas, e com um ciclo ao redor de 55 dias (EMBRAPA, 2018).

Para obter êxito no cultivo da soca é necessário um planejamento do sistema de produção de arroz, compreendendo desde o estabelecimento do cultivo principal até a segunda colheita.

2.7 AGRICULTURA DE PRECISÃO

O Ministério da Agricultura, Pecuária e Abastecimento (MAPA), ao instituir a Comissão Brasileira de Agricultura de Precisão (CBAP), definiu a Agricultura de Precisão (AP) como “um sistema de gerenciamento agrícola baseada na variação espacial e temporal da unidade produtiva e visa ao aumento de retorno econômico, à sustentabilidade e à minimização do efeito ao ambiente” (BRASIL, 2012, p.6).

No livro “Agricultura de precisão – Resultados de um novo olhar” publicado pela EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária) se define a AP como “uma forma de gestão da lavoura que leva em conta a variabilidade espacial”. E que devesse recomendar somente se houver potencial de retorno econômico e ambiental e nesse caso é necessário que haja a variabilidade espacial. Quanto maior a diferença, maior a oportunidade de se obter retorno econômico ao se tratar adequadamente as características que as diferenciam (DE CAMPOS et al. 2014).

Um conceito diferente para a AP é apresentado em Liaghat e Balasundram (2010), que define-a como “um sistema agrícola integrado, baseado em informação e produção, concebido para aumentar a eficiência, produtividade e rentabilidade de longo prazo, específico do local e da exploração agrícola, evitando os efeitos indesejáveis do excesso de carga química no ambiente ou perda de produtividade devido à insuficiente aplicação de entrada e reduzindo a incerteza das decisões necessárias para gerenciar a variabilidade nas fazendas”.

Para finalizar as diferentes definições estipuladas para a AP, encontra-se a que envolve a geoestatística (estatística que considera a dependência espacial entre os dados) e que define a AP como “um sistema produtivo agrícola em que os erros podem ser tratados por meio de geoestatística” (DE CAMPOS et al. 2014).

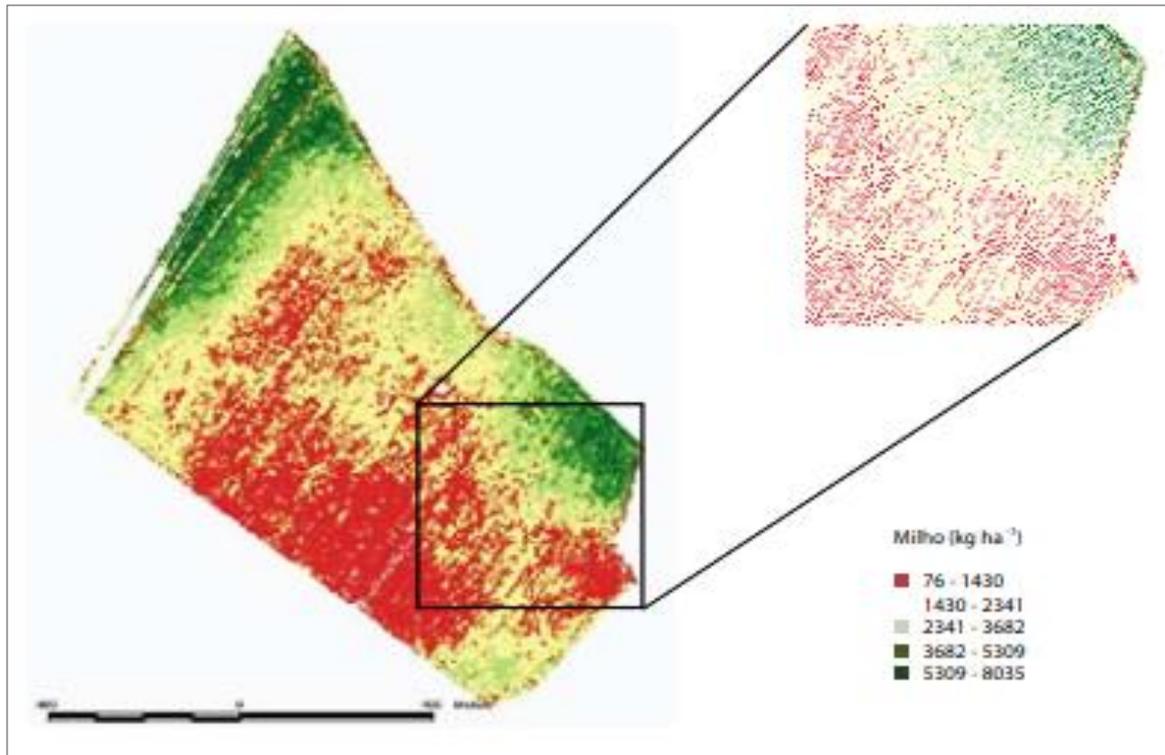
A agricultura de precisão (AP) tem várias formas de abordagem, é comum organizar e descrever a AP em três etapas: o início determinado pela leitura (levantamento e obtenção de dados), a etapa da interpretação dos dados para planejamento das operações de campo e a etapa de atuação ou de execução do planejamento. O objetivo é sempre o mesmo, utilizar estratégias para resolver os problemas da desuniformidade das lavouras e se possível tirar proveito delas. O desenvolvimento de novas tecnologias (Sensores remotos, GNSS, Satélites, Veículos aéreos não tripulados) e o incremento na necessidade de maior uso de insumos agrícolas tem incentivado as aplicações e estudos na agricultura de precisão.

2.7.1 A AGRICULTURA DE PRECISÃO NO BRASIL

Hoje em dia, no Brasil, as soluções existentes estão focadas na aplicação de fertilizantes e corretivos (insumos) em taxa variável. Ainda não se vê comercialmente a aplicação de sementes e agroquímicos em geral, mas um dos grandes avanços que se pode destacar é a gestão da lavoura. Reconhecer a variabilidade como o primeiro passo antes mesmo de iniciar investimentos em Agricultura de Precisão. Porém não se deve perder de vista que a AP é um sistema de gestão que considera a variabilidade espacial das lavouras em todos seus aspectos: produtividade, solo (características físicas, químicas, compactação etc.), infestação de ervas daninhas, doenças e pragas.

A busca por maiores produtividades com o uso de AP implica em estratégias mais elaboradas que normalmente estão associadas a aqueles usuários que dispõem de mapas de produtividade (Figura 12). O mapa de produtividade materializa a resposta da cultura com a melhor exatidão possível.

Figura 12 - Mapa de produtividade em um talhão.



Fonte: MAPA, 2009

Observa-se na Figura 12 um mapa de produtividade gerado pelos dados obtidos pela colhedora como um conjunto de pontos; cada ponto representa uma pequena área da lavoura delimitada pela largura da plataforma da colhedora (elevador de grãos limpos com sensor de fluxo e sensor de humidade), com intervalos de 2 a 3 segundos. Os mapas de produtividade são de primeira importância, não somente porque mostram a variabilidade das lavouras, mas também porque dão uma abordagem mais correta para a recomendação de adubação (fertilização) do ciclo seguinte, levando-se em consideração a produtividade da cultura anterior para se fazer a reposição dos nutrientes extraídos.

Além dos mapas de produtividade existem outras medidas úteis para atenuar a falta de dados sobre as parcelas, como: mapas de condutividade elétrica aparente do solo, imagens da superfície (de satélite, drones ou sensores próximos) e técnicas de topografia (paisagem). Podem indicar indiretamente como ocorre a variabilidade da lavoura.

Existem avanços recentes enquanto à aplicação de fertilizantes, como é o caso dos do tipo nitrogenados, aplicados em taxa variável com base na refletância das plantas em determinados comprimentos de ondas. Assim, também se

desenvolvem técnicas para mensurar alguma característica de planta ou de solo. O indicador com mais potencial para expressar as deficiências das plantas ou dos solos tem sido a refletância da luz incidente, especialmente na região do visível e do infravermelho próximo (MAPA, 2009).

Várias outras ferramentas têm sido propostas para se identificar as manchas existentes em um talhão. É assim que as fotografias aéreas, as imagens de satélite, e outras têm sido testadas e utilizadas. O sensoriamento remoto (SR) tem sido utilizado para avaliar as condições das culturas em relação ao nitrogênio, incidência de pragas, invasoras e doenças (MAPA, 2009).

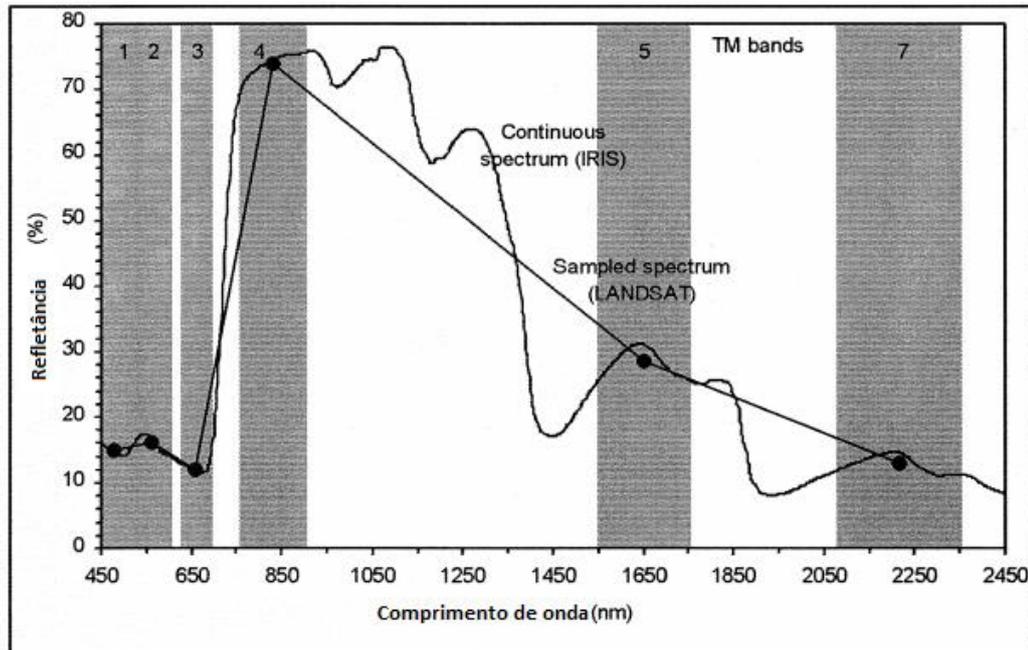
2.8 ASSINATURAS ESPECTRAIS DA VEGETAÇÃO

Vários estudos foram realizados para determinar os parâmetros da vegetação no solo por sensoriamento remoto, utilizando as características espectrais da refletância foliar. A quantidade de energia que é absorvida em um comprimento de onda específico caracterizará uma feição espectral de absorção que se mostrará como uma assinatura espectral da composição daquele material. A maneira prática que se tem para identificar em quais comprimentos de onda ocorrem as feições de absorção, é por meio de medições dos espectros de refletância, feitas em laboratórios ou no campo. Para se obter essas medidas usam-se os espectrorradiômetros, que são instrumentos que plotam na forma de gráficos (Figura 13), a intensidade da energia refletida por unidade de comprimento de onda (assinatura espectral).

Outra fonte de medição refletância por comprimento de onda (bandas de um sensor) são os sensores imageadores, que configuram a imagem dos objetos em níveis de cinza, onde os valores de cinza claros representam alvos com alta refletância e os valores de cinza escuros representam alvos com baixa refletância. Através do uso dos GIS é factível a obtenção dos gráficos de assinaturas espectrais nos valores de porcentagem de refletância dos alvos que sejam de interesse de estudo. Pode-se observar na Figura 13 o contraste entre os dados de refletância medidos com um espectrômetro (GER IRIS) e os valores correspondentes em cada uma das bandas do satélite Landsat TM (Thematic mapper). Nota-se que dados consideráveis são perdidos e que as características espectrais mais variáveis da vegetação não são mais discerníveis pelos sensores de menor resolução espectral. Embora as poucas

faixas de informações dos sensores tipo Landsat TM ainda possam ser úteis para a discriminação da vegetação, será difícil discriminar entre espécies que apresentem refletância muito semelhante.

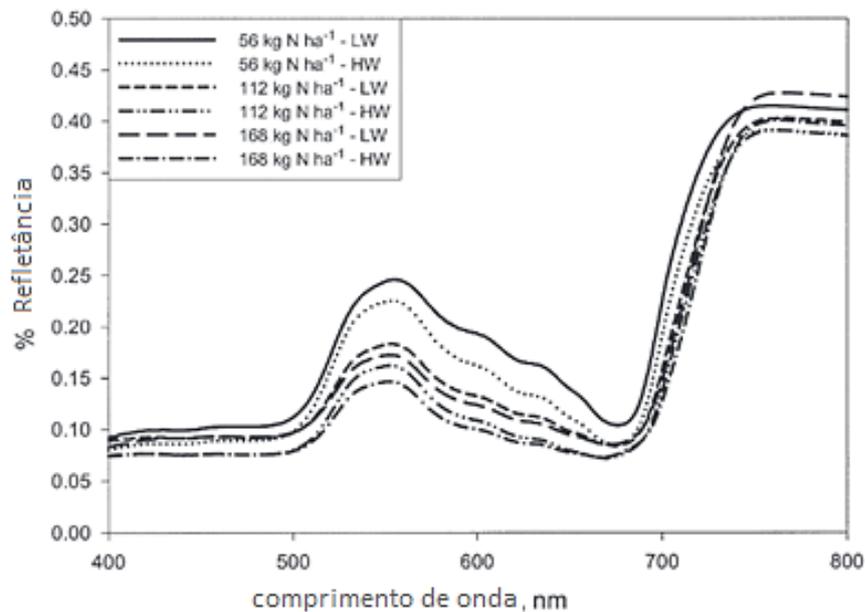
Figura 13 – Comparação da assinatura espectral obtida com um espectrômetro (GER IRIS) (linha curva) e com o satélite Landsat TM (linha reta).



Fonte: Kumar, 1974

As assinaturas espectrais das culturas podem ser utilizadas na determinação do conteúdo de nutrientes, como é mostrado em Schlemmer et al. (2005) para um estudo de conteúdo de nitrogênio em uma cultura de milho com diferentes conteúdos de água. Na Figura 14, se observam as diferenças nas assinaturas para estresse hídrico (LW - *low water*) e conteúdo de humidade elevado (HW - *high water*) com diferentes doses de nitrogênio. No caso da assinatura da cultura com baixo conteúdo de nitrogênio, observa-se respostas elevadas da refletância na faixa do visível para baixo conteúdo de nitrogênio e água.

Figura 14 - Assinaturas espectrais de uma plantação de milho considerando-se a aplicação de nitrogênio.



Fonte: Schlemmer et al. (2005).

Segundo Pinter et al. (2003), a quantidade de radiação refletida das plantas é inversamente relacionada com a radiação absorvida pelos pigmentos das plantas e varia com o comprimento de onda da radiação incidente. Pigmentos vegetais como clorofila absorvem radiação fortemente no espectro visível de 400 a 700 nm (430 e 660 para clorofila-a, 450 e 650 para clorofila-b). Em contraste, a refletância da planta é alta na região do infravermelho próximo (NIR 700 e 1300 nm) como resultado da densidade das folhas e dos efeitos da estrutura da copa.

A variação acentuada no comportamento de refletância entre o vermelho e as porções NIR do espectro é a motivação para o desenvolvimento de índices espectrais que são baseados em razões de valores de refletância nas regiões visíveis e NIR.

2.9 ÍNDICES DE VEGETAÇÃO

Barbosa (2006) define os índices de vegetação (VIs) como modelos matemáticos desenvolvidos para avaliar as características da superfície imageada, que relacionam a assinatura espectral e os parâmetros mensuráveis no campo tanto quantitativamente quanto qualitativamente. Assim Xiu e Sue (2017) definem aos VIs

como algoritmos bastante simples e eficazes para avaliações quantitativas e qualitativas do vigor, dinâmica de crescimento, e outras características da cobertura vegetal.

Por serem modelos matemáticos ou algoritmos, os índices são descritos através de equações, que são determinadas em base à banda (faixa do espectro) que apresenta interesse. O reconhecimento e diferenciação da utilidade de um índice ou outro pode ser feito depois da análise da assinatura espectral dos alvos.

O cálculo dos índices de vegetação é realizado diretamente pelos sistemas de informação geográfica (GIS), que usando as equações próprias de cada índice, transformam as bandas das imagens gerando uma imagem com valores em uma escala interpretável pelo usuário. Muitos índices espectrais estão disponíveis para uso em agricultura de precisão. O Quadro 7 exhibe alguns dos índices amplamente utilizados e sua respectiva definição (equação), fazendo referência as faixas do espectro (bandas espectrais) nas quais atua. A maioria dos índices mostra o comportamento nas bandas do verde, vermelho e infravermelho (G-*Green*, R-*Red*, NIR-*Near infrared*).

Quadro 7. Índices de vegetação comumente usados na AP.

Índice	Definição
NG	$G/(NIR + R + G)$
NR	$R/(NIR + R + G)$
RVI	NIR/R
GRVI	NIR/G
DVI	$NIR - R$
GDVI	$NIR - G$
NDVI	$(NIR - R)/(NIR + R)$
GNDVI	$(NIR - G)/(NIR + G)$
SAVI	$1.5 * [(NIR - R)/(NIR + R + 0.5)]$
GSAVI	$1.5 * [(NIR - G)/(NIR + G + 0.5)]$
OSAVI	$(NIR - R)/(NIR + R + 0.16)$
GOSAVI	$(NIR - G)/(NIR + G + 0.16)$
MSAVI2	$0.5 * [2 * (NIR + 1) - \sqrt{4 * (NIR + 1)^2 - 8 * (NIR - R)}]$

Fonte: Mulla, 2013

Cada uma das abreviaturas feitas no Quadro 7, é explicada a seguir:

- NG: *Normalized green index* (Índice normalizado verde);
- NR: *Normalized red index* (Índice normalizado vermelho);
- RVI: *Ratio vegetation index* (Índice de vegetação de proporção);
- GRVI: *Green red vegetation index* (Índice de vegetação verde vermelho);
- DVI: *Difference vegetative index* (Índice vegetativo da diferença);

- GDVI: *Green difference vegetation index* (Índice de vegetação de diferença verde);
- NDVI: *Normalized difference vegetation index* (Índice Diferencial da Vegetação Normalizado);
- EVI: *Enhanced Vegetation Index* (Índice de vegetação aprimorado);
- GNDVI: *Green normalized difference vegetation index* (Índice de vegetação de diferença normalizado verde);
- SAVI: *Soil adjusted vegetation index* (Índice de vegetação ajustado ao solo);
- GSAVI: *Green soil adjusted vegetation index* (Índice de vegetação ajustada ao solo verde);
- OSAVI: *Optimized soil adjusted vegetation index* (Índice de vegetação ajustado ao solo otimizado);
- GOSAVI: *Green optimized soil adjusted vegetation index* (Índice de vegetação ajustado ao solo otimizado em verde);
- MSAVI2: *Modified soil adjusted vegetation index* (Índice ajustado de vegetação do solo modificado).

O comportamento da vegetação nas imagens de sensoriamento remoto é interpretado principalmente pelas diferenças e alterações das folhas verdes das plantas e pelas características espectrais do dossel. O processo de validação mais comum é através de correlações diretas ou indiretas entre os VIs obtidos e as características da vegetação de interesse medidas in situ, como a cobertura vegetal (XIU e SUE, 2017). Nesta pesquisa procurou-se a obtenção dos índices de vegetação NDVI, GNDVI, EVI e SAVI, os quais serão detalhados a seguir.

2.9.1 ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADA (NDVI).

O NDVI é o índice de vegetação mais comumente utilizado na hora de analisar o vigor da vegetação. Segundo Rouse et al. (1973), este índice é um dos mais antigos, mais conhecidos e usados com maior frequência. A combinação de sua formulação de diferenças normalizadas e o uso das regiões de absorção e refletância mais altas da clorofila (NIR e R) o tornam útil em uma ampla gama de condições, tendo uma

resposta sensível à vegetação verde, mesmo em áreas cobertas por vegetação baixa. Porém, pode se saturar em condições de vegetação densa quando o LAI (índice de área foliar) se torna alto. A equação 1 apresenta a fórmula para obter o NDVI, o termo NIR é o correspondente à faixa do infravermelho próximo e o R é o correspondente à faixa do vermelho.

$$NDVI = \frac{NIR-R}{NIR+R} \quad (1)$$

No entanto, o NDVI é sensível aos efeitos do brilho do solo, cor do solo, atmosfera, sombra de nuvem e sombra do dossel das folhas e requer calibração do sensor (XIU e SUE, 2017). A abordagem do NDVI baseia-se no fato de que a vegetação saudável tem baixa refletância na porção visível do espectro devido à clorofila e à absorção de outros pigmentos, e tem alta refletância no NIR devido à refletância interna pelo tecido mesófilo esponjoso da folha verde. Os cálculos de NDVI para um determinado pixel sempre resultam em um número que varia de menos um (-1) a mais um (+1). Destes, apenas os valores positivos correspondem a áreas de vegetação, valores próximos de zero não significam vegetação e valores negativos pertencem a nuvens, neve, água, áreas de solo descoberto e rochas.

2.9.2 ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA VERDE (GNDVI).

O índice de vegetação da diferença normalizada verde (GNDVI) é proposto para avaliar a variação do dossel na biomassa das culturas, é uma variante do NDVI que usa a faixa verde em vez da vermelha (KEMERER, 2007). O GNDVI pode ser atribuído à senescência das culturas devido ao estresse ou maturidade. O GNDVI indicou maior sensibilidade a variações no teor de clorofila foliar do que em outros índices (SHANAHAN et al. 2001). No trabalho de Pradhan, Bandyopadhyay e Josh (2012) o GNDVI mostrou melhores resultados que o NDVI para prever a biomassa e a produtividade de grãos do trigo.

Os valores lançados por este índice também variam entre -1 e 1. Os valores entre -1 e 0 estão associados à presença de água ou solo descoberto. Este índice é usado principalmente no estágio intermediário e final do ciclo das culturas, sua fórmula está descrita na equação 2.

$$GNDVI = \frac{NIR-G}{NIR+G} \quad (2)$$

2.9.3 ÍNDICE DE VEGETAÇÃO AJUSTADA PELO SOLO (SAVI).

Como mostrado anteriormente, o NDVI (1) é muito sensível a fatores de fundo, como o brilho e a sombra dos dosséis da vegetação e o brilho do fundo do solo. Dado o efeito do fundo do solo, a radiação R aumenta significativamente quando a cobertura vegetal é escassa; inversamente, a radiação NIR é reduzida para tornar mais sensível a relação entre vegetação e solo (XIU e SUE, 2017). Tendo isto em conta, muitos VIs foram desenvolvidos para se ajustar ao efeito do solo.

Huete (1988) propôs um índice de vegetação ajustado ao solo (SAVI), para reduzir o impacto no NDVI das variações de solo em áreas de cobertura vegetal inferior. O SAVI foi considerado um passo importante para o estabelecimento de um modelo "global" simples que pode descrever sistemas dinâmicos de solo-vegetação a partir de dados de sensoriamento remoto. A equação 3 mostra a fórmula para o cálculo do SAVI.

$$SAVI = (1 + L) * \frac{NIR-R}{NIR+R+L} \quad (3)$$

Onde L é o índice de condicionamento do solo, que melhora a sensibilidade do NDVI ao fundo do solo. A faixa de L é de 0 a 1. Em aplicações práticas, os valores de L são determinados de acordo com as condições ambientais específicas. Portanto L varia de 0 para cobertura vegetal muito alta a 1 para cobertura vegetal muito baixa. O valor mais usado é 0,5, que é para cobertura vegetal intermediária.

2.9.4 ÍNDICE DE VEGETAÇÃO APRIMORADO (EVI).

Liu e Huete (1995) analisaram exaustivamente vários tipos de solo e VIs atmosféricamente aprimorados, introduzindo assim, um parâmetro para corrigir simultaneamente os efeitos do solo e da atmosfera, otimizando o sinal da vegetação com melhor sensibilidade em regiões de alta biomassa. Este parâmetro é o índice de vegetação aprimorado (EVI), que pode ser expressado na equação 4.

$$EVI = G \frac{(NIR-R)}{(NIR+C1*R-C2*B+L)} \quad (4)$$

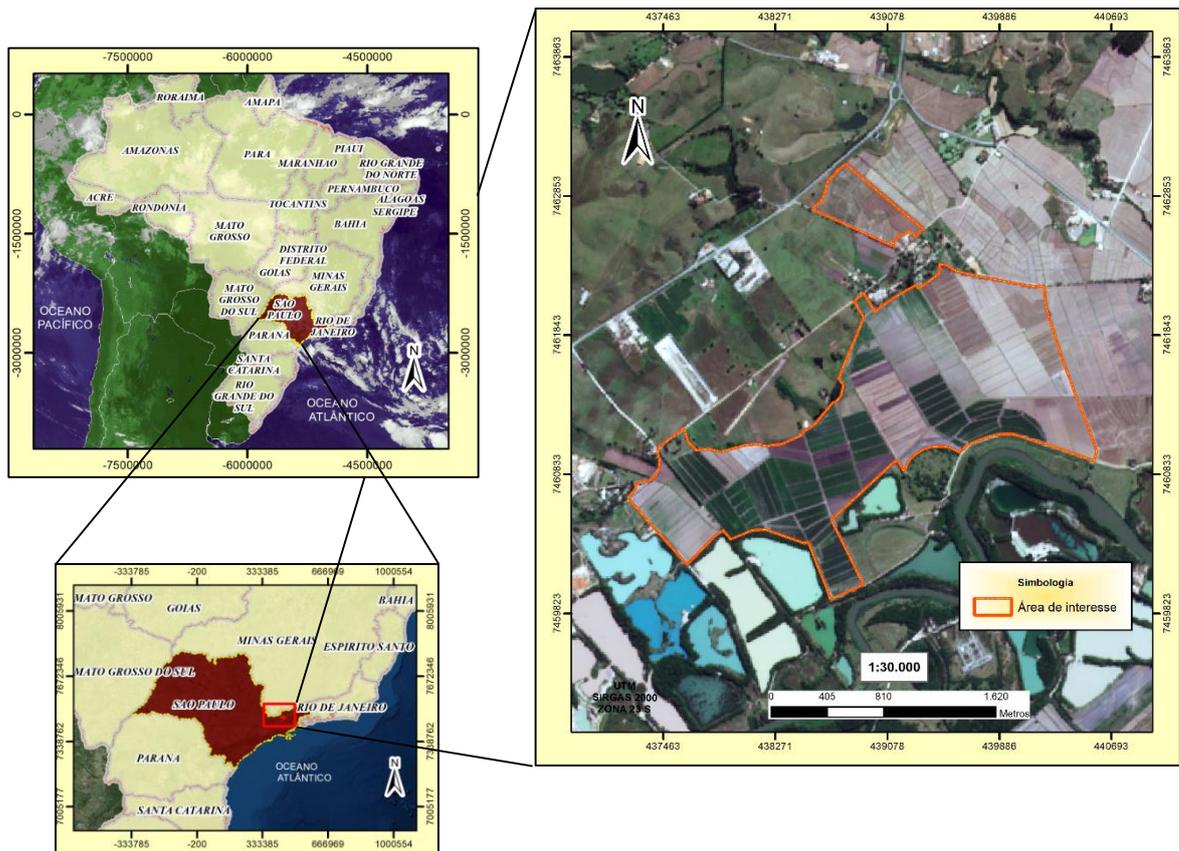
A equação 4, inclui os valores das bandas das faixas NIR (*near infrared*), R (*red*) e B (*blue*), que são corrigidos para a atmosfera; L representa parâmetros empíricos de ajuste do solo e seu valor é igual a 1; e os parâmetros que correspondem às constantes C1 e C2 (são os coeficientes do termo de resistência ao aerossol) que são equivalentes a 6 e 7,5 respectivamente; por último, o termo G, faz referência ao fator de ganho equivalente a 2,5.

3 MATERIAIS E MÉTODOS

3.1 DESCRIÇÃO DA ÁREA DE ESTUDO

A área escolhida para esta pesquisa é uma plantação de cerca de 320 hectares (distribuídas nas culturas de milho, arroz e soja), que se situa na cidade de Tremembé (estado de São Paulo - Brasil), sendo escolhida pela facilidade de acesso aos dados dos produtores que mantêm um contato próximo com os alunos da faculdade de Engenharia Civil da Universidade Presbiteriana Mackenzie. A Figura 15 apresenta a localização da área no estado de São Paulo.

Figura 15 - Localização da área de estudo (demarcada em laranja) na cidade de Tremembé.



Fonte: Elaboração própria

A plantação encontra-se localizada próxima à Serra da Cantareira, nas coordenadas UTM (Universal Transversal Mercator) de 438.814.90 m E, 7.461.118.52 m N para o sistema de referência SIRGAS 2000 (Sistema de Referência Geocêntrico

para as Américas) zona 23 Sul. O setor possui vegetações características de mata atlântica e temperaturas que vão desde 12 °C a 31 °C. Tremembé tem a estação de maior precipitação aproximadamente de outubro a abril, e a estação seca de abril a outubro. O mês mais seco é julho, com precipitações aproximadas de 21 mm, como contraste a maioria da precipitação cai em janeiro, com uma média de 238 mm aproximadamente (MATARAZZO, 2012).

A análise abrange as zonas de lavoura de Milho, Arroz e Soja, que variam com a época do ano, e são semeadas nos ciclos de verão, sendo os meses de desenvolvimento de novembro a março. Com base nisso foram utilizadas as imagens dos satélites Sentinel-2, CBERS-4 e Landsat-8, para comparar os ciclos de semeadura do verão (novembro a março) de 2017/2018 e 2018/2019 de toda a plantação. Obtendo os diferentes índices de vegetação (NDVI, GNDVI, SAVI, EVI) calculados para os dois ciclos de semeadura e para o conjunto de imagens dos 3 satélites. Além disso, a proposta desta pesquisa é a análise das assinaturas espectrais dos três tipos de culturas (milho, arroz e soja) usando as imagens Sentinel-2 visto que são as imagens com o maior número de bandas e as únicas que apresentam a região do redEdge (600 a 800 nm). O Quadro 8 mostra um resumo de algumas das características do setor de estudo.

Quadro 8. Resumo das características da zona de estudo.

Característica	Descrição
Área de semeadura	320 ha
Ciclos de semeadura da análise	2017/2018 2018/2019
Meses de análise	Novembro a março
Meses de chuvas	Outubro a abril
Temperatura do setor	12 a 31°C
Coordenada Leste	438.814,90 m
Coordenada Norte	7.461.118,52 m
Elevação (nível do mar)	560 m

Fonte: Elaboração própria

Com o apoio dos registros de semeadura, fornecidos pelos agricultores, e as imagens de satélite, foi elaborado o Quadro 9, que explica a rotação das culturas para os ciclos de semeadura 2017/2018 e 2018/2019 (meses de novembro a março). Com o objetivo de melhorar o entendimento da distribuição das culturas na área de estudo, se propõe a divisão em 12 parcelas (Figura 16) as quais serão diferenciadas por estarem espacialmente separadas por diferentes combinações das culturas de milho, arroz e soja.

Figura 16 – Distribuição das parcelas (milho - polígonos em verde, arroz - polígonos em azul e soja - polígonos em amarelo) na área de estudo (a imagem de fundo é uma combinação de bandas RGB do Sentinel-2 para o mês de novembro 2017).



Fonte: Elaboração própria

A Figura 16 indica a subdivisão da área de semeadura em 12 parcelas ou zonas de análises (1a, 1b, 1c, 1d, 2, 3, 4, 5, 6, 7, 8, 9a, 9b, 10, 11 e 12), considerando-se a variedade mensal das culturas e a localização na plantação.

Quadro 9. Resumo da rotação das culturas na área de estudo (a linha pontilhada separa os ciclos de verão a serem comparados).

Parcela	2017		2018			2018		2019		
	Novembro	Dezembro	Janeiro	Fevereiro	Março	Novembro	Dezembro	Janeiro	Fevereiro	Março
1a	Arroz	Arroz	T G	Soca	Soca	Arroz	Arroz	Arroz	Arroz	Arroz
1b	Arroz	Arroz	Arroz	Arroz	Soca	Arroz	Arroz	Arroz	Arroz	Arroz
1c	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz
1d	Arroz	Arroz	Arroz	Arroz	Soca	Arroz	Arroz	Arroz	Arroz	Arroz
2	Soja	Soja	Soja	Soja	T G	T G	Soja	Soja	Soja	T G
3	Soja	Soja	Soja	Soja	T G	T G	Soja	Soja	Soja	T G
4	Milho	Milho	Milho	Milho	T G	T G	Milho	Milho	Milho	T G
5	Soja	Soja	Soja	Soja	T G	Soja	Soja	Soja	Soja	T G
6	Milho	Colhido	Milho	Milho	T G	Soja	Soja	Soja	Soja	T G
7	Arroz	Arroz	Arroz	Arroz	T G	T G	Arroz	Arroz	Arroz	Arroz
8	Milho	Milho	Milho	Milho	T G	Milho	Milho	Milho	Milho	Milho
9a	Milho	Milho	Milho	Milho	Milho	Milho	Milho	Milho	Milho	Milho
9b	Milho	Milho	Milho	Milho	Milho	Milho	Milho	T G	Milho	Milho
10a	Milho	Milho	T G	Milho	Milho	Soca	T G	Milho	Milho	Milho
10b	Arroz	Arroz	Arroz	Soca**	Soca	Arroz	Arroz	Soca	Soca	Soca
10c	Arroz	Arroz	Arroz	Arroz	Soca	Arroz	Arroz	Soca	Soca	Soca
10d	Arroz	Arroz	Arroz	T G	T G	Arroz	Arroz	Arroz	Arroz	Soca
11	T G*	Soja	Soja	Soja	Colhido	Soja	Soja	Soja	Soja	T G
12	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz	Arroz	Soca	Soca	Soca

*TG: termo que indica terra gradeada, ou gradagem, feito como preparo para a próxima semeadura no período da colheita.

**Soca: termo que faz referência a plantação restante do arroz após a primeira colheita.

Fonte: Elaboração própria

3.2 INSTRUMENTAÇÃO

Existem algumas diferenças nas características das imagens das plataformas de satélite, dadas nas resoluções espaciais, espectrais, radiométricas e temporais. O sensor MSI (*Multi-Spectral Imager*) do Sentinel-2, o sensor OLI (*Operational Land Imager*) do Landsat-8 e a Câmera Multiespectral Regular (MUX) do CBERS-4, são semelhantes em algumas das faixas que cobrem do espectro eletromagnético, mas possuem diferentes resoluções temporais, espectrais e espaciais, e seus dados têm diferentes níveis de correção radiométrica e atmosférica.

As bandas do Sentinel-2, Landsat-8 e CBERS-4 possuem comprimentos de onda análogos entre eles, conforme mostrado no Quadro 10.

Quadro 10. Bandas espectrais equivalentes para os sensores OLI, MSI e MUX.

# Banda	Comprimento de onda central (nm)			Largura de banda (nm)			Resolução espacial (m)		
	S2	L8	C4	S2	L8	C4	S2	L8	C4
1 - Aerossol	443	443		20	16		60	30	
2 - Blue	490	482	485	65	60	70	10	30	20
3 - Green	560	561	555	35	57	70	10	30	20
4 - Red	665	654	660	30	37	60	10	30	20
5 - redEdge	705			15			20		
6 - redEdge	740			15			20		
7 - redEdge	783			20			20		
8 - NIR	842	864	830	115	28	120	10	30	20
8A - redEdge	865			20			20		
9 - WV*	945			20			60		
10 - Cirrus	1375	1373		30	20		60	30	
11 - SWIR	1610	1609		90	84		20	30	
12 - SWIR	2190	2200		180	186		20	30	

*Water vapor

Fonte: Adaptado de Barsi et al. 2014.

No Quadro 10 são descritos os comprimentos de onda centrais, a largura da faixa do espectro e as resoluções espaciais para os satélites Sentinel-2 (S2), Landsat-8 (L8) e CBERS-4 (C4). O MSI do S2 cobre 13 bandas espectrais (443-2190 nm), sendo descritas assim: B1 - costal aerossol, B2 - blue, B3 - green, B4 - red, B5 - vegetation redEdge, B6 - vegetation redEdge, B7- vegetation redEdge, B8 - NIR, B8A - vegetation redEdge, B9- water vapour, B10- cirrus, B11-SWIR, B12-SWIR.

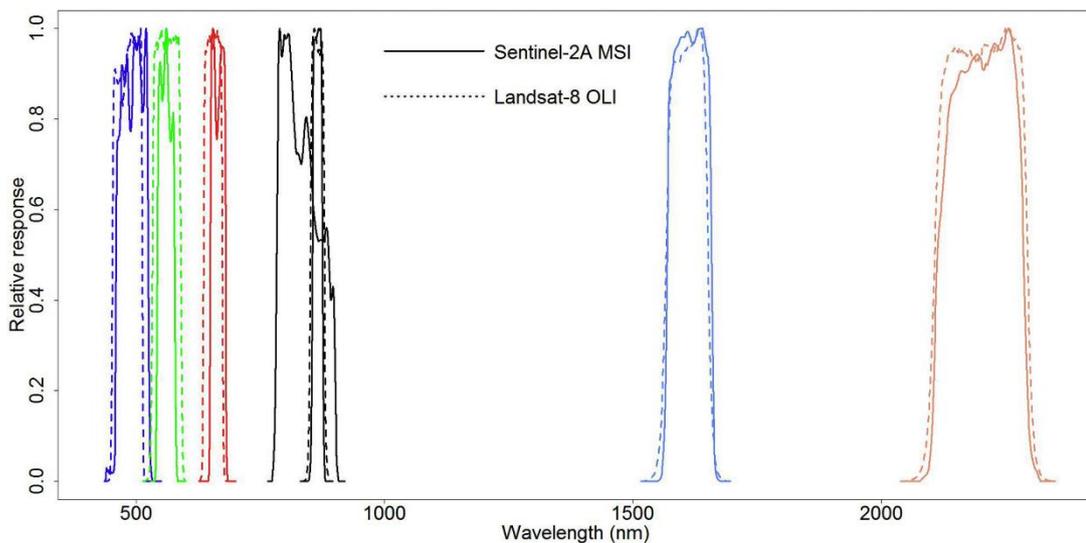
Ao mesmo tempo, o sensor OLI do satélite Landsat-8 cobre 11 bandas espectrais (443-2200 nm): B1 - costal aerossol, B2 - blue, B3 - green, B4 - red, B5 – NIR, B6 – SWIR 1, B7- SWIR 2, B8 – panchromatic, B9- cirrus, B10- termal infrared (TIRS 1), B11- termal infrared (TIRS 2). O Quadro 10 indica somente 8 dessas bandas, excluindo as bandas da faixa térmica.

No caso do sensor MUX do CBERS-4, o mesmo apresenta 4 bandas (450 - 890 nm) que cobrem a faixas do visível e do infravermelho próximo (NIR): B4 - blue, B5 - green, B6 - red, B7 – NIR.

A Figura 17 mostra a resposta espectral equivalente dos sensores OLI (L8) e MSI (S2) e a Figura 18 mostra a comparação da resposta espectral dos sensores OLI (L8) e MUX (C4).

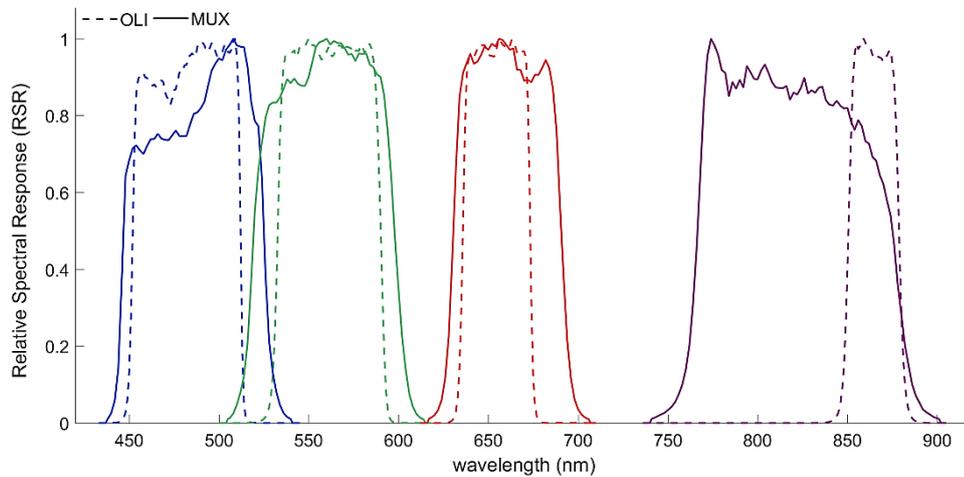
O tempo de revisitação das plataformas de satélite CBERS-4, Landsat-8, e Sentinel-2 é 26, 16 e 5 dias, respectivamente, o que permite a disponibilidade de observações espalhadas ao longo do tempo, úteis no caso do monitoramento dos recursos naturais.

Figura 17 – Comparação da resposta espectral dos sensores OLI (linhas pontilhadas) e MSI.



Fonte: Zhang et al. 2018

Figura 18 – Comparação da resposta espectral dos sensores OLI (linhas pontilhadas) e MUX.



Fonte: Martins et al. 2018

3.3 OBTENÇÃO E PROCESSAMENTO DE DADOS

Nesta pesquisa foram utilizadas diferentes imagens multiespectrais dos satélites Sentinel-2, CBERS-4 e Landsat-8, para o período de semeadura de verão dos meses de novembro a março das safras 2017/2018 e 2018/2019. As imagens processadas foram 5 para cada um dos satélites estudados, tendo assim uma imagem por mês, a exceção do Sentinel-2 que não apresentou imagens sem cobertura de nuvens da área para o mês de dezembro de 2017.

Os produtos Sentinel-2 são de acesso livre e estão disponíveis através da plataforma web OpenHub da ESA (European Spatial Agency) (<https://scihub.copernicus.eu/>), as imagens são disponibilizadas no nível de processamento L1C (Nível-1C) que significa que os valores dos ND das imagens foram geométrica, radiométrica e atmosféricamente corrigidos ao Top of Atmosphere (topo da atmosfera – TOA) e, portanto, devem ser corrigidos ao Bottom of Atmosphere (base da atmosfera – BOA).

Com relação às imagens do Landsat-8, estão disponíveis no site EarthExplorer, que fornece acesso gratuito a produtos processados de nível L2A (no site <https://earthexplorer.usgs.gov>), que possuem correção geométrica, radiométrica e atmosférica, aplicando o método de correção física Landsat Surface Reflectance

Code (LaSRC). Esse método usa os valores de captura de informação do sensor OLI e observações por satélite dos instrumentos MODIS (Moderate Resolution Imaging Spectroradiometer) a bordo dos satélites Terra e Aqua, na correção dos efeitos atmosféricos, apresentando os níveis digitais da imagem em valores de refletância da superfície (BOA) escalados (USGS, 2009).

No que se refere as imagens do satélite CBERS-4, foram adquiridas através do download gratuito no catálogo de imagens do Instituto Nacional de Pesquisas Espaciais - INPE (disponíveis em <http://www.dgi.inpe.br/catalogo/>), as imagens são fornecidas em nível 4 com correção geométrica (precisão subpixel) e atmosférica no nível TOA (MARTINS, et al., 2018).

O Quadro 11 apresenta um resumo das imagens processadas para o cálculo dos índices de vegetação (NDVI, GNDVI, EVI, SAVI) e no caso das imagens do Sentinel-2 para a obtenção das assinaturas espectrais.

Quadro 11- Imagens Sentinel-2, CBERS 4 e Landsat-8 a serem usadas na pesquisa.

Mês/Ano	Sentinel-2	CBERS 4	Landsat-8
Novembro/2017	13/11/2017	16/11/2017	15/11/2017
Dezembro/2017	N/A	15/12/2017	17/12/2017
Janeiro/2018	17/01/2018	10/01/2018	18/01/2018
Fevereiro/2018	11/02/2018	28/02/2018	12/02/2018
Março/2018	28/03/2018	29/03/2018 (I)	16/03/2018
Novembro/2018	13/11/2018	15/11/2018	11/11/2018
Dezembro/2018	13/12/2018	11/12/2018	13/12/2018
Janeiro/2019	17/01/2019	06/01/2019	21/01/2019
Fevereiro/2019	01/02/2019	01/02/2019	22/02/2019
Março/2019	23/03/2019	25/03/2019	26/03/2019

Fonte: Elaboração própria.

No Quadro 11 o termo N/A foi colocado para aquelas imagens que não foram possíveis de incluir no estudo por causa do excesso de cobertura de nuvens na área de interesse e no caso da imagem do mês de março de 2018 (I) do CBERS-4, apresenta somente uma porção da zona de estudo, porém foi usada considerando só os pontos coincidentes com as parcelas em análise.

Na execução das análises correspondentes às imagens, utilizou-se o software QGIS versão 3.2. O pré-processamento (correção atmosférica e georreferenciação), obtenção dos valores de refletância espectral e cálculo dos índices NDVI, GNDVI,

SAVI e EVI foram feitos através do *plugin semi-automatic classification* (SCP) e a ferramenta *raster calculator* (calculadora de imagem).

Usando o plug-in SCP foi feito o processo para correção atmosférica com a finalidade de obter os valores de refletância na base da atmosfera (BOA) aplicando o método de correção da subtração de objeto escuro (DOS1) no caso das imagens dos satélites Sentinel-2 e CBERS-4. As imagens do Landsat-8 não precisam dessa correção, mas devem ser redimensionadas a valores físicos de refletância. Sabemos que uma das fontes de erro que pode alterar completamente a imagem radiometricamente é a atmosfera, mudando o brilho medido na imagem de duas maneiras: como refletor, adicionando brilho extra ao sinal e como absorvedor, atenuando a intensidade da energia iluminando o alvo na superfície. O método de correção atmosférica DOS1 usa as equações (5), (6) e (7) para transformar os ND das imagens em valores de físicos de refletância (BOA), o método DOS1 não é um método físico e, portanto, usa os parâmetros contidos no arquivo de metadados (que contém os valores de calibração radiométrica do satélite) para realizar a correção (ESA, 2015).

$$L_{DO1\%} = \frac{0.01[(ESUN\lambda * \cos \theta_s * T_z) + E_{down}] * T_v}{\pi * d^2} \quad (5)$$

$$L_p = L_{min} - L_{DO1\%} \quad (6)$$

$$\rho = \frac{[\pi * (L_\lambda - L_p) * d^2]}{ESUN\lambda * \cos \theta_s} \quad (7)$$

Onde: L_λ = Radiação espectral no sensor (Radiância no satélite); L_p = Radiância do caminho; L_{min} = Radiância obtida com o valor da contagem digital (DN_{min}); $L_{DO1\%}$ = radiância do objeto escuro, assumido como tendo um valor de refletância de 0,01; d = Distância Terra-Sol em Unidades Astronômicas (AU); T_v = transmitância da atmosfera na direção da visão; T_z = transmitância atmosférica na direção da iluminação; $ESUN\lambda$ = irradiâncias exo-atmosféricas solares médias ($W / (m^2 \mu m)$); θ_s = ângulo zenital solar medido em graus; E_{down} = irradiância difusa descendente; ρ = refletância da superfície.

Várias técnicas do DOS consideram valores diferentes sobre T_v e E_{down} . A técnica DOS1 fornece para T_v e T_z o valor de 1 e para E_{down} o valor de 0 (SOBRINO, 2004). Após aplicar a correção atmosférica, os níveis digitais (ND) das imagens do

Sentinel-2 e CBERS-4 resultantes são medidas da refletância da superfície terrestre. No caso das imagens do Landsat-8 que possuem os níveis digitais da imagem em valores de refletância da superfície escalados, precisam ser transformados em valores físicos de refletância usando a Equação 8 apresentada na documentação guia dos produtos L2A OLI (USGS, 2019).

$$R = \frac{ND}{QV} \quad (8)$$

Onde:

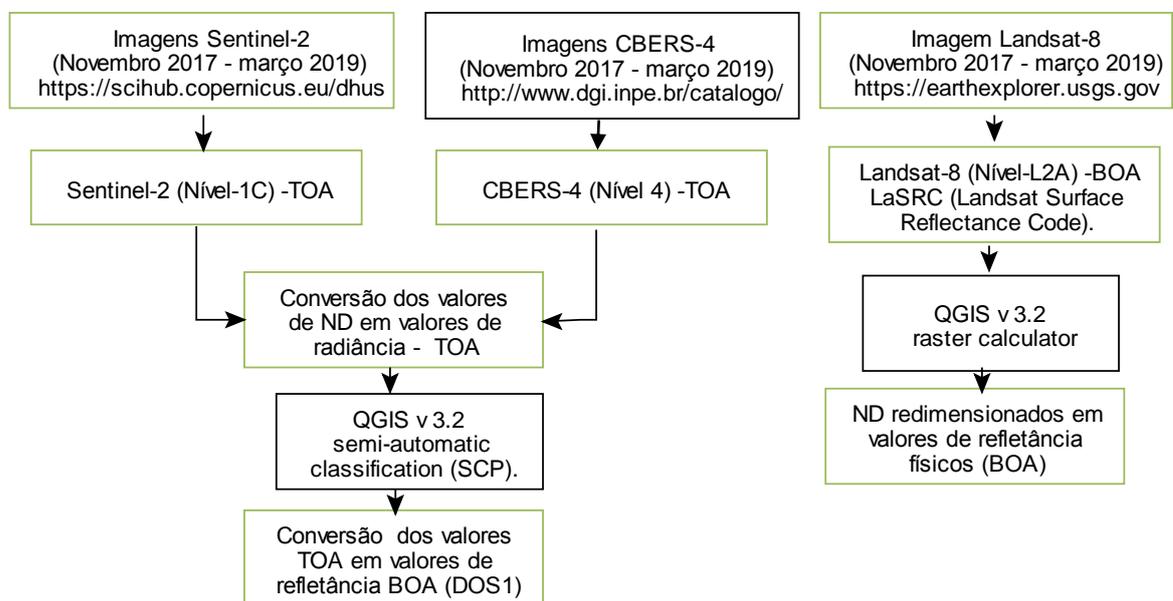
R: Valores físicos de refletância na base da atmosfera.

ND: nível digital ND da imagem

QV: *quantification value* ou valor de quantificação no caso do Landsat-8 é 10000.

A Figura 19 indica um resumo do processo de correção atmosférica para cada grupo de imagens.

Figura 19 – Processo seguido para a obtenção dos valores de refletância na BOA para as imagens dos satélites Sentinel-2, CBERS-4 e Landsat-8.



Fonte: Elaboração própria

Uma vez obtidos os valores de refletância na BOA (Base da atmosfera), foi feita a obtenção das assinaturas espectrais das culturas de Milho, Arroz e Soja para os ciclos de semeadura de verão 2017/18 e 2018/19 (novembro a março), usando

através do *plugin* SCP as bandas 2,3,4,5,6,7,8,8A,9,11 e 12 das imagens do satélite Sentinel-2 e as bandas 2,3,4,5,6 e 7 da imagem do mês de dezembro de 2017 do satélite Landsat-8, com a finalidade de obter o comportamento das assinaturas durante todos os meses que serão analisados através dos índices de vegetação (NDVI, GNDVI, EVI, SAVI).

Os valores de % de refletância nas imagens do Sentinel-2 para cada uma das culturas foram obtidos depois da correção atmosférica através do *plugin* SCP, considerando amostras distribuídas ao redor de toda a plantação. No caso da imagem do mês de dezembro 2017 (Landsat-8) para a transformação dos níveis digitais (ND) da imagem Landsat-8 L2A em valores de refletância, usando a Equação 8, a imagem foi dividida para o valor de quantificação de 10.000 sendo o valor apresentado nos dados do arquivo de metadados da imagem baixada desde *EarthExplorer*. Os gráficos das assinaturas espectrais foram feitos usando a linguagem de programação Python 3. Considerando a data de cada imagem e os registros dos livros de campo obtidos dos agricultores (foram consideradas áreas separadas para identificar diferenças de culturas), se obtiveram diferentes assinaturas espectrais, correspondentes com o desenvolvimento das culturas.

Posteriormente foi feito o cálculo corresponde aos índices de vegetação, com base nas equações 1, 2, 3 e 4 para o NDVI, GNDVI, SAVI e EVI respectivamente, e foram geradas as imagens (classificadas em diferentes escalas de cores distribuídos nas faixas de -1 e 1) que se observam nas páginas 95 a 102 da seção de Resultados e discussão.

Utilizando as imagens obtidas como resultado do cálculo dos índices referentes aos meses de desenvolvimento das safras 2017/18 e 2018/19 se geraram pontos aleatórios (randômicos) nas 12 parcelas criados a partir da ferramenta *random points* no QGIS v3.2, tendo um total de 540 pontos distribuídos dentro de todas as parcelas; para cada um dos pontos foi calculado o valor respectivo em cada uma das imagens dos índices usando a ferramenta *raster value* na calculadora raster do software. Finalmente foram feitos os gráficos de correlação (observam-se nas páginas 104 a 112 da seção 4) entre cada um dos satélites (S2, C4 e L8) respeito aos índices de vegetação calculados, a correlação foi feita unicamente para as imagens que apresentavam menos de 10 dias de separação nas datas de captura para evitar mudanças muito extremas na resposta espectral das culturas.

4 RESULTADOS E DISCUSSÃO

4.1 ANÁLISE DAS ASSINATURAS ESPECTRAIS

Como foi indicado na seção anterior, as assinaturas espectrais para os ciclos de semeadura 2017/18 e 2018/19 das culturas de Milho, Arroz e Soja foram obtidas usando somente as imagens do satélite SENTINEL-2, considerando as diferentes áreas de semeadura da região de estudo (área agrícola de 320 ha., subdividida nas regiões 1a, 1b, 1c, 1d, 2, 3, 4, 5, 6, 7, 8, 9, 9a, 10a, 10b, 10c, 10d, 11, 12). Cada uma das sub-regiões de semeadura estão separadas pelo tipo de cultura, como mostrou-se na Figura 16 (página 68), as áreas 1a, 1b, 1c, 1d, 7, 10b, 10c, 10d e 12 estão semeadas com Arroz, as áreas 2, 3, 5 e 11 estão semeadas com Soja e as áreas 4, 6, 8, 9a, 9b e 10a estão semeadas com Milho. Cada uma das assinaturas foi obtida usando regiões de interesse (regiões de amostragem digital de 3 ou mais pixels) das 10 bandas de interesse à Agricultura de precisão nas que o satélite SENTINEL-2 trabalha. Além disso é importante indicar que o ciclo das 3 culturas pode ir desde os 90 aos 130 dias, dependendo das condições atmosféricas e de humidade do solo, por esse motivo alguns dos gráficos são comparados com os 60 dias de semeadura como um referente de meio ciclo para todas as culturas, considerando-se que para essa época todas teriam alcançado a maturidade da cultura.

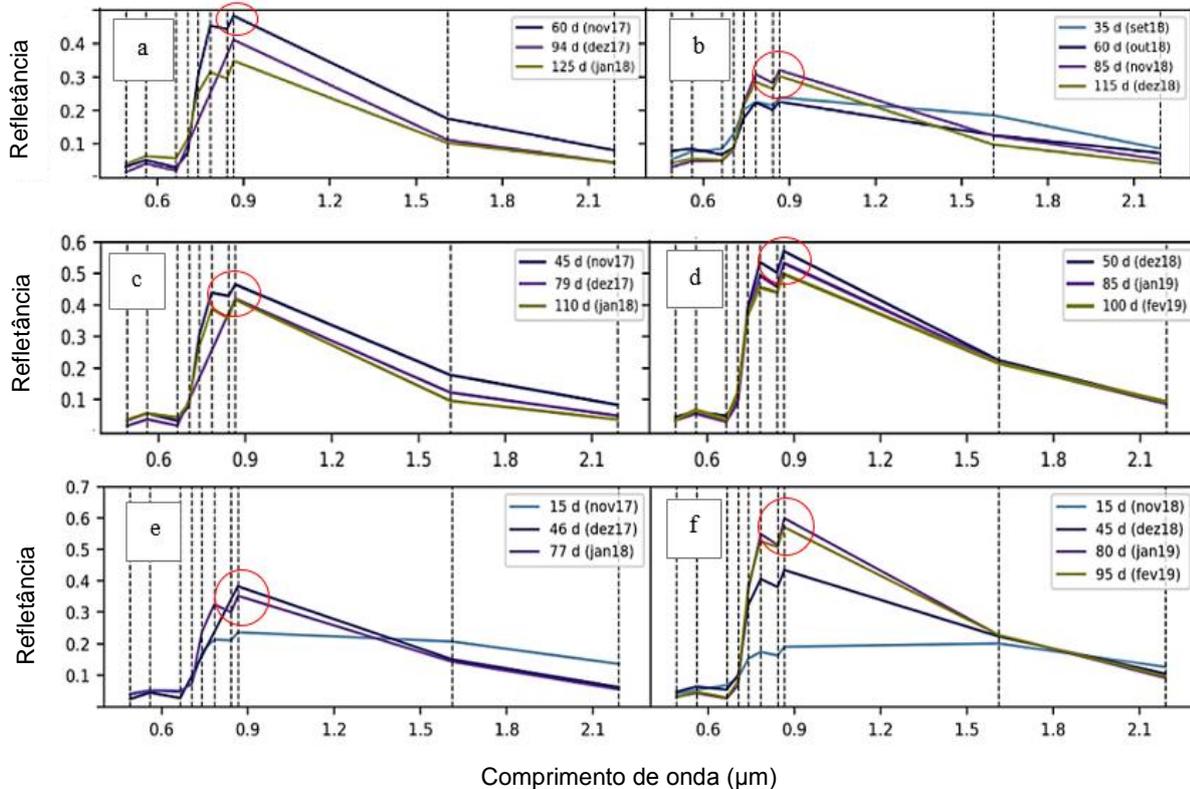
A análise comparativa para os gráficos de comportamento espectral (assinaturas espectrais) das culturas de Milho, Arroz e Soja para os ciclos de semeadura 2017/18 e 2018/19, foram resumidos nas Figuras 20 e 21, sendo exibidas somente as que apresentaram maiores diferenças entre a porcentagem de refletância obtida para cada um dos ciclos, assim, comentam-se as seguintes observações:

- em geral, há uma semelhança com o comportamento geral de todas as culturas estudadas (arroz, soja, milho), com diferenças marcantes na resposta espectral, apresentando pontos de inflexão de valores nas bandas 3 (0,560 μm), 4 (0,665 μm), 5 (0,705 μm), 7 (0,783 μm), 8 (0,842 μm) e 8A (0,865 μm) do Sentinel-2;
- na zona de colheita 10b (arroz), as Figuras 20a e 20b mostram uma maior resposta de refletância para as assinaturas espectrais no ciclo 2017/18, com um valor de pico (sinalizado em vermelho) em torno de 48% (0,865 μm) para

60 dias de semeadura equivalente ao valor de pico de 32% (destacado em vermelho) para o ciclo 2018/19 com 85 dias de semeadura;

- da mesma forma, na zona de colheita 10d (arroz) (Figura 20c e 20d), o pico máximo do valor de refletância é de 57% (sinalizado em vermelho), dado na faixa 8A (0,865 μm) aos 50 dias da semeadura, para o ciclo da safra 2018/2019, diferente da resposta espectral em 2017/2018 de 47% aos 45 dias de semeadura (sinalizado em vermelho), o que dá a ideia de que há um melhor desenvolvimento dessa cultura no segundo ciclo, sendo um comportamento comum em todas as áreas de cultivo;
- para a área de semeadura, 6 (milho), as Figuras 20e e 20f mostram um pico de resposta espectral na banda 8A no ciclo 2017/18 a 40% com 46 dias de semeadura e um pico espectral na mesma banda de 60% para 80 dias de semeadura no ciclo 2018/19. Note-se também que a duração do primeiro ciclo foi menor (77 dias) que os 95 dias do segundo ciclo, assumindo um problema (deficiência de nutrientes, por exemplo) nesta parcela para o ciclo 2017/18;
- a cultura da soja apresenta valores de refletância mais altos em comparação com outras culturas (arroz, milho) (Figura 21), com os maiores valores de resposta na região do NIR e os mais baixos na região verde, o que estaria relacionado à boa porcentagem de absorção para a soja de nitrogênio na faixa visível (focada em 0,560 μm verde).

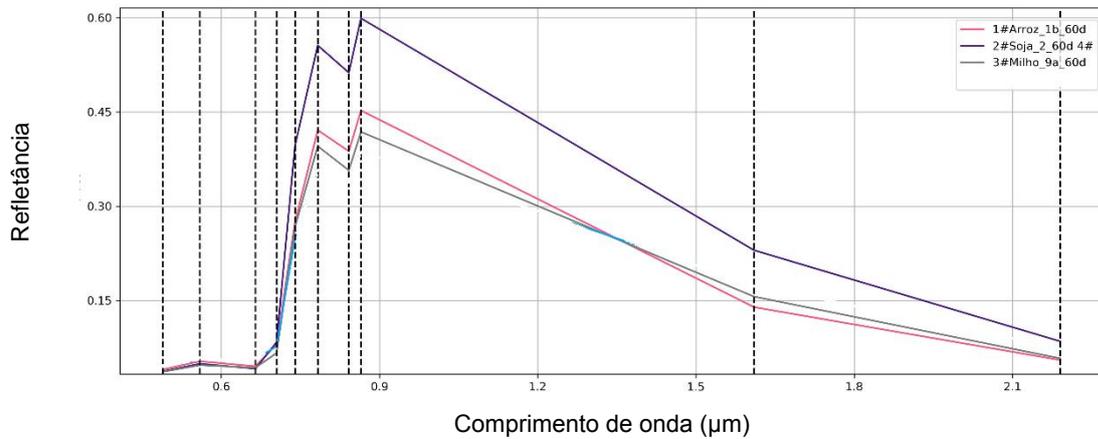
Figura 20 – Resultados do comportamento espectral (usando as imagens do SENTINEL-2) dos ciclos 2017/18 (esquerda) e 2018/19 (direita) para as zonas de cultivo 10b-arroz (a e b), 10d-arroz (c e d), e 6-milho (e e f).



Fonte: Elaboração própria

De acordo com Corti (2017), os valores de refletância na faixa visível (490 nm a 655 nm) estão relacionados ao conteúdo de clorofila (carotenos e antocianinas) e nitrogênio (N) nas culturas. Assim, pode-se identificar, como é mostrado em Martínez (2017), que os intervalos de espectro onde ocorrem picos podem ter o potencial de gerar informações relacionadas a algumas características das plantações. No caso do conteúdo de nitrogênio nas folhas, apresenta um coeficiente altamente significativo com valores de refletância na faixa de comprimento de onda de 450 nm e 780 nm. Isso pode estar relacionado aos maiores valores de refletância encontrados nas lavouras de soja, dado o aumento do consumo de fertilizantes nitrogenados durante o período da semeadura.

Figura 21 – Comportamento espectral das culturas de milho, arroz e soja ao redor de 60 dias de semeadura do ciclo 2017/18 (imagens SENTINEL-2).

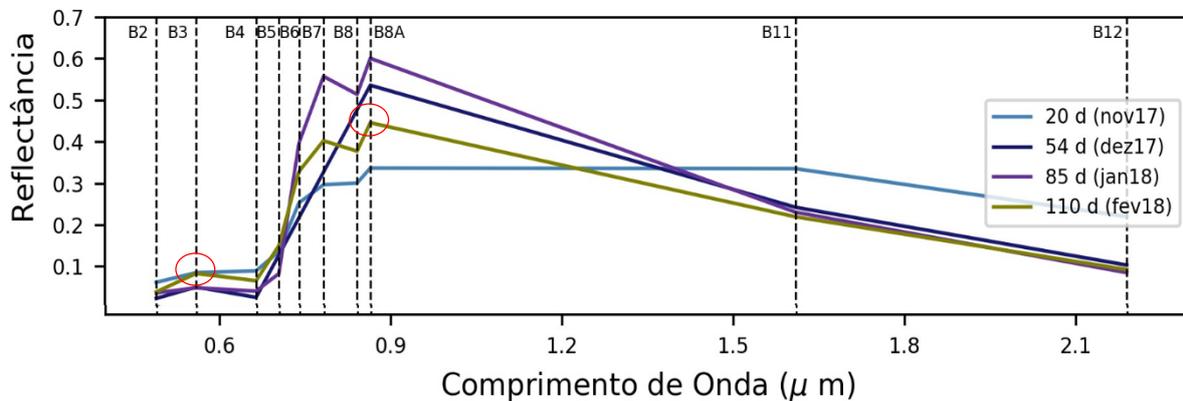


Fonte: Elaboração própria

O cultivo do Arroz no ciclo 2018/19 teve a tendência a apresentar melhor rendimento na colheita comparado ao cultivo de 2017/18. Além disso, Pereira et al. (2016) manifestam que as bandas 11 e 12 correspondentes ao infravermelho de onda curta (*Short-wavelength Infrared* - SWIR) podem ajudar na estimativa da porcentagem de água presente nas plantas, devido à relação inversa entre absorção e refletância. Pode-se mencionar que no ciclo 2018/2019 a cultura de Arroz mostra registros de ter um maior conteúdo de umidade na estrutura celular da plantação, em comparação ao ciclo anterior.

Assim também se verificou que, de acordo com o manifestado em Pinter et al. (2003), as respostas espectrais decrescem com a aproximação da colheita, o que é dado pela perda dos nutrientes e a clorose (amarelamento) das folhas. Isto pode ser verificado com destaque no comportamento espectral da parcela 2 no ciclo 2017/2018 apresentado na Figura 22 onde a cultura da Soja diminui significativamente sua resposta espectral aos 110 dias de semeadura, com destaque em vermelho na faixa do visível que aos 110 dias de semeadura faz um pico na porção do verde (0.56 µm) que indicaria uma perda significativa da clorofila, e uma queda no pico do *redEdge* (0.865 µm) que relacionaria a mesma causa.

Figura 22 – Comportamento espectral da parcela 2 do cultivo de Soja para o ciclo 2017/2018.



Fonte: Elaboração própria

4.2 ANÁLISE DOS ÍNDICES DE VEGETAÇÃO ESPECTRAL

4.2.1. ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADA (NDVI).

A determinação do índice de vegetação normalizado (NDVI) revelou a relação da resposta espectral dos cultivos com os valores de NDVI. O NDVI é um índice que mede o vigor dos cultivos (que no caso considera o verdor das folhas), começa a diminuir ao chegar perto da época de colheita, dada a variação do pigmento nas folhas que tendem a se amarelar nos cultivos estudados. Os resultados obtidos para o NDVI são mostrados nas Figuras 23 e 24, que além disso indicam uma comparação para as três plataformas de satélite estudadas.

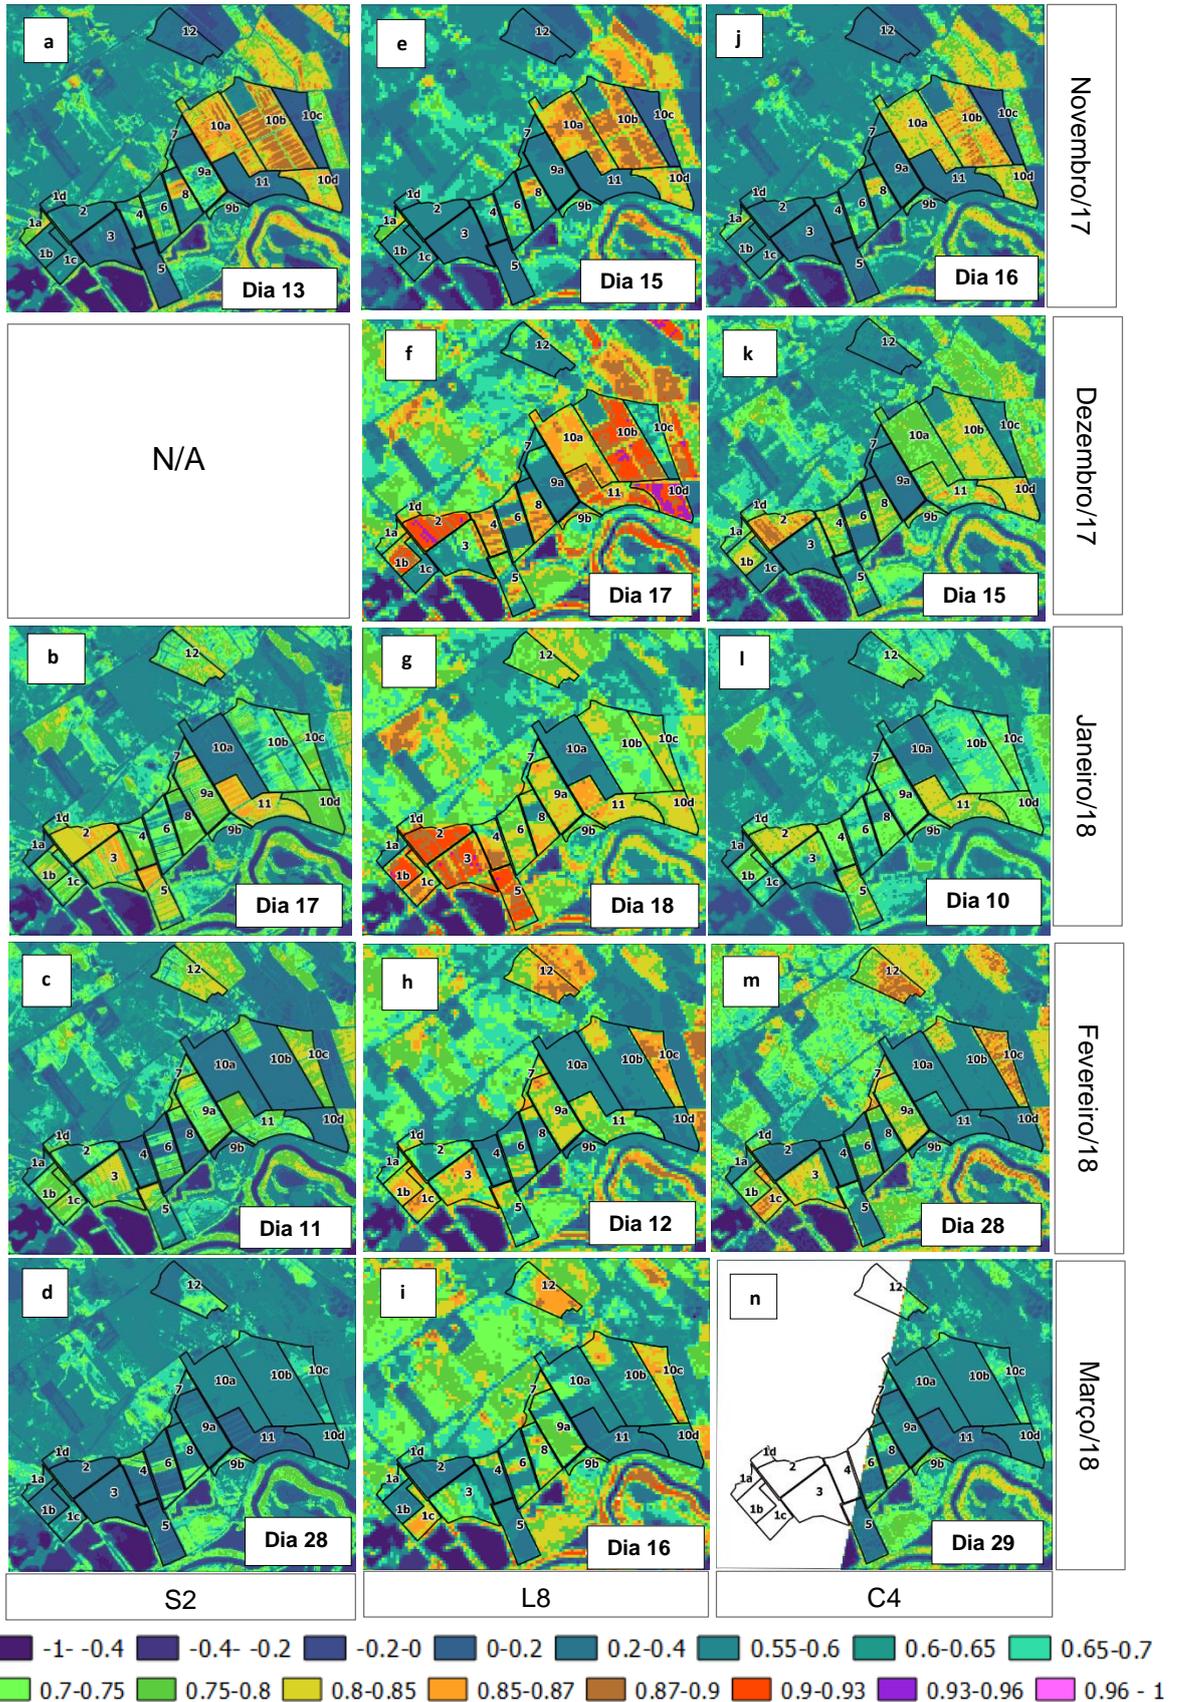
As figuras apresentam da esquerda à direita os resultados para o SENTINEL-2 (S2), LANDSAT-8 (L8) e CBERS-4 (C4) e de acima para abaixo os meses de novembro a março respectivamente. Depois da análise das Figuras 23 e 24 temos as seguintes observações:

- o valor máximo obtido para o NDVI verifica-se nas imagens do L8, como mostrado na Figura 23-f, para o ciclo 2017/2018 (áreas com valores de 0,93 a 0,96) na imagem de dezembro de 2017, nas zonas de semeadura 10d (arroz 79 dias) e 2 (soja 54 dias) mostrando a maior área com valor máximo (áreas em roxo). Um comportamento similar é apresentado para as parcelas 1b (arroz), 2, 3 e 5 (soja) na Figura 23-g (janeiro 2018) onde existem mais áreas

com faixas do NDVI de 0,90 a 0,93 (áreas em laranja) e alguns pontos na faixa de 0,93 a 0,96 (áreas em roxo);

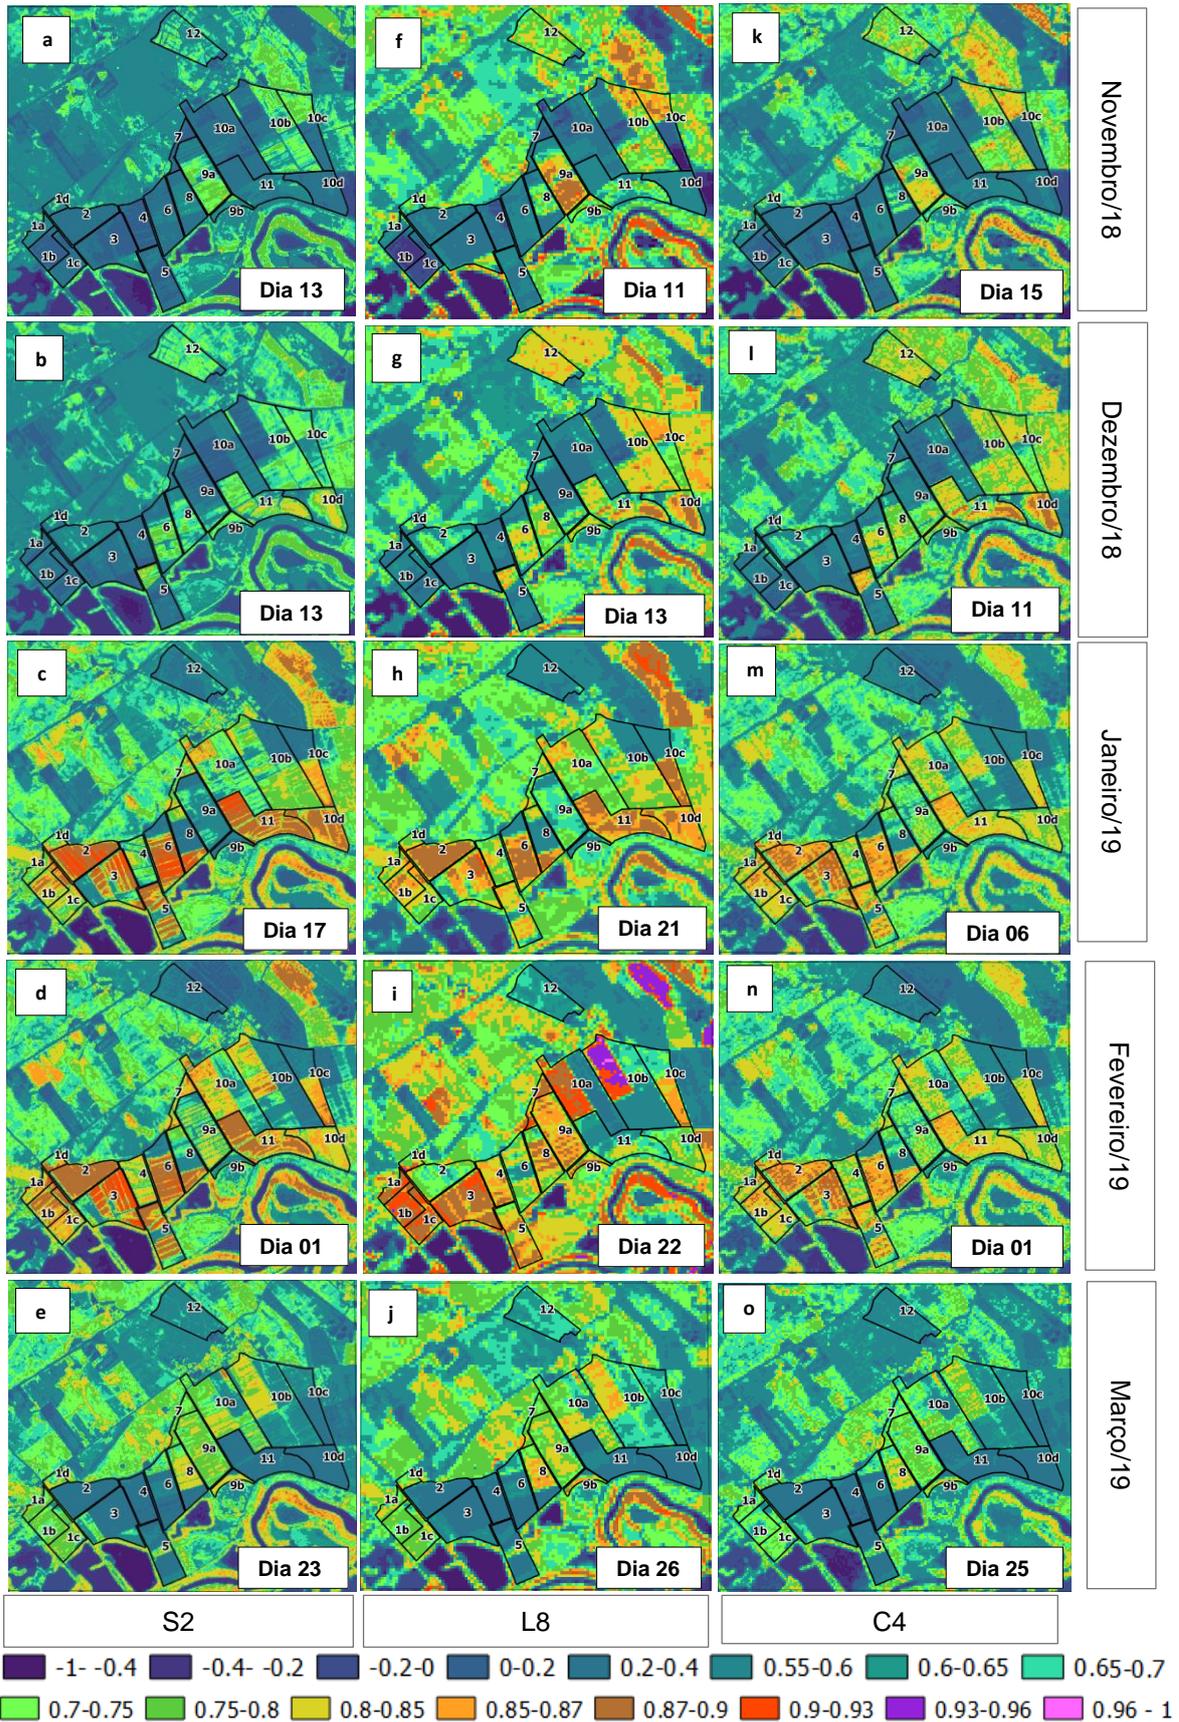
- no caso das Figuras 24-c e 24-d, que mostram o comportamento do ciclo 2018/2019, temos que os valores máximos (0,90-0,93) são observados nas parcelas 2, 3, 5, 11 (semeadas com Soja), 6 (milho) e 10d (arroz), para as imagens do satélite S2;
- no ciclo 2018/2019, o valor máximo obtido para o NDVI foi de 0,93 para a imagem de janeiro de 2019 (Figura 24-c), com as zonas de semeadura 2 (soja 55 dias), 3 (soja 65 dias) e 11 (soja 80 dias) mostrando a maior área com o valor máximo;
- as zonas de cultivo 6, 8 e 10a (semeadas com milho) também apresentaram uma melhor resposta no ciclo 2018/2019 com áreas maiores com valores na faixa de 0,87 a 0,90 de NDVI;
- considerando as diferentes plataformas de satélite, observa-se de maneira geral maior similaridade entre as imagens obtidas do NDVI para os satélites L8 e S2, como pode-se ver nas Figuras 23-a e 23-e. Além disso, nota-se que as respostas para os índices das imagens dos satélites C4 e L8 são amplamente diferentes, como mostra a Figura 24-f e 24-k;
- a tendência mostrada pelos resultados do cálculo dos índices NDVI são valores altos nas imagens do satélite L8 e valores mais baixos no satélite C4, o que está bem marcado nas Figuras 23-g e 23-l;

Figura 23 – NDVI (S2, L8 e C4) calculado para o ciclo 2017/18.



Fonte: Elaboração própria

Figura 24 – NDVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.



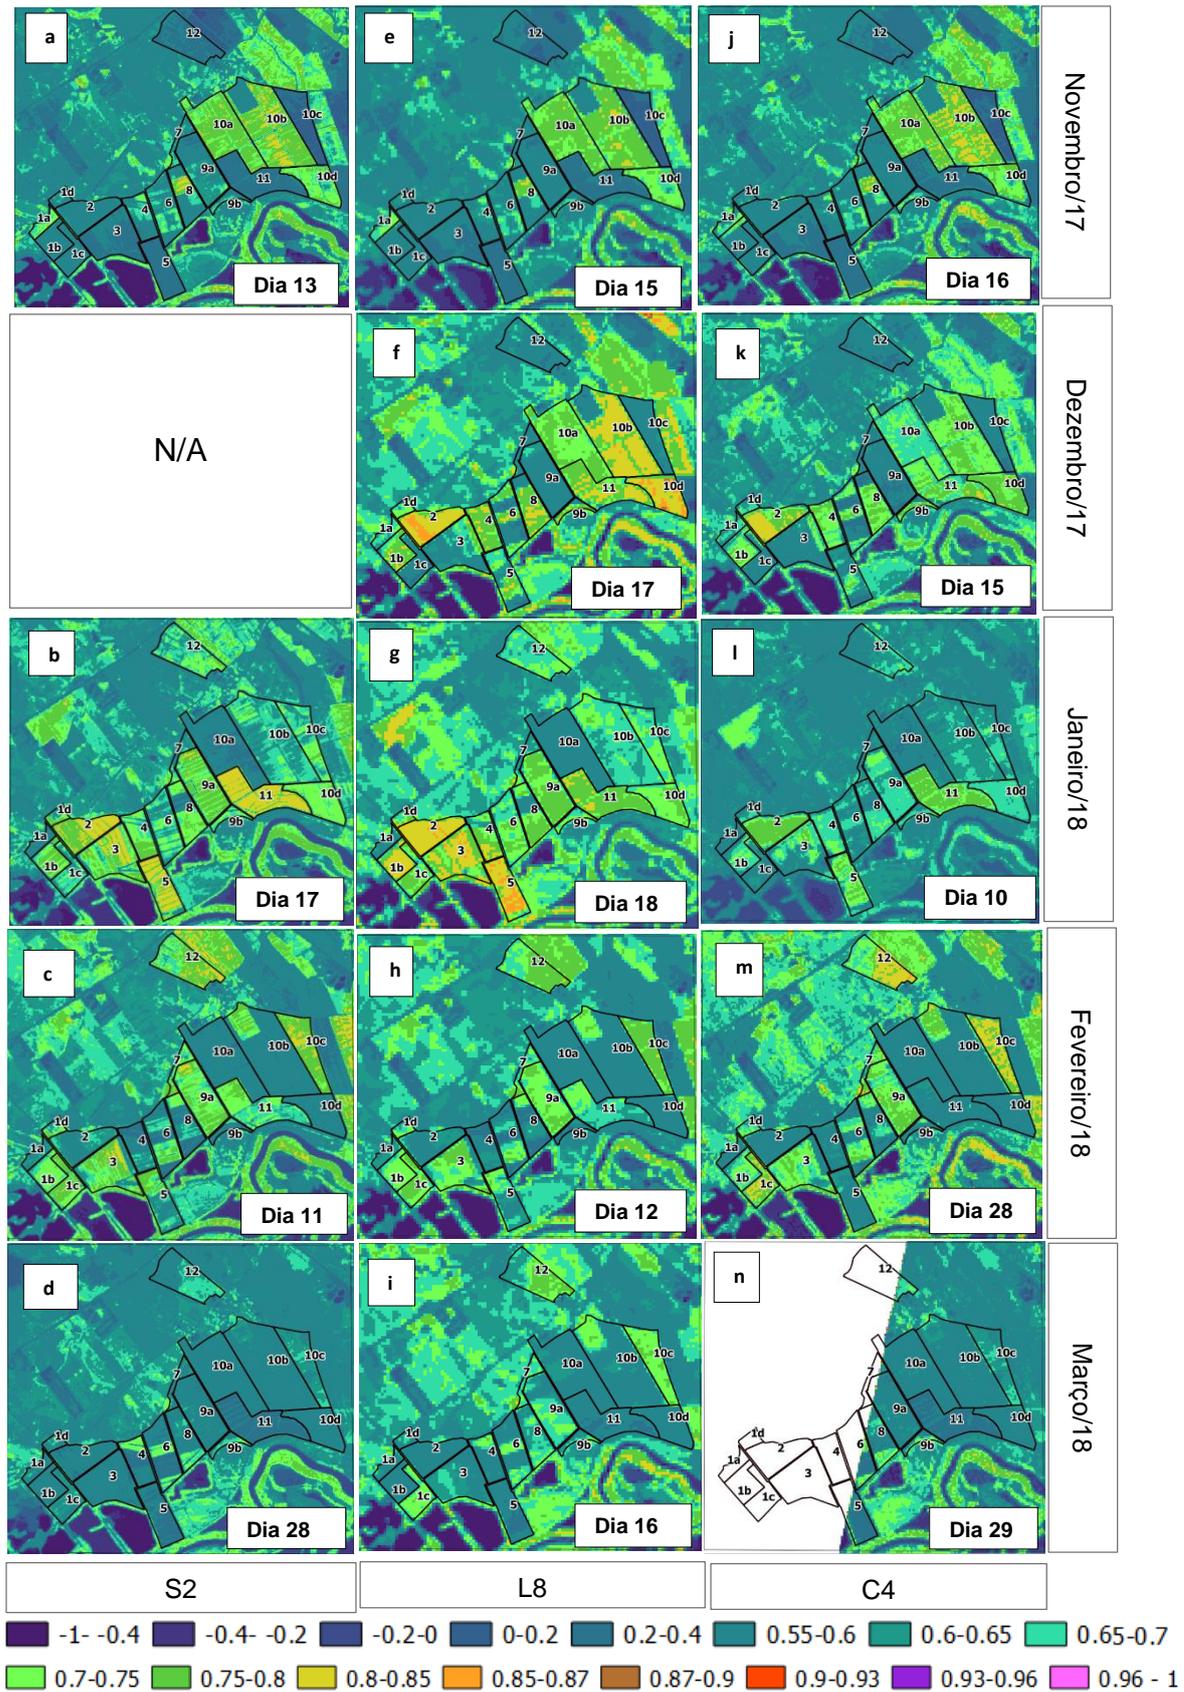
Fonte: Elaboração própria

4.2.2. ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA VERDE (GNDVI).

O GNDVI é o índice de vegetação da diferença normalizada verde, e pode ser atribuído à senescência das culturas, em trabalhos como os de Shanaham et al. (2001), o GNDVI indicou maior sensibilidade a variações no teor de clorofila foliar do que em outros índices. As Figuras 25 e 26 apontam os resultados obtidos para o cálculo do índice GNDVI, que vão se resumir a seguir:

- as imagens do GNDVI apresentam menores valores em comparação aos obtidos para o cálculo do NDVI, que pode ser verificado na Figura 25-f em comparação com a homóloga Figura 23-f, onde os valores máximos da faixa de 0,93 a 0,96 para o NDVI na parcela 10d (arroz) são trocados por valores máximos para o GNDVI na faixa de 0,80-0,85;
- de maneira geral, os resultados para o GNDVI parecem ter menor variação entre as plataformas de satélite a exceção da imagem do mês de janeiro de 2018 (Figuras 25-b e 25-g), na qual existe uma diferença significativa (0,75 a 0,80 e 0,80-0,85) nos valores de resposta da parcela 11 para os satélites S2 e L8, sendo as datas de captura muito próximas (17 para S2 e 18 para L8);
- o maior porcentagem de áreas com valores máximos (faixa de 0,87 a 0,90) para o GNDVI se encontraram na Figura 26-m, para o satélite C4, nas parcelas 11(soja) e 10d (arroz) no ciclo de semeadura 2018/2019, que em comparação com a homóloga no NDVI (Figura 24-m) mostrou maiores valores;
- no índice GNDVI os resultados apresentados pelas plataformas S2 e C4 mostraram aparentemente uma maior similaridade (Figuras 25-a e 25-j e Figuras 25-d e 25-n);

Figura 25 – GNDVI (S2, L8 e C4) calculado para o ciclo de semeadura 2017/18.



4.2.3. ÍNDICE DE VEGETAÇÃO AJUSTADA PELO SOLO (SAVI).

O índice de vegetação ajustado ao solo (SAVI) foi estabelecido para reduzir o impacto no NDVI das variações de solo em áreas de cobertura vegetal inferior. As Figuras 27 e 28 indicam o comportamento do índice SAVI em cada uma das plataformas (S2, L8, C4) para os dois ciclos de semeadura (2017/2018, 2018/2019). Resumindo as variações observadas temos o seguinte:

- os resultados apresentados para o índice SAVI mostram de maneira geral menores valores nas imagens em comparação como o NDVI e GNDVI. Nota-se que do mesmo jeito que nos índices NDVI e GNDVI o valor máximo está na imagem de dezembro de 2017 (L8) os quais estão na faixa de 0,75 a 0,80;
- pode ser observado nas Figuras 28-g, 28-l, 28-d e 28-n, que o SAVI apresenta resposta similares nas 3 plataformas de satélite. À primeira vista (Figura 28-h) existe um melhor comportamento nos cultivos de soja (parcelas 2 e 11) do segundo ciclo (2018/2019);

Figura 27 – SAVI (S2, L8 e C4) calculado para o ciclo de semeadura 2017/18.

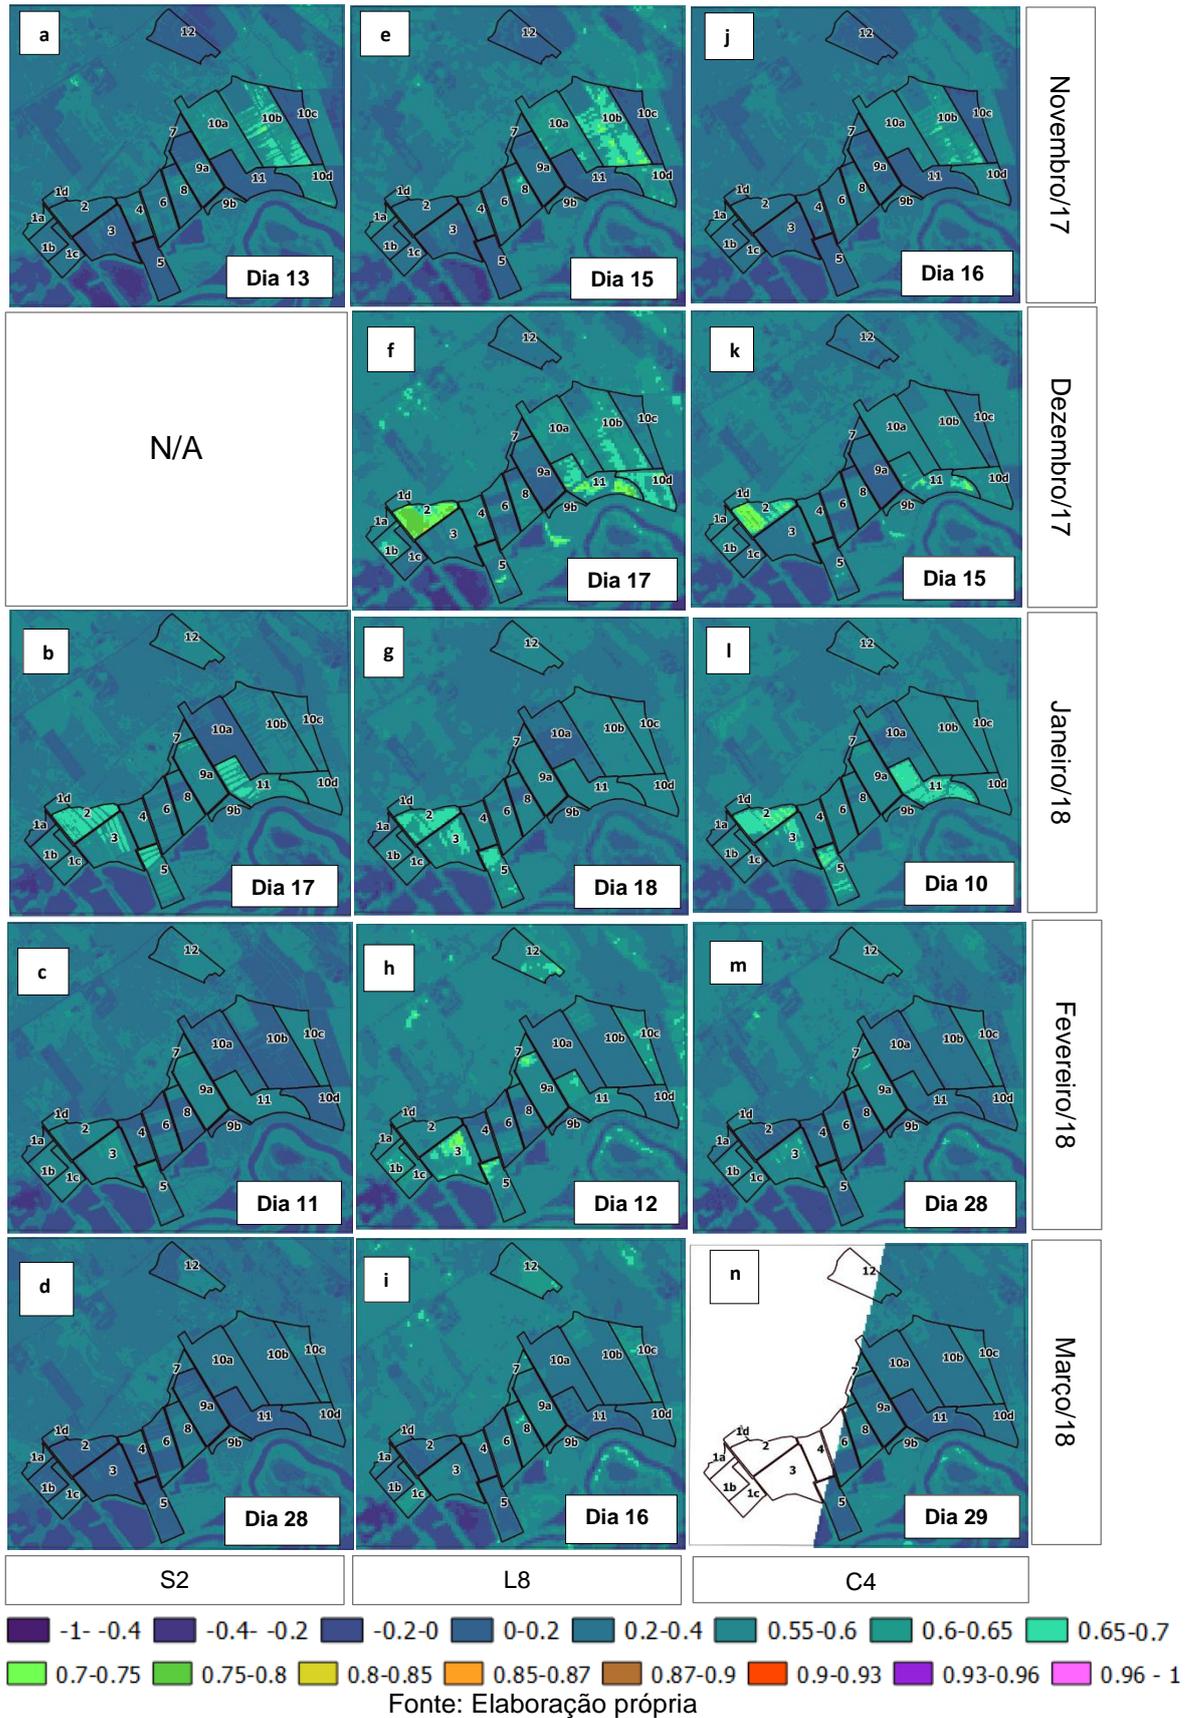
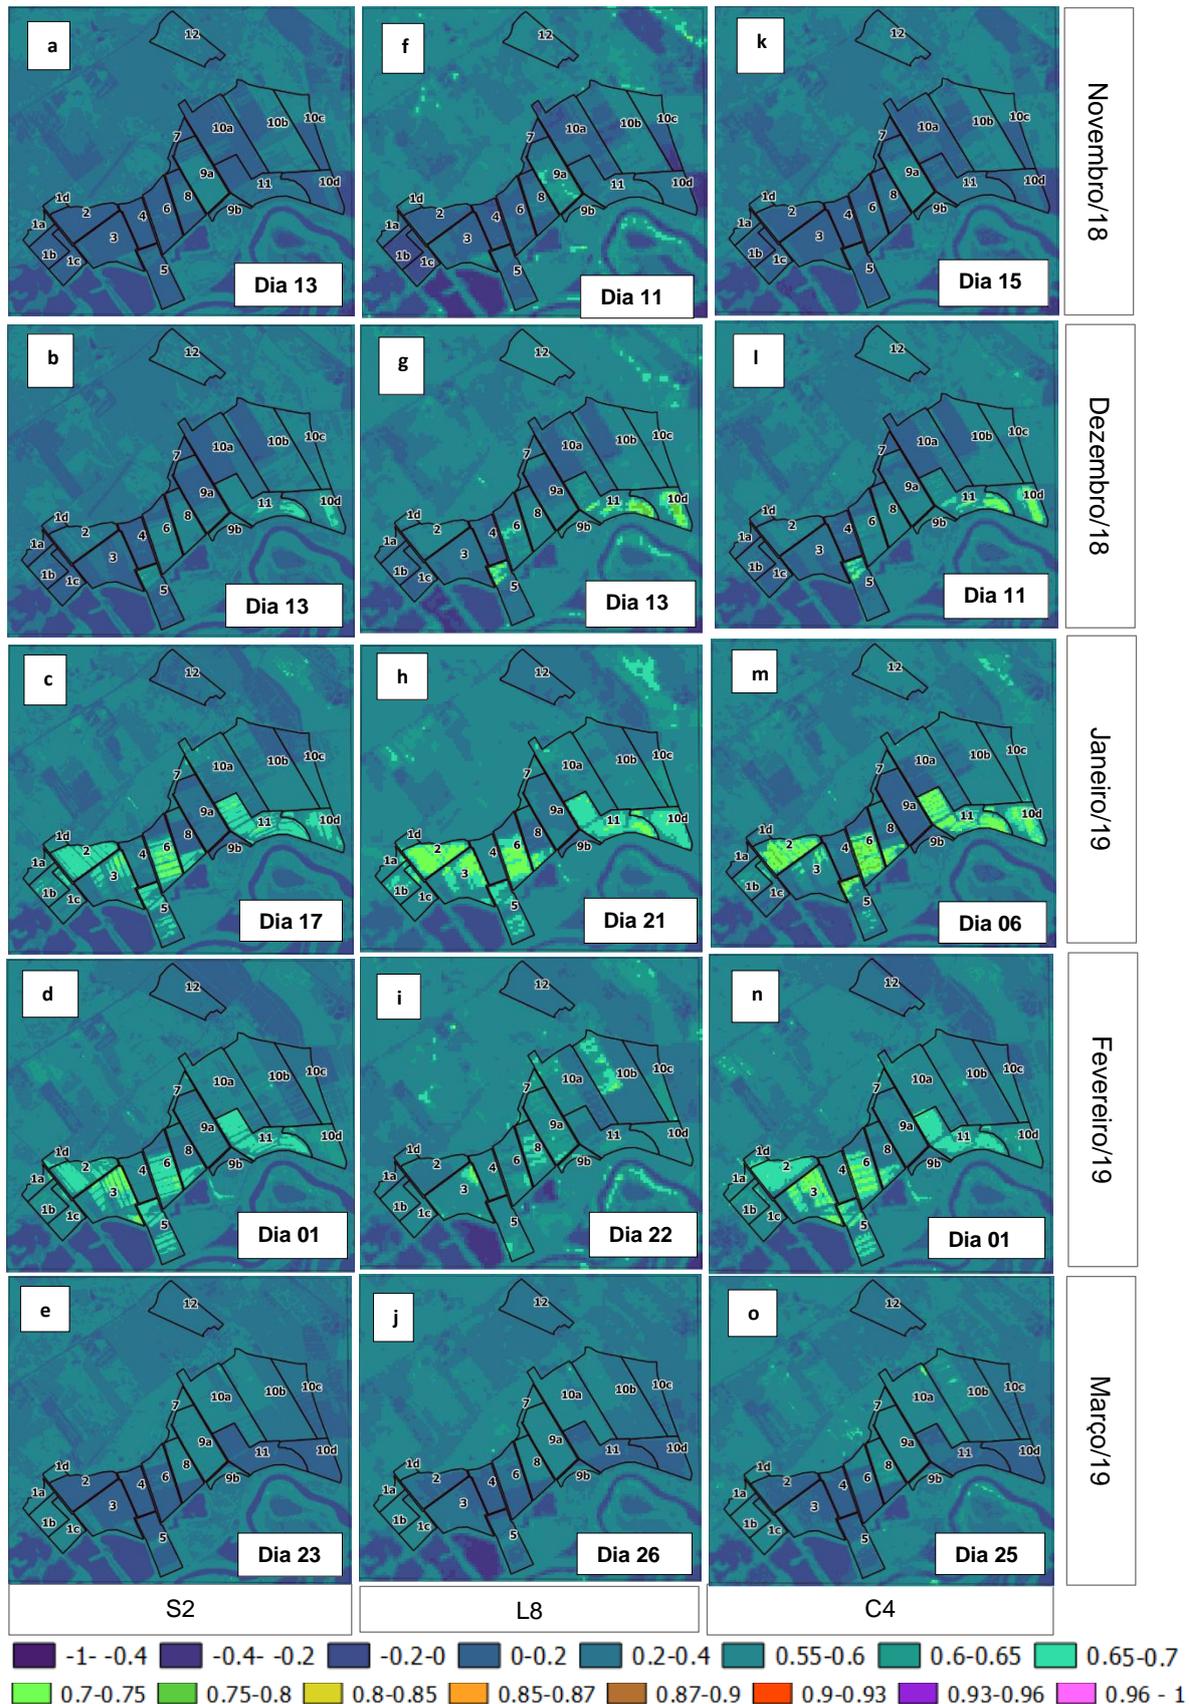


Figura 28 – SAVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.



4.2.4. ÍNDICE DE VEGETAÇÃO APRIMORADO (EVI).

O EVI (Índice de vegetação aprimorado) foi criado para corrigir simultaneamente os efeitos do solo e da atmosfera, otimizando o sinal da vegetação com melhor sensibilidade em regiões de alta biomassa. As Figuras 29 e 30 mostram o comportamento do índice EVI para as duas safras (2017/2018 e 2018/2019) e as diferentes plataformas de satélite (S2, L8, C4). O índice EVI apresenta o comportamento mais interessante em comparação com os três índices calculados anteriormente (NDVI, GNDVI, SAVI), pelo que se podem fazer os seguintes comentários:

- as imagens apresentam maior variedade nos valores dos pixels de uma mesma parcela. A Figura 29-f mostra áreas com uma faixa de valor máximo de 0,96 a 1,00, dentro da parcela 2 (soja), que comparada à sua imagem correspondente do NDVI (Figura 23 f), apresentava valores na faixa de 0,93 a 0,96 no mesmo setor.
- na mesma Figura 29-f observa-se a redução dos valores de (0,93-0,96) obtidos no NDVI para as parcelas 11 (soja) e 10d (arroz) para valores de 0,75 a 0,80 na nova classificação dos pixels no EVI;
- observa-se além disso que a diferença das variações entre as respostas obtidas no NDVI (parcelas 2, 11 e 10b) para os satélites C4 e L8, a imagem de dezembro de 2017 (Figuras 29-f e 29-k) mostra resultados muito similares no cálculo do EVI;
- como comportamento geral do índice EVI, as áreas que no NDVI apresentavam valores menores a 0,85 foram reduzidas a valores de 0,70 a 0,75. Mas no caso das áreas com valores elevados do NDVI (maiores a 0,85), foram maximizadas a valores de 0,96 a 1,00 (Figura 23-f em comparação à Figura 29-f).
- o EVI apresenta melhores resultados para as imagens do C4, como pode ser observado na comparação das Figuras 29-l e 23-l;
- em geral, o índice EVI parece nos dar mais pontos de interesse ao planejar uma amostragem no campo, devido ao aumento de classes (maior diversidade dos valores de cada pixel) de dados nas áreas com maior densidade de cobertura vegetal (valores de NDVI superiores a 0,85);

- há uma percepção de que as imagens do satélite C4 se comportam melhor no índice EVI, mantendo uma estabilidade nos resultados em comparação com outros satélites e índices anteriores.

Figura 29 – EVI (S2, L8 e C4) calculado para o ciclo de semeadura 2017/18.

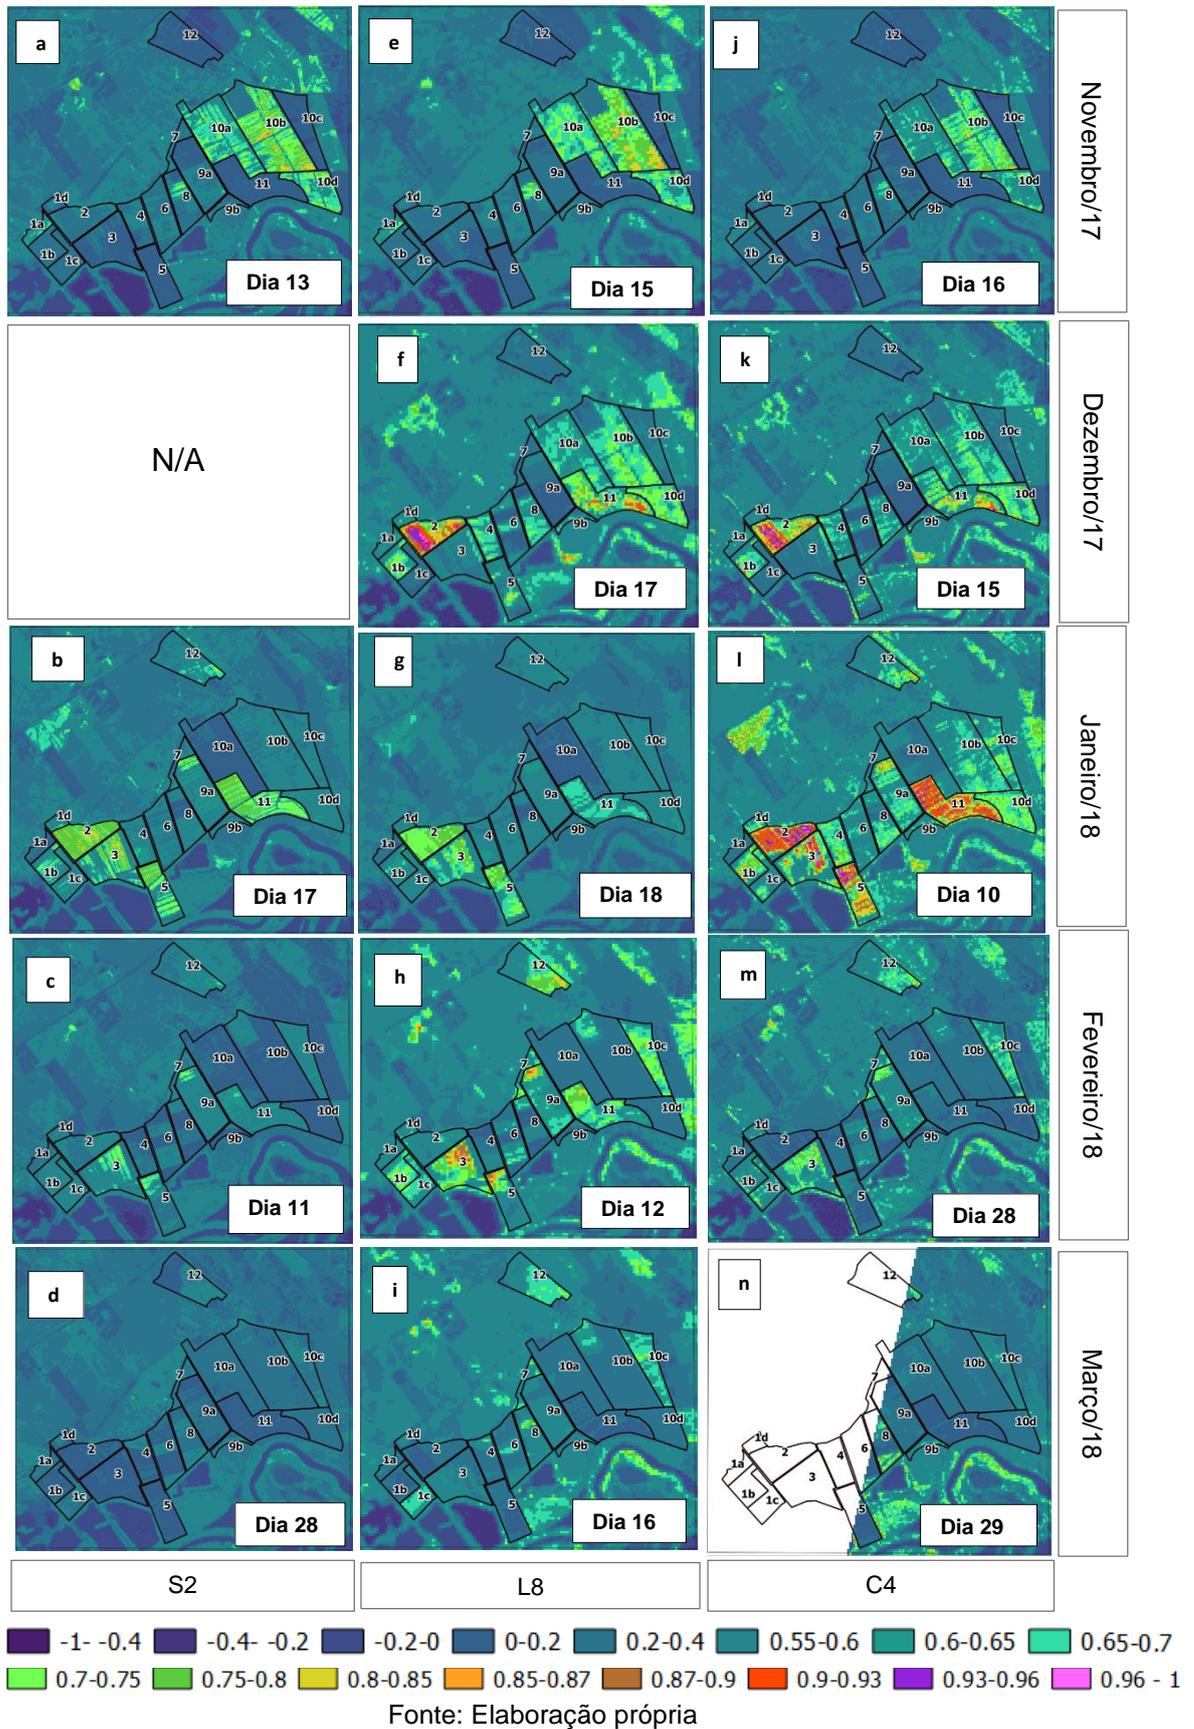
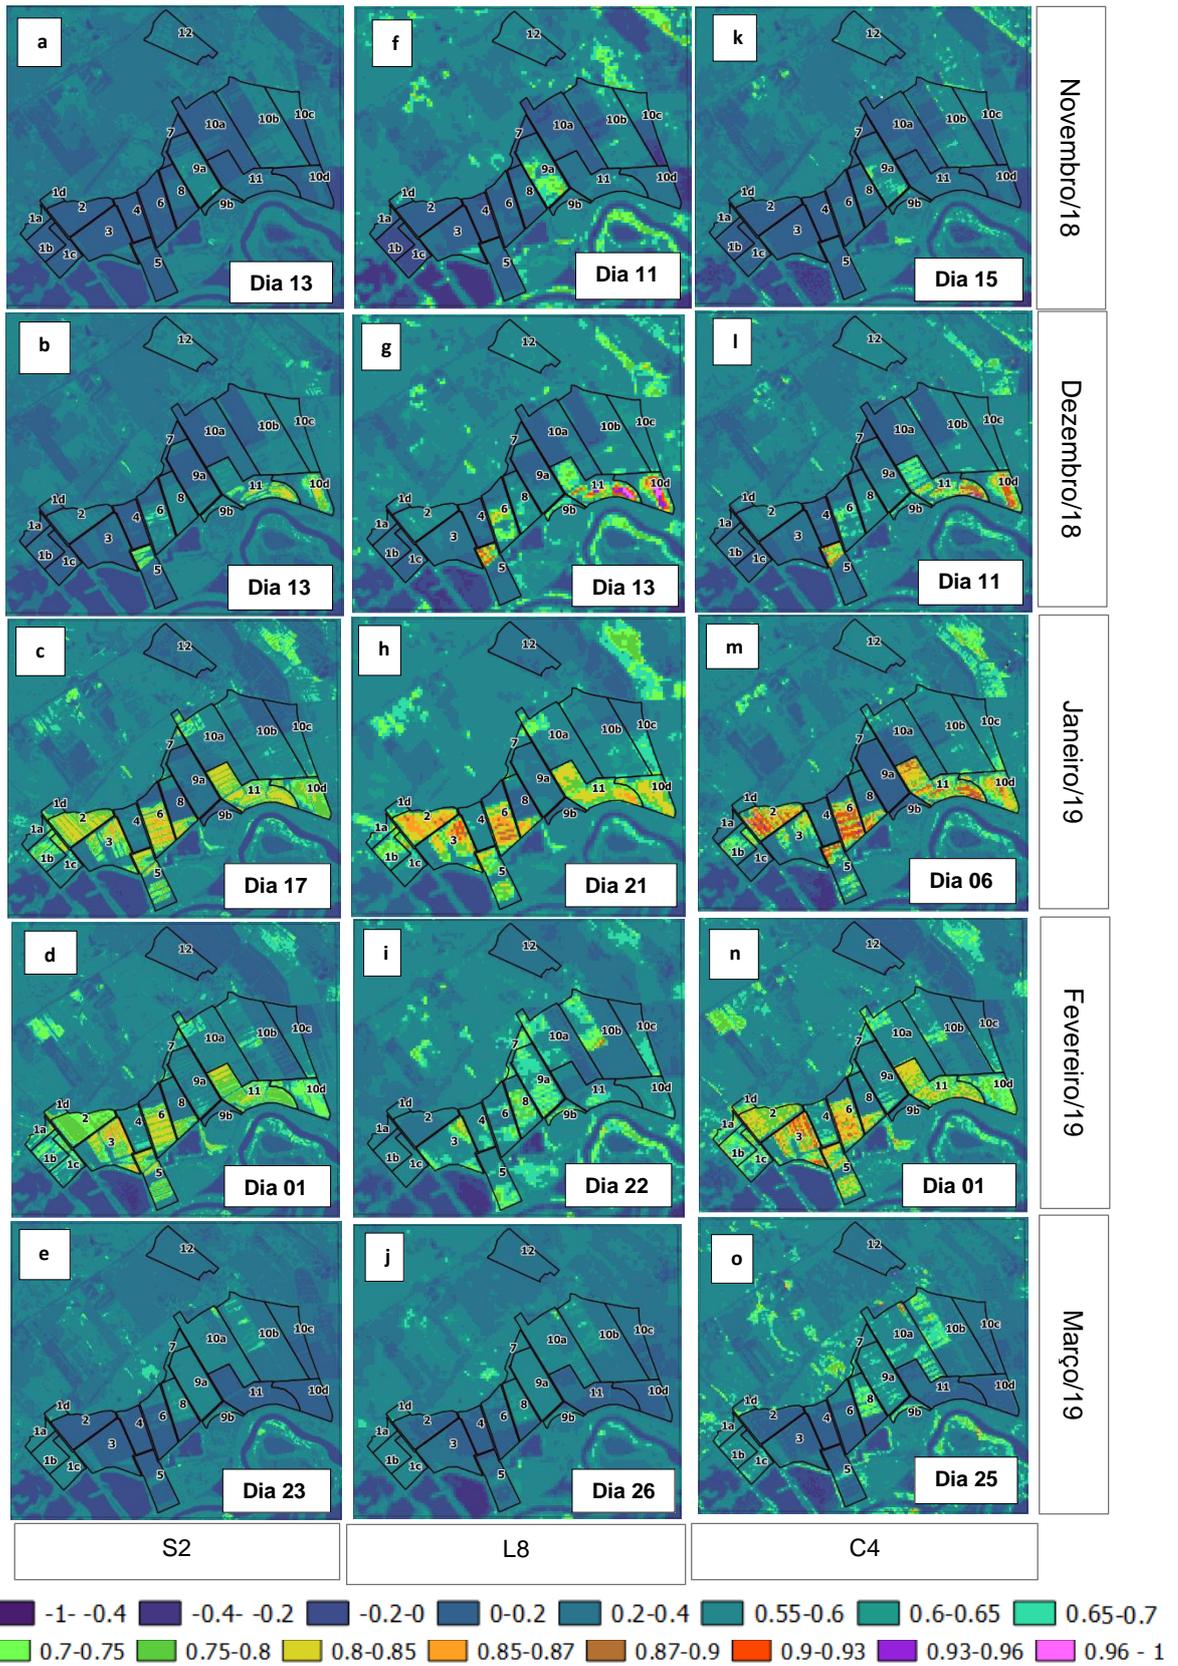


Figura 30 – EVI (S2, L8 e C4) calculado para o ciclo de semeadura 2018/19.



Fonte: Elaboração própria

É importante mencionar que no cálculo dos índices (NDVI, GNDVI, EVI, SAVI) mostrados nas Figuras 23 a 30, existe uma semelhança na classificação das áreas nas faixas de -1 a 0 (áreas azuis escuras) estabelecida como corpos de água e areia, e as faixas de 0 a 0,6 (áreas azuis claras), usadas para setores com vegetação rasteira, assim como também áreas de terras gradeadas. No geral pode-se observar que as áreas com culturas em desenvolvimento são classificadas em faixas superiores a 0,7.

Uma das maneiras que nos permitirá ter outra perspectiva sobre as diferenças na resposta ao cálculo dos diferentes índices entre cada um dos satélites, será apresentada nos gráficos de correlação mostrados na próxima subseção.

4.2.5. CORRELAÇÃO ENTRE OS ÍNDICES DE VEGETAÇÃO.

Os resultados da análise de correlação usando os 540 pontos aleatórios gerados no software QGIS v3.2 e distribuídos nas 12 parcelas são resumidos nos gráficos do Apêndice A (pagina 109), os quais apresentam também a equação de correspondência entre as variáveis e o coeficiente de correlação (R^2), junto com o erro quadrático médio (RMSE). O Quadro 12 mostra as datas das imagens processadas na pesquisa, foram consideradas somente as imagens que tinham até 5 dias de diferença na captura de imagem da área para a obtenção da correlação R^2 .

Quadro 12 - Datas das imagens processadas na pesquisa (datas em marrom não foram usadas para a correlação).

MÊS/ANO	SENTINEL-2	CBERS 4	LANDSAT-8
Novembro/2017	13/11/2017	16/11/2017	15/11/2017
Dezembro/2017	Não Disponível	15/12/2017	17/12/2017
Janeiro/2018	17/01/2018	10/01/2018	18/01/2018
Fevereiro/2018	11/02/2018	28/02/2018	12/02/2018
Março/2018	28/03/2018	29/03/2018	16/03/2018
Novembro/2018	13/11/2018	15/11/2018	11/11/2018
Dezembro/2018	13/12/2018	11/12/2018	13/12/2018
Janeiro/2019	17/01/2019	06/01/2019	21/01/2019
Fevereiro/2019	01/02/2019	01/02/2019	22/02/2019
Março/2019	23/03/2019	25/03/2019	26/03/2019

Fonte: Elaboração própria

No que se refere ao coeficiente de correlação R² obtido para as plataformas de satélite estudadas (SENTINEL-2, CBERS-4, LANDSAT-8), o Quadro 13 indica um resumo dos valores obtidos, destacando em vermelho os valores máximos para cada um dos índices, sendo todos eles para o mês de novembro de 2017 (ciclo 2017/18). Em correspondência colocaram-se em marrom os valores obtidos no mês de dezembro 2018 (ciclo 2018/19) que foi o mês em que iniciou o segundo ciclo, a diferença do primeiro ciclo, que iniciou no mês de novembro 2017. Observa-se que existem melhores porcentagens de correlação no primeiro ciclo e no cálculo do índice EVI.

Quadro 13 - Resumo do R² para os diferentes índices calculados.

CORRELAÇÕES	DATAS	NDVI	GNDVI	SAVI	EVI
S2-C4	Nov. 2017	0,9440	0,9240	0,9497	0,9624
S2-C4	Nov. 2018	0,8820	0,8839	0,8420	0,8960
S2-L8	Nov. 2017	0,9592	0,9567	0,9693	0,9703
S2-L8	Nov. 2018	0,6017	0,4683	0,7230	0,7707
C4-L8	Nov. 2017	0,9639	0,9372	0,9581	0,9723
C4-L8	Nov. 2018	0,5348	0,3842	0,6373	0,7299
C4-L8	Dez. 2017	0,9143	0,9014	0,8495	0,9208
C4-L8	Dez. 2018	0,9124	0,9120	0,9360	0,9296
S2-L8	Jan. 2018	0,8909	0,8807	0,8884	0,8887
S2-L8	Jan. 2019	0,8980	0,9019	0,9162	0,9186
S2-C4	Mar. 2018	0,8955	0,8345	0,8546	0,9012
S2-C4	Mar. 2019	0,9330	0,8401	0,9319	0,9482
Média		0,8608	0,8187	0,8713	0,9007

Fonte: Elaboração própria

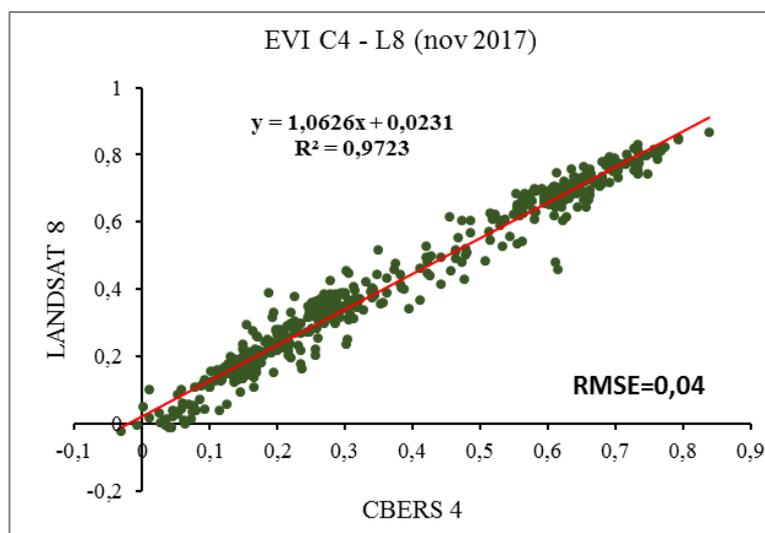
O Quadro 13 mostra os valores calculados para o coeficiente de correlação R², para os diferentes índices (NDVI, GNDVI, SAVI, EVI), lembrando que as comparações só foram feitas para imagens que possuíam datas próximas. Pode-se observar no Quadro 13 que os coeficientes de correlação mais elevados foram obtidos para o índice EVI (média de 0,9007), com o máximo valor de 0,9723 para a correlação da imagem do mês de novembro de 2017 entre o CBERS-4 e Landsat-8. Nota-se também que a correlação na data mencionada é a maior para todos os índices calculados, seguida pela correlação do Sentinel -2 e Landsat-8 para o mesmo mês. O valor médio mínimo foi obtido para o cálculo do GNDVI, com o valor de 0,3842 para a imagem de novembro de 2018 e a correlação C4-L8. Podemos assumir que os valores mínimos de correlação encontrados nas relações de C4-L8 e S2-L8 na imagem de novembro de 2018, são atribuídos a uma mudança nas culturas (possível colheita no dia 12 de novembro) semeadas na época (13 de novembro

S2, 11 de novembro L8, 15 de novembro C4), devido a que a imagem do L8 era de dias anteriores e poderia existir uma colheita nas zonas que apresentam valores dispersos.

A Figura 31 mostra um dos gráficos de correlação que são resumidos no apêndice A (página 106), que exhibe o valor máximo de correlação R^2 obtido para a relação do índice EVI do satélite CBERS-4 e LANDSAT-8.



Figura 31 – Correlação (R^2) do índice EVI entre os dias 15 e 16 d novembro de 2017 para os satélites L8 e C4 respectivamente (linha de tendência desenhada em vermelho).



Fonte: Elaboração própria

5 CONCLUSÃO

Nesta pesquisa buscou-se apresentar a importância do sensoriamento remoto na agricultura de precisão, assim como o conhecimento das técnicas para o processamento de imagens de livre acesso e os diferentes produtos que podem ser obtidos. Com base nisso foram utilizadas as imagens dos sensores SENTINEL-2, LANDSAT-8 e CBERS-4 no estabelecimento da correlação dos índices de vegetação NDVI, GNDVI, SAVI e EVI, e na análise das assinaturas espectrais para as culturas de Milho, Soja, e Arroz em uma zona de lavouras da cidade de Tremembé, para dois ciclos de semeadura (2017/18 e 2018/19). Depois dos resultados se faz evidente que existe uma marcada tendência na variação da curvatura de uma assinatura em certas faixas do espectro eletromagnético, todas as culturas apresentaram um ponto máximo em 0,56 μm (correspondente a banda do verde), valor que é amplamente relacionado ao conteúdo de nitrogênio N das plantas e outros pontos de inflexão na faixa do *redEdge* e NIR.

As primeiras afirmações que podem ser feitas depois da análise das assinaturas espectrais para as culturas de Milho, Soja, e Arroz nos ciclos de semeadura 2017/18 e 2018/2019 são que aparentemente existe um melhor desenvolvimento das culturas no segundo ciclo, de acordo com os dados encontrados nos índices e nas assinaturas que em geral mostram melhores respostas nas culturas do segundo ciclo, especialmente nas bandas 11 e 12 da faixa do SWIR, relacionadas com o conteúdo de humidade das plantações. Além disso, existe uma tendência à queda nas assinaturas quando as datas da colheita estão próximas, esse comportamento é marcado para todas as culturas.

Quanto ao comportamento dos índices de vegetação o índice que apresentou melhores coeficientes de correlação (R^2) foi o EVI (*Enhanced Vegetation Index*), com um valor médio de 0,9007 e um valor máximo de 0,9723 (RMSE de 0,04) para o mês de novembro de 2017 na correlação dos satélites CBERS-4 e LANDSAT-8. As imagens obtidas como produto do cálculo dos índices mostraram uma boa referência para obtenção de áreas com problemas na plantação, destacando-se o EVI como o índice que apresentou a maior porcentagem de variação nos pixels da imagem, o que poderia ajudar na otimização do tempo na organização das campanhas de campo.

Nesta pesquisa observou-se melhores respostas das imagens do CBERS-4 no cálculo do índice EVI em comparação com os índices NDVI, GNDVI, e SAVI, apresentando também valores mais equivalentes com os resultados obtidos com as imagens do

LANDSAT-8. Apesar de ser um sensor com uma correção atmosférica que ainda é muito empírica, o CBERS-4, mostrou que o comportamento das respostas dos ND (níveis digitais) das imagens produto do cálculo dos índices não foram muito distantes das imagens obtidas com o SENTINEL-2 e LANDSAT-8, portanto encontrou-se melhores valores de correlação entre o CBERS-4 e LANDSAT-8 usando o índice EVI. No caso do SENTINEL-2, apresentou melhores valores nas imagens correlacionadas com o sensor LANDSAT-8.

É necessário destacar que a Agricultura de precisão é uma técnica que contempla a aquisição de informação estatística do comportamento das culturas, com base no uso do sensoriamento remoto, útil tanto na planificação da plantação como nas predições de rendimento e datas de colheita. A aproximação nesta pesquisa faz uma referência a alguns dos produtos que podem ser gerados usando as imagens de satélite, mas tem que se comentar que os resultados somente poderão ser verificados juntando a análises de campo sobre o conteúdo de nutrientes nas plantações (nitrogênio, potássio, fosforo e outros), que geralmente são obtidos usando espectrorradiômetros ou métodos químicos fazendo amostras do solo e folhas.

Evidencia-se também que os índices de vegetação podem ser utilizados como ferramenta na detecção de possíveis áreas pontuais com afetações (falta de nutrientes) que evitaria as extensas campanhas de campo ou a aplicação de ações corretivas em áreas que não apresentam problema, otimizando o uso de agrotóxicos ou fertilizantes. Além disso destaca-se o índice EVI como um bom indicador no comportamento das culturas no início do ciclo vegetativo.

Uma vez mais evidencia-se a utilização do sensoriamento remoto como fonte geradora de uma base estatística útil na hora de estudar a tendência de uma área a gerar melhores rendimentos, dando maiores ferramentas aos agricultores para tomar ações concretas na hora de gerenciar os cultivos. Fora dos inconvenientes na informação faltante, o estudo mostra grandes potencialidades para o uso das imagens do SENTINEL-2, o acesso e disponibilidade a informação, documentação e ferramentas de aplicação, assim como a variedade de índices de vegetação gerados para uso exclusivo destas imagens (que são as únicas com a região *redEdge*) é uma grande evidência da importância do conhecimento e procura de novas metodologias e produtos que se possam gerar na área da agricultura de precisão. Assim como também se destaca a potencialidade do uso das imagens do CBERS-4 que sendo um satélite sem muitas aplicações na área da Agricultura

de precisão, foi verificado que pode ser usado junto ao LANDSAT-8 e SENTINEL-2, obtendo resultados muito próximos.

5.1. TRABALHOS FUTUTOS

Acompanhamento das culturas no desenvolvimento dos próximos ciclos e junto com testes de solo e espectrorradiômetros, relacionar as diferenças encontradas nos índices com as variações no solo e nas assinaturas espectrais.

Utilização de imagens de drone no acompanhamento das culturas nas diferentes etapas de desenvolvimento, comparar com as imagens e índices obtidos usando LANDSAT-8, SENTINEL-2 e CBERS-4.

Acrescentar os estudos usando as imagens do CBERS-4 para os seguintes períodos de colheita, usando diferentes índices de vegetação e diferentes metodologias de correção atmosférica. 

Geração de mapas de produtividade associados ao rendimento das colheitas e à variabilidade nas áreas estudadas com sensoriamento remoto.

REFERÊNCIAS

ARONOFF, S. (1989). **Geographic information systems: a management perspective**. Ottawa, WDL Publications, 295 p. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S1364815203001051>. Acessado em: 15 de jan. 2019



BARBOSA, K. M. do N. (2006) **Monitoramento espacial de biomassa e carbono orgânico da vegetação herbácea de várzea na Amazônia Central**. Curitiba: Universidade Federal do Paraná, Tese de Doutorado, 131 p. Disponível em: <https://acervodigital.ufpr.br/handle/1884/4450>. Acessado em: 15 de jan. 2019

BARBOSA, C. NOVO, E. MARTINS, V. (2019). **Introdução ao Sensoriamento Remoto de Sistemas Aquáticos**. Instituto Nacional de Pesquisas Espaciais – São Jose dos Campos. Disponível em: <http://www.dpi.inpe.br/labisa/livro/res/conteudo.pdf>. Acessado em: 30 de jan. 2019

BARSI, J. LEE, K. KVARAN, G.L. MARKHAM, B. PEDELTY, J. (2014). **The Spectral Response of the Landsat-8 Operational Land Imager**. Remote Sensing. 6. 10232-10251. 10.3390/rs61010232. Disponível em:

https://www.researchgate.net/publication/278721038_The_Spectral_Response_of_the_Landsat-8_Operational_Land_Imager. Acesso em: 12 de nov.2018.

BAUER, M. E., & CIPRA, J. E. (1973). **Identification of agricultural crops by computer processing of ERTS MSS data. LARS Technical Reports**. Paper 20. <http://docs.lib.purdue.edu/larstech/20>. W. Lafayette, IN: Purdue Univ.

BLACKBURN, G. A. (2007). **Hyperspectral remote sensing of plant pigments**. Journal of Experimental Botany, 58, 855e 867. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1516-35982009000900001. Acesso em: 7 jun. 2019.

BOOCHS, F., KUPFER, G., DOCKTER, K., KUHBAUCH, W., (1990). **Shape of the red-edge as vitality indicator for plants**. Int. J. Remote Sens. 11, 1741–1753.

BOELTER, P; TODT, V; DA SILVA, M. (2019). **Análise comparativa dos modelos de vegetação NDVI e SAVI a partir de imagens CBERS-4/MUX e LANDSAT-8/oli para o município de São Francisco de Paula**. In: ANAIS DO XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Santos. Disponível em: <https://proceedings.science/sbsr-2019/trabalhos/analise-comparativa-dos-modelos-de-vegetacao-ndvi-e-savi-a-partir-de-imagens-cbers-4-mux-e-landsat-8-oli-para-o-municipi>. Acesso em: 20 fev. 2019.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Portaria nº 852 - **Art. 1º Criar a Comissão Brasileira de Agricultura de Precisão – CBAP.** Diário Oficial da República Federativa do Brasil, Brasília, DF, 21 set. 2012. Seção 1, n. 184. Disponível em: http://www.cntp.embrapa.br/biblio/do/p_do42.htm. Acesso em: 10 jun. 2019.

BURROUGH, P.A. (1986). **Principles of geographical information systems for land resources assessment.** Oxford, Clarendon Press, 193 p.

CÂMARA, G. (1999). **Sistemas de informações geográficas para aplicações ambientais e cadastrais: uma visão geral.** <http://www.dpi.inpe.br/geopro/trabalhos/analise.pdf>. Acessado em: 23 Jan 2019.

CHAVEZ, J. P.S. (1988). **An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data.** Remote Sensing of Environment, New York, v.24, p. 459-479.

CONAB. **Safras 2018.** Disponível em: <https://portaldeinformacoes.conab.gov.br/index.php/safras?view=default>. Acesso em: 4 jan. 2019.

CORTI, M. (2017). **MULTISPECTRAL AND HYPERSPECTRAL SENSING FOR NITROGEN MANAGEMENT IN AGRICULTURE.** Università Degli Studi di Milano. Dipartimento di Scienze Agrarie e Ambientali - Produzione, Territorio, Agroenergia. Disponível em: https://pdfs.semanticscholar.org/71ea/6254e841155cbfd75dcf1a478a1426365826.pdf?_ga=2.56723682.974673029.1576515590-2070416567.1576515590. Acesso em: 5 de setembro 2019.

COSTA, S., SANTOS, V., MELO, D., E SANTOS, P. (2017). **Evaluation of Landsat 8 and Sentinel-2A data on the correlation between geological mapping and NDVI.** First IEEE International Symposium of Geoscience and Remote Sensing (GRSS-CHILE). doi:10.1109/grss-chile.2017.7996006. Disponível em: https://www.researchgate.net/publication/318806783_Evaluation_of_Landsat_8_and_Sentinel-2A_data_on_the_correlation_between_geological_mapping_and_NDVI. Acesso em: 12 de setembro 2019.

CRÓSTA, A.P. (2002). **Processamento Digital de Imagens de Sensoriamento Remoto.** Campinas, SP: IG/UNICAMP.

DELEGIDO, J., VERRELST, J., ALONSO, L., & MORENO, J. (2011). **Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content.** Sensors (Basel, Switzerland), 11(7), 7063–7081. doi:10.3390/s110707063. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3231680/>. Acesso em: 5 de maio 2019.

DE CAMPOS, A. C., DE MENDONÇA, J., VILELA, A., BASSOI, L., INAMASU, R. (2014). **Agricultura de precisão - Resultados de um Novo Olhar**. Brasília, DF: Embrapa, 2014. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/113993/1/Agricultura-de-precisao-2014.pdf>. Acesso em: 12 de dic. 2019

DI MAIO, A. FRIEDRICH, T. MORAES, E. PEREIRA, G. MOREIRA, M. SAUSEN, T. FLORENZANO, T. Brasil, (2018). **Sensoriamento Remoto**. Disponível em: http://www.cdcc.usp.br/cda/oba/aeb/sensoriamento_remoto_alta_resolucao_2008.pdf. Acesso em: 20 mar. 2019.

DIKER, K. (1998). **Use of geographic information management systems (GIMS) for nitrogen management**. Ph. D. Thesis, Department of Chemical and Bioresource Engineering, Colorado State University, Spring 1998

EMBRAPA. Visão 2014-2034: **o futuro do desenvolvimento tecnológico da agricultura brasileira**. Brasília, DF: Embrapa, 2014b. 194 p.

EMPRESA PAULISTA DE PLANEJAMENTO METROPOLITANO S.A. (EMPLASA). **Ortofotocartas**. São Paulo, 2007. Escala 1:5000.

ESA, (2015). **Sentinel-2 User Handbook**. Disponível em: https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook. Acesso em: 7 jan. 2019.

ESCOLÀ, A. BADIA, N. ARNÓ, J. MARTÍNEZ-CASASNOVAS, J. **Using Sentinel-2 images to implement Precision Agriculture techniques in large arable fields: First results of a case study**. GEOSS Evolution. [2017]. Disponível em: <http://www.earthobservations.org/geoss.php>. Acesso em: 7 jan. 2019.

EO Portal Directory (Sharing Earth Observation Resources). (2019). Disponível em: <https://directory.eoportal.org/web/eoportal/satellite-missions>. Acesso em: 20 de fev. 2019.

FRAMPTON, W., DASH, J., WATMOUGH, G., MILTON, E. (2013). **Evaluating the Capabilities of Sentinel-2 for Quantitative Estimation of Biophysical Variables in Vegetation** ISPRS Journal of Photogrammetry and Remote Sensing, vol. 82, pp. 83-92, 10.1016/j.isprsjprs.2013.04.007. Disponível em: <https://www.sciencedirect.com/science/article/pii/S092427161300107X>. Acesso em: 15 de fev.2019.

FIGUEIREDO, D. (2005). **Conceitos Básicos de Sensoriamento Remoto**. Disponível em: http://www.clickgeo.com.br/wpcontent/uploads/2013/04/conceitos_sm.pdf. . Acesso em: 12 de fev.2019.

HERBEI, M.V.; POPESCU, C. A.; BERTICI, R.; SMULEAC, A.; POPESCU, G. (2016). **Processing and Use of Satellite Images in Order to Extract Useful Information in Precision Agriculture**. Acesso em: 12 de jan. 2019

HUETE, A.R., (1988). **A Soil Adjusted Vegetation Index (SAVI)**. Remote Sens. Environ. 25, 295–309. Disponível em: <http://maestrelab.com/wp-content/uploads/2015/10/Ecollnd2013.pdf>. Acesso em: 10 de nov.2018.

INPE. **CBERS 3&4 satellite specification**. São José dos Campos, INPE, 2005. 28p. (relatório interno, RB-HDS-023/01).

JENSEN, J. R. (2007). **Remote sensing of the environment: An earth resource perspective (2nd ed.)**. Upper Saddle River, NJ: Pearson Education, Inc. Disponível em: <http://www.gisagmaps.com/scatter-background/> Acessado em: 12 de jan.2019

KEMERER, A.; DI BELLA, C.; MELCHIORI, R.; BENENCH, A.; ALVAREZ, R. (2007). **Comparación de índices espectrales para la predicción del IAF en campos de maíz. Congreso de teledetección: hacía mejor entendimiento de la dinámica global y regional**. Asociación Española Teledetección. Disponível em: https://eprints.ucm.es/31423/1/TFM_Juan_Diaz_Cervignon.pdf. Acessado em: 14 de jan.2019

KORHONEN, L., PACKALEN, P., RAUTIAINEN, M. (2017) **Comparison of Sentinel-2 and Landsat 8 in the estimation of boreal forest canopy cover and leaf area index**, Remote Sens. of Environ., vol.195, pp. 259-274, mar. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425717301256>. Acessado em: 25 de jan.2019

KUMAR, L., SKIDMORE, A., BIJKER, W., SCHMIDT, K. (1974). **Use of remote sensing and GIS for sustainable land management**. Disponível em: <http://docs.fct.unesp.br/docentes/cartoenner/PPGCC/Hiperespectral/Lab%208%20-%20Vegetation%20and%20agriculture/chapter01.pdf> Acessado em: 20 de jan.2019

LEÃO, E. e PONZONI, F. (2011). **Introdução ao sensoriamento remoto**. São Jose dos campos- Brasil. Disponível em: http://www.dpi.inpe.br/Miguel/AlunosPG/Jarvis/SR_DPI7.pdf Acessado em: 28 de jan.2019

LIAGHAT, S. e BALASUNDRAM, S.K. (2010). A Review: **The Role of Remote Sensing in Precision Agriculture**. Am. J. Agri. & Biol. Sci., 5 (1): 50-55, 2010. ISSN 1557-4989.

LIU HQ, HUETE AR. (1995). **A feedback based modification of the NDV I to minimize canopy background and atmospheric noise**, IEEE Trans. Geosci. Remote Sensing, 33: 457-465. Disponível em: <https://pdfs.semanticscholar.org/2f24/b4eca2a5bc8dad94e651ba748b5c4039ba5b.pdf>. Acesso em: 2 de abr. 2019.

MARTÍNEZ, L. J. (2017). **Relationship between crop nutritional status, spectral measurements and Sentinel 2 images**. *Agron. C.* 35(2), 205-215. Doi: 10.15446/gron.colomb.v35n2.62875.

MARTINS, V., SOARES, J., NOVO, E., BARBOSA, C., PINTO, C., ARCANJO, J. KALEITA, A. (2018). **Continental-scale surface reflectance product from CBERS-4 MUX data: assessment of atmospheric correction method using coincident Landsat observations**. *Remote Sens. Environ.*, 218 (2018), pp. 55-68. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425718304280>
Acesso em: 15 de abr. 2019.

MATARAZZO, A. **As Áreas Verdes do Tremembé**. *Brasil Econômico*, São Paulo, 17 mar. 2012. p. 3.

MENESES, P. & ALMEIDA, T. (2012). **Introdução ao processamento de imagens de Satélite**. Brasília

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. 2018. **Agricultura de Precisão de Precisão (Boletim Técnico)**. Brasília-Brasil - ISBN 978-85-99851-90-6.

MOREIRA, M.A. (2012). **Fundamentos de sensoriamento remoto e Metodologias de aplicação**. Universidad Federal de Viçosa.

MULLA, D. J. (2013). **Twenty five years of Remote Sensing in precision agriculture: Key advances and remaining knowledge gaps**. *Biosystems Engineering II4* (2013): 358-371. Disponível em: <http://dx.doi.org/10.1016/j.biosystemseng.2012.08.009>. Acesso em: 2 de jan 2019.

NICODEMUS, F.E.; RICHMOND, J.C.; HSIA, J.J. (1977). **Geometrical Considerations and Nomenclature for Reflectance**; National Bureau of Standards, US Department of Commerce: Washington, DC, USA,. Disponível em: <http://physics.nist.gov/Divisions/Div844/facilities/specphoto/pdf/geoConsid.pdf>. Acesso em: 12 de ago. 2018.

NOWATZKI, J., R. ANDRES e K. KYLLO, 2004. **Agricultural remote sensing basics**. Disponível em: <http://www.ag.ndsu.edu/pubs/ageng/gis/ae1262.pdf>. Acesso em: 7 de junho 2019.

ORYCH, A; WALCZYKOWSKI, P; DĄBROWSKI, R e KUTYNA, E. (2013). **Using plant spectral response curves in detecting plant stress**. *Ecological Questions*. 17. 67-74. 10.12775/ecoq-2013-0017. Disponível em: https://www.researchgate.net/publication/260426131_Using_plant_spectral_response_curves_in_detecting_plant_stress. Acesso em: 25 de junho 2019.

PADRÓ, J., MUÑOZ, F., AVILA, L., PESQUER, L., PONS, X. (2018). **Radiometric Correction of Landsat-8 and Sentinel-2A Scenes Using Drone**

Imagery in Synergy with Field Spectroradiometry. Remote Sensing. 10. 1687. 10.3390/rs10111687. Disponível em: <https://www.mdpi.com/2072-4292/10/11/1687>. Acesso em: 29 de jun.2019.

PRADHAN, S., BANDYOPADHYAY, K.K., JOSHI, D.K. **Canopy reflectance spectra of wheat as related to crop yield, grain protein under different management practices.** (2012) Journal of Agrometeorology, 14 (1), pp. 21-25. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84865202042&partnerID=40&md5=818371d19076bd3df0d4a586fe5fdb5d>. Acesso em: 12 de junho 2019.

PASQUALOTTO, N., DELEGIDO, J., VAN WITTENBERGHE, S., RINALDI, M., & MORENO, J. (2019). **Multi-Crop Green LAI Estimation with a New Simple Sentinel-2 LAI Index (SeLI).** Sensors (Basel, Switzerland), 19(4), 904. doi:10.3390/s1904090. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6412664/>. Acesso em: 22 de jun.2019.

PINTER, P. J., JR., HATFIELD, J. L., SCHEPERS, J. S., BARNES, E. M., MORAN, M. S., DAUGHTRY, C. S. T., et al. (2003). **Remote sensing for crop management.** Photogrammetric Engineering and Remote Sensing, 69, 647e 664.

PEREIRA, L. SILVA, D. PAMBOUKIAN, S. 2016. **Sensoriamento Remoto Aplicado À Agricultura de Precisão no Cultivo de Bambu.** Universidade Presbiteriana Mackenzie (UPM)-São Paulo. Disponível em: https://www.mackenzie.br/fileadmin/OLD/62/ARQUIVOS/PUBLIC/user_upload/_importe_d/fileadmin/LABGEO/Trabalhos/2017/REVISTA_-_SENSORIAMENTO_REMOTO_APLICADO_A_AGRICULTURA_DE_PRECISAO_NO_CULTIVO_DE_BAMBU.pdf. Acesso em: 10 de jan. 2019.

ROUSE, J.W., HAAS, R.H., SCHELI, J.A., DEERING, D.W., 1973. **Monitoring vegetation systems in the great plains with ERTS.** In: Third ERTS Symposium, NASA SP-351 I, pp. 309–317. Disponível em: <http://maestrelab.com/wp-content/uploads/2015/10/EcolInd2013.pdf>. Acessado em: 22 de fev. 2019.

SANCHEZ, I., ANDRADE, R., QUARTAROLI, C., GONÇALVES, C. (2011). **Análise comparativa de três métodos de correção atmosférica de imagens Landsat 5 TM para obtenção de refletância de superfície e NDVI.** Simpósio Brasileiro de Sensoriamento Remoto – Curitiba Brasil.

SCHLEMMER, M.R., D.D. FRANCIS, J.F. SHANAHAN, AND J.S. SCHEPERS. 2005. **Remotely measuring chlorophyll content in corn leaves with differing nitrogen levels and relative water content.** Agron. J. 97(1), 106-112. Doi: 10.1021/ac60214a047.

SEYHAN, I. 2004. RS & GIS (Remote Sensing & Geographical Information Systems). Pp. 4. Disponível em: http://www.mta.gov.tr/RSC_WEB/rsgis.html. Acesso em: 12 de abr.2019.

SHANAHAN, J.F., SCHEPERS, J.S., FRANCIS, D.D., VARVEL, G.E., WILHELM, W.W., TRINGE, J.M., SCHLEMMER, M.R. AND MAJOR, D.J. (2001), **Use of Remote-Sensing Imagery to Estimate Corn Grain Yield**. *Agron. J.*, 93: 583-589. doi:10.2134/agronj2001.933583x. Disponível em: <https://acess.onlinelibrary.wiley.com/action/showCitFormats?doi=10.2134%2Fagronj2001.933583x>. Acesso em: 15 de abr.2019.

SOBRINO, J., JIMÉNEZ-MUÑOZ, J. e PAOLINI, L. (2004). **Land surface temperature retrieval from LANDSAT TM 5**. *Remote Sensing of Environment*, Elsevier, 90, 434-440. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425704000574> Acesso em: 25 de abr.2019.

STAR, Jeffrey L.; ESTES, John E.; MCGWIRE, Kenneth C. (Ed.). **Integration of geographic information systems and remote sensing**. Cambridge University Press, 1997. Disponível em: <https://geotecnologias.wordpress.com/2016/05/09/resolucao-radiometrica/>. Acesso em: 22 de jun.2019.

TANRIVERDI, C. 2006. **A Review of remote sensing and vegetation indices in precision farming**. *KSU, J. Sci. Eng.* 9(1): 69-76.

U. S. Geological Survey. 2009. **Landsat 8 Surface Reflectance Code (LaSRC) Product Guide**. Disponível em: https://prd-wret.s3-us-west-2.amazonaws.com/assets/palladium/production/atoms/files/LSDS-1368_L8_Surface_Reflectance_Code_LASRC_Product_Guide-v2.0.pdf. Acesso em: 12 jan. 2019.

VERMOTE, E. F. **Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: an overview**. *IEEE Transactions on Geoscience and Remote Sensing*, New York, v.35, n.3, p.675-686, 1997. Disponível em: <https://pdfs.semanticscholar.org/61ad/698abc800bbb8a25b2ada0671d5c9df659cc.pdf>. Acesso em: 20 jan. 2019.

WILSON, J; ZHANG, C e KOVACS, J. (2014). **Separating Crop Species in Northeastern Ontario Using Hyperspectral Data**. *Remote Sensing*. 6. 925-945. 10.3390/rs6020925. Disponível em: https://www.researchgate.net/publication/260061613_Separating_Crop_Species_in_Northeastern_Ontario_Using_Hyperspectral_Data. Acesso em: 12 jan. 2019.

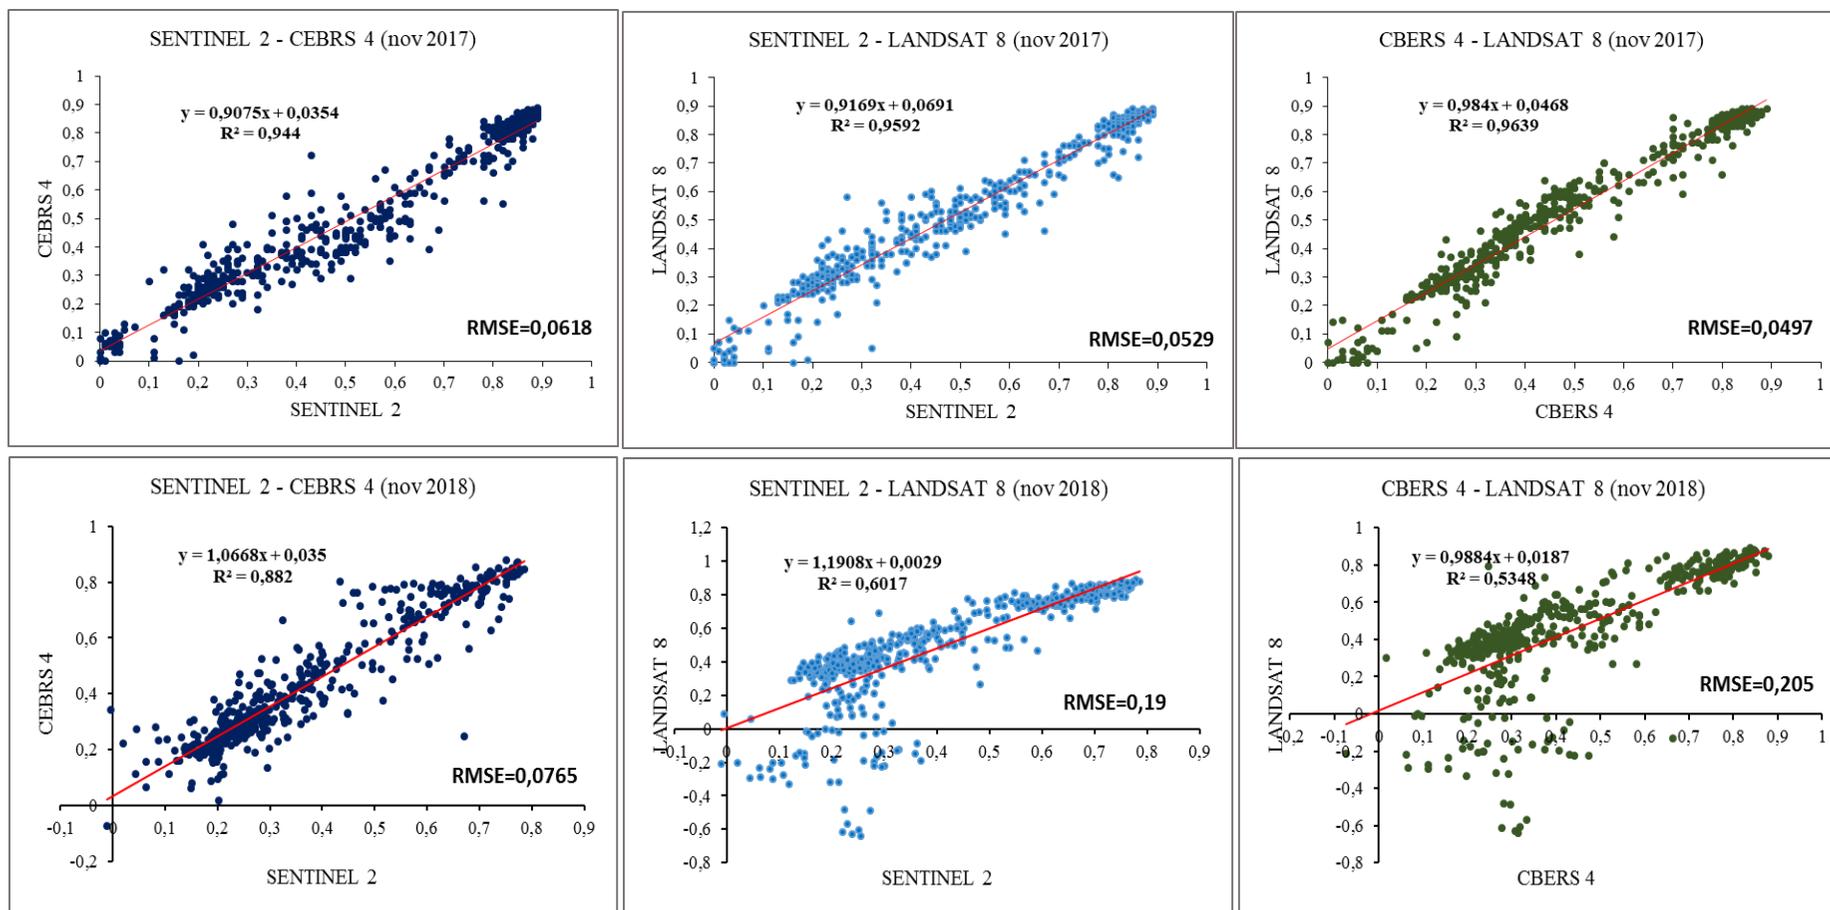
XUE, J. e SU, B. (2017). **Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications**. *Journal of Sensors*. 2017. 1-17. 10.1155/2017/1353691. Disponível em: https://www.researchgate.net/publication/317146924_Significant_Remote_Sensi

ng_Vegetation_Indices_A_Review_of_Developments_and_Applications. Acesso em: 2 de jan. 2020

ZHANG, H., ROY, D, YAN, L., LI, Z., HUANG, H., VERMOTE, E., SKAKUN, S., ROGER, J. (2018). **Characterization of Sentinel-2A and Landsat-8 top of atmosphere, surface, and nadir BRDF adjusted reflectance and NDVI differences**. Remote Sensing of Environment. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425718301883>. Acesso em: 2 de jan. 2019

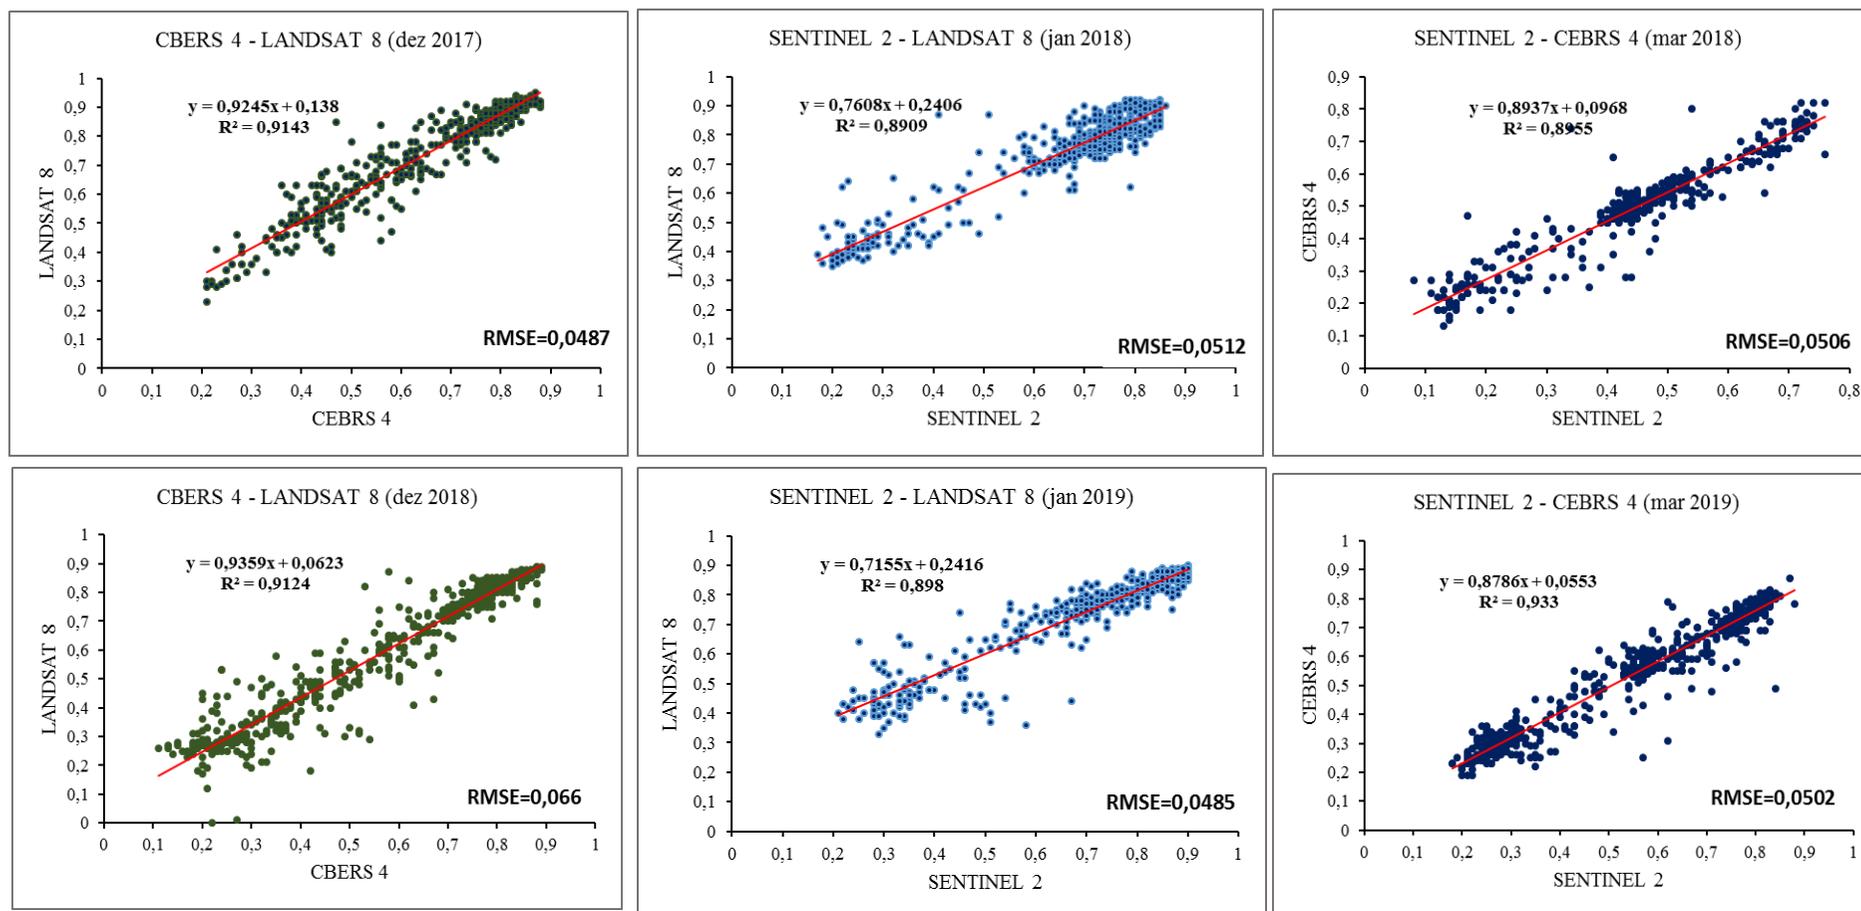
APÊNDICE A – Correlação das imagens SENTINEL-2, CBERS-4 e LANDSAT-8

Figura A32 – Correlação do índice NDVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.



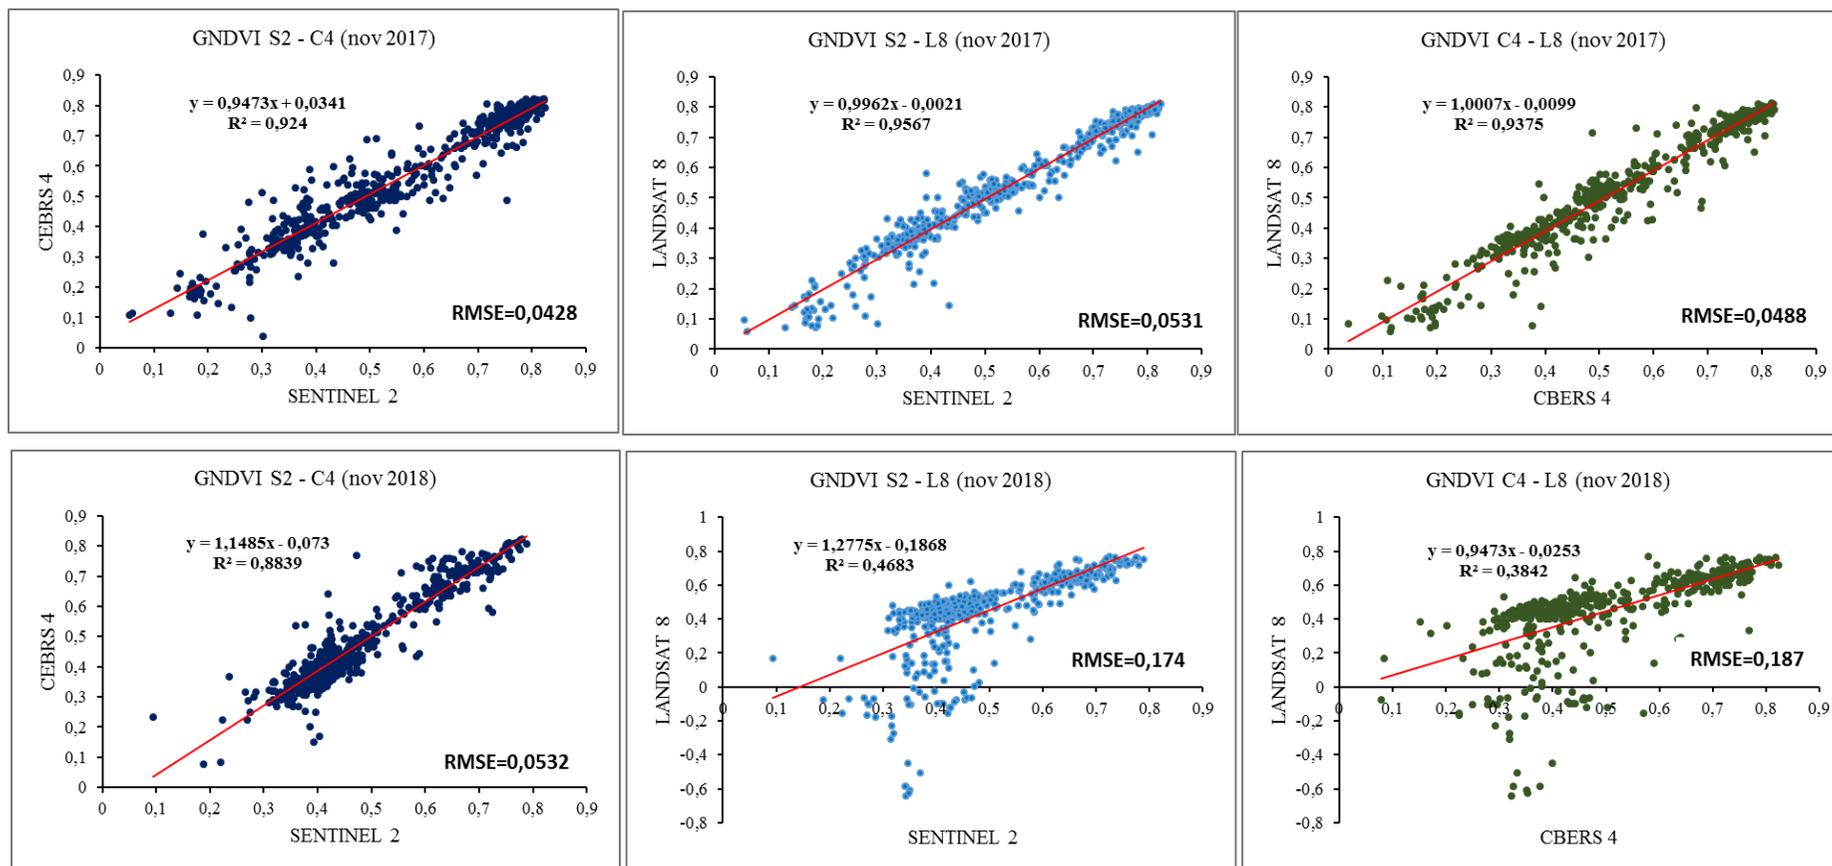
Fonte: Elaboração própria

Figura A33 – Correlação do índice NDVI para os meses de dezembro, janeiro e março (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.



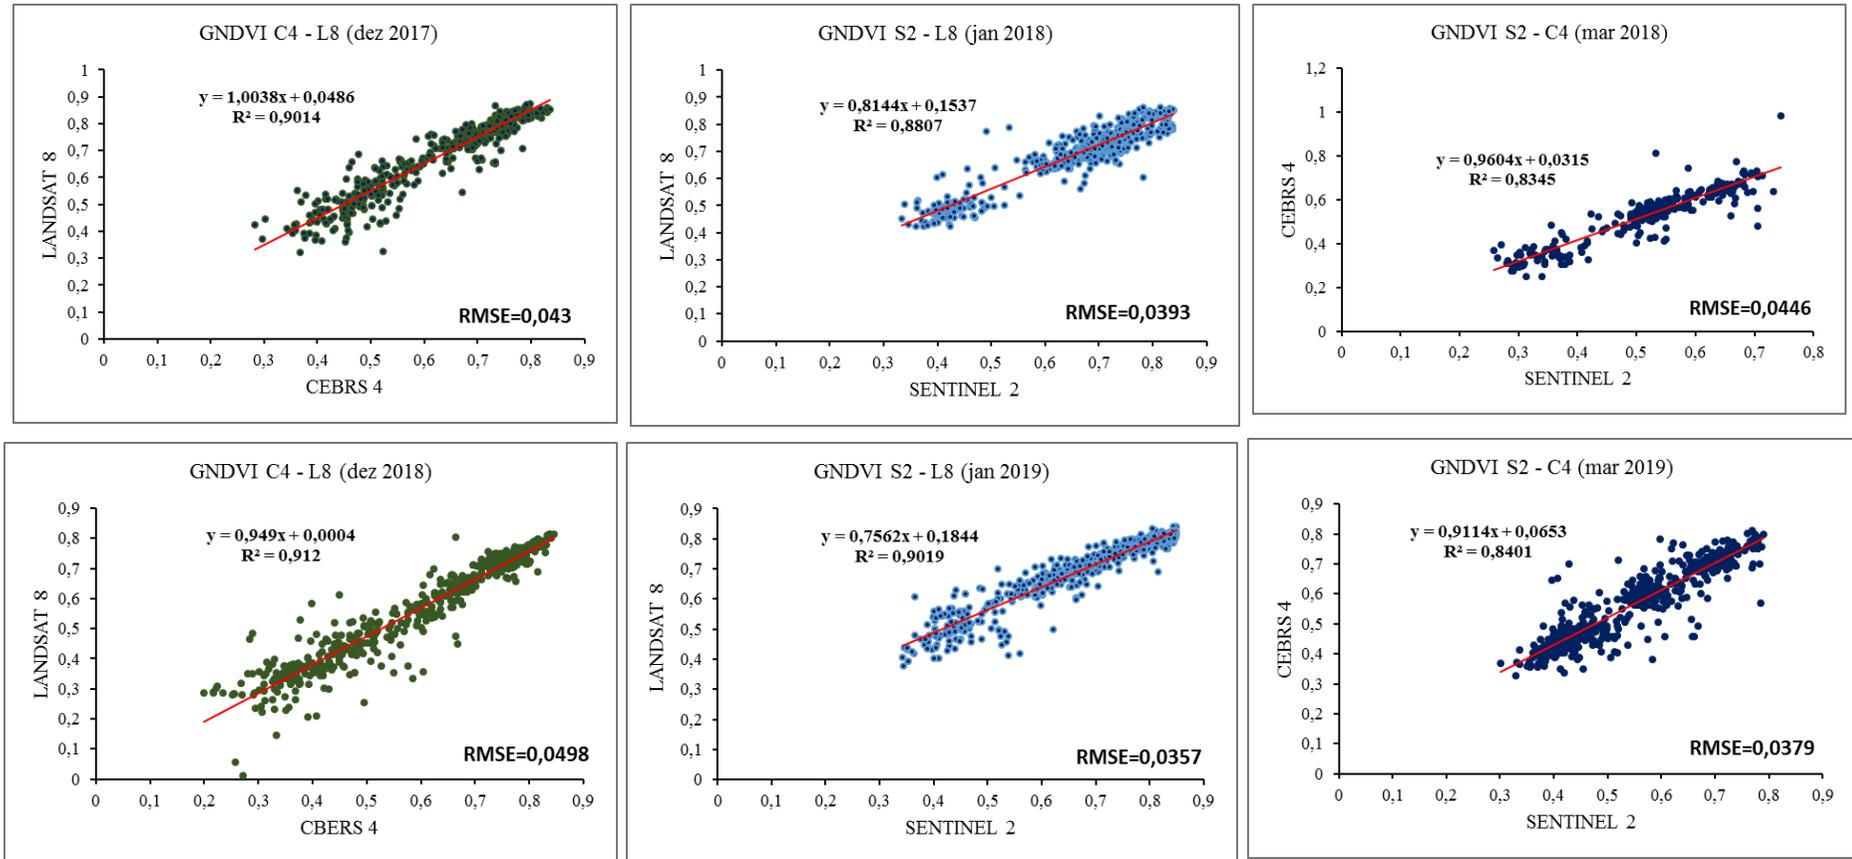
Fonte: Elaboração própria

Figura A34 – Correlação do índice GNDVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEI-2, LANDSAT-8 e CBERS-4.



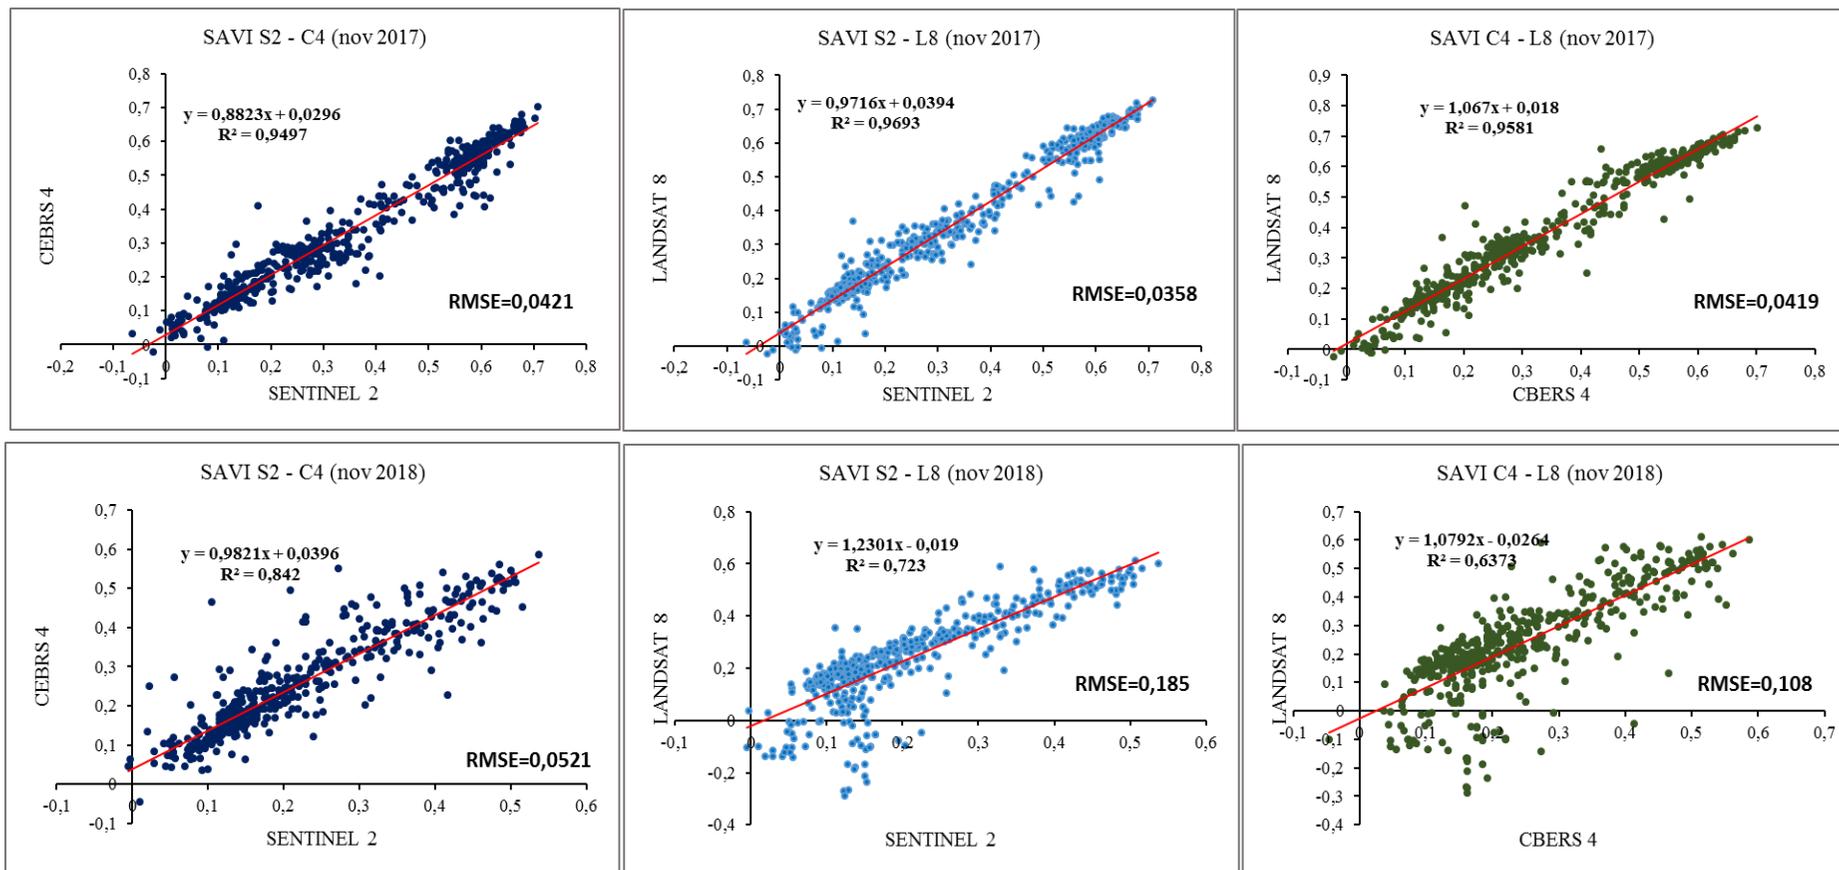
Fonte: Elaboração própria

Figura A35 – Correlação do índice GNDVI para os meses de dezembro, janeiro e março (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.



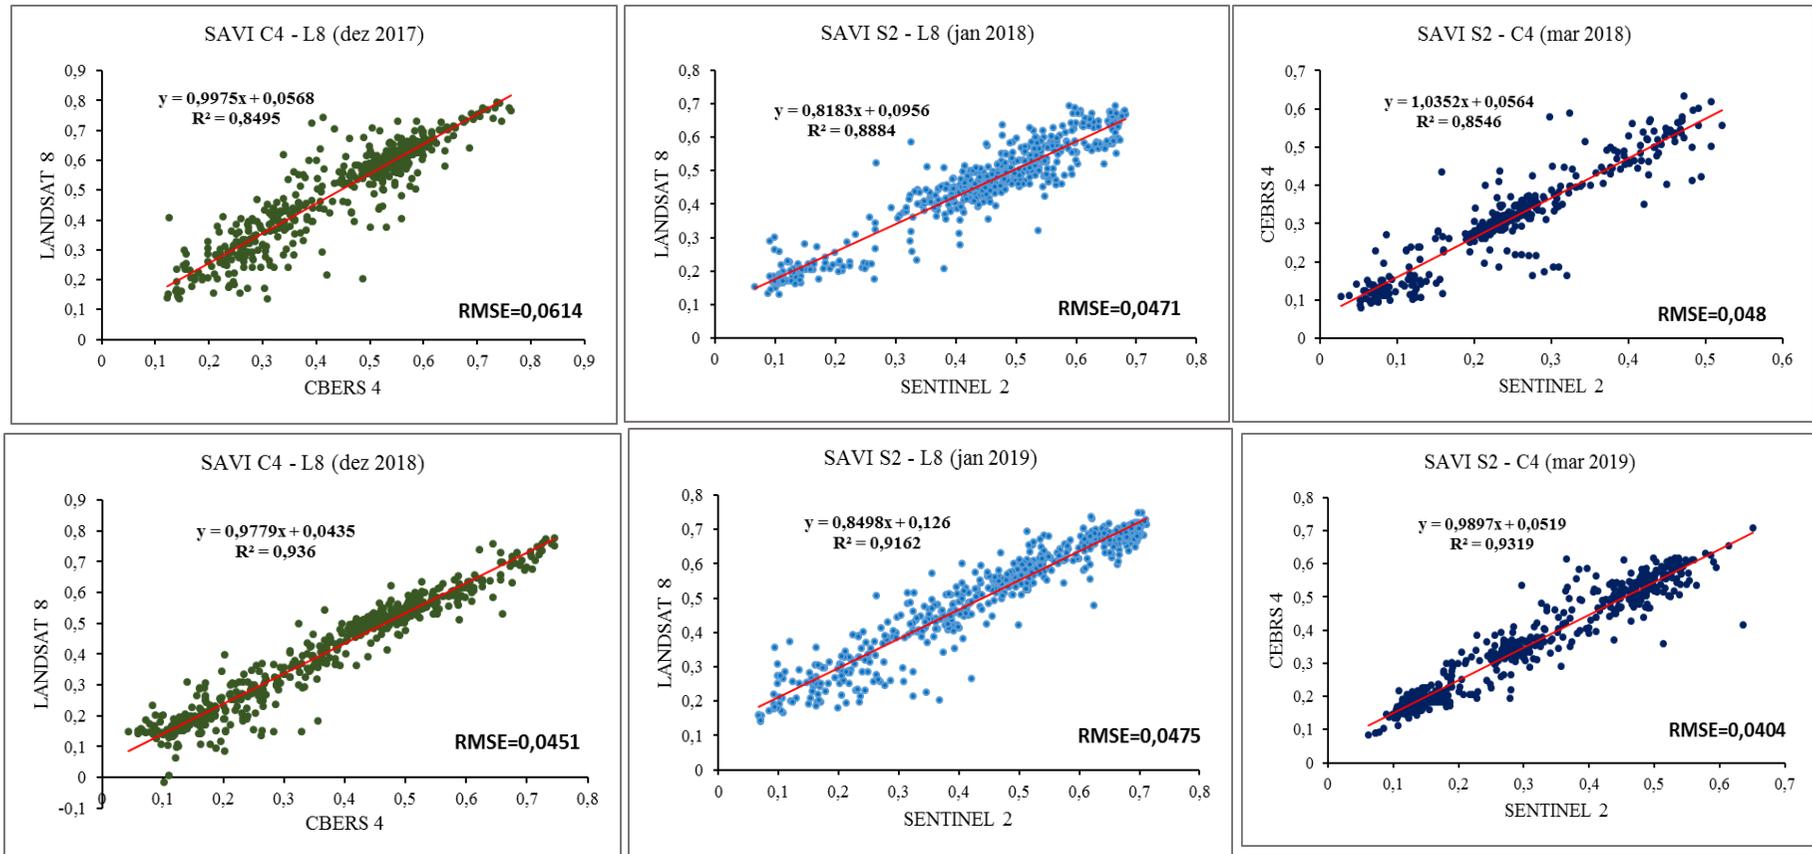
Fonte: Elaboração própria

Figura 36 – Correlação do índice SAVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.



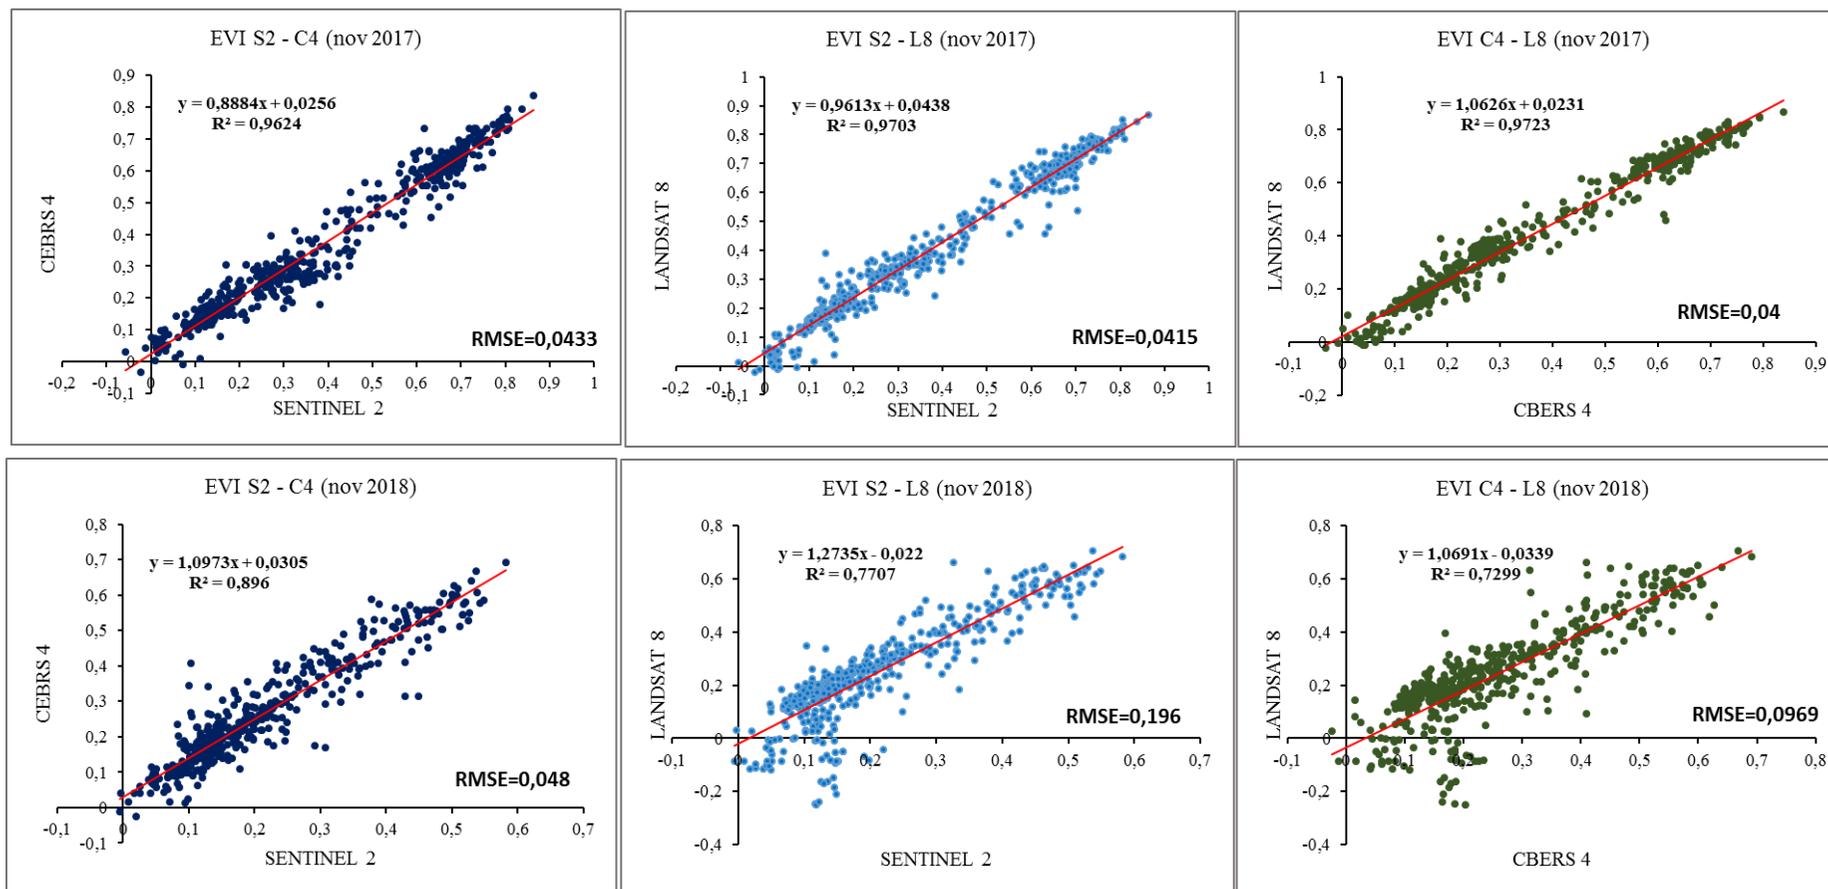
Fonte: Elaboração própria

Figura 37 – Correlação do índice SAVI para os meses de dezembro, janeiro e março (ciclos 2017/2018 e 2018/2019) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.



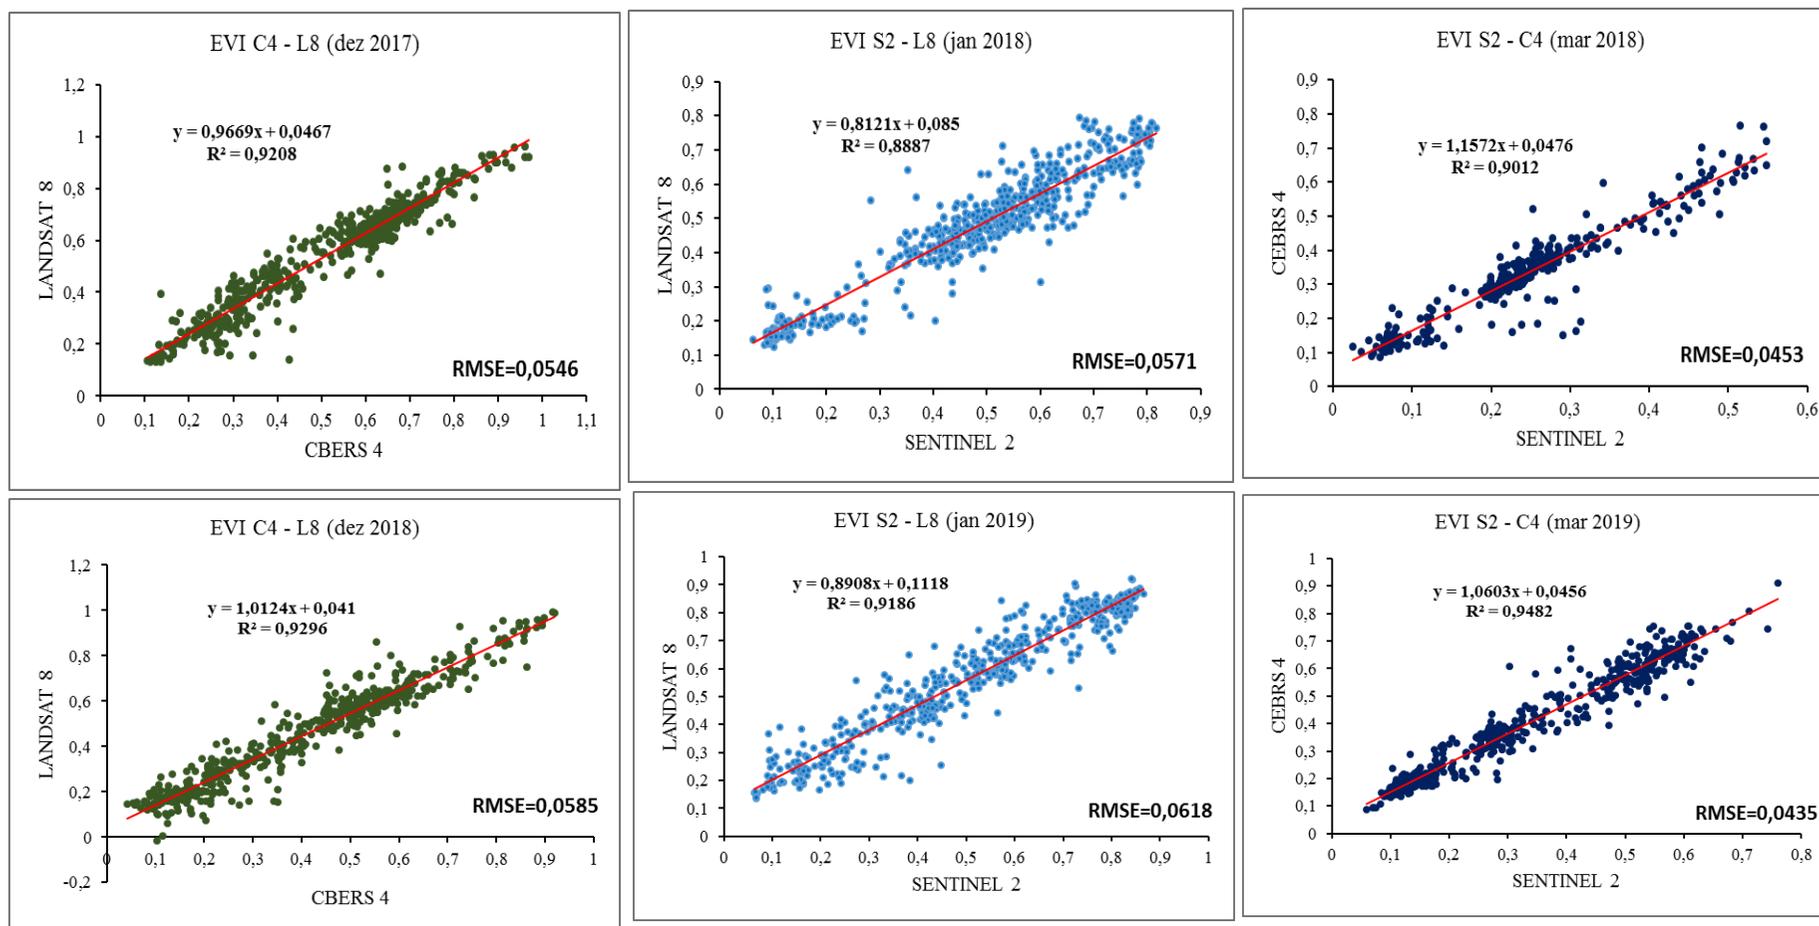
Fonte: Elaboração própria

Figura 38 – Correlação do índice EVI para o mês de novembro (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4.



Fonte: Elaboração própria

Figura 39 – Correlação do índice EVI para os meses de dezembro, janeiro e março (ciclos 2017/18 e 2018/19) entre os satélites SENTINEL-2, LANDSAT-8 e CBERS-4



Fonte: Elaboração própria