

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – CAMPUS DE CASCAVEL
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS
PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

MAPEAMENTO DE SOJA E MILHO COM MINERAÇÃO DE DADOS E IMAGENS
SINTÉTICAS LANDSAT E MODIS

LUCAS VOLOCHEN OLDONI

CASCAVEL – PARANÁ – BRASIL

JANEIRO – 2018

LUCAS VOLOCHEN OLDONI

**MAPEAMENTO DE SOJA E MILHO COM MINERAÇÃO DE DADOS E IMAGENS
SINTÉTICAS LANDSAT E MODIS**

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Agrícola, em cumprimento parcial aos requisitos para obtenção do título de Mestre em Engenharia Agrícola, área de concentração em Engenharia de Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Erivelto Mercante.
Co-Orientador: Dr. João Francisco Gonçalves Antunes.

CASCADEL – PARANÁ – BRASIL

JANEIRO – 2018

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Sistema de Bibliotecas - UNIOESTE)

O38m	<p>Oldoni, Lucas Volochen. Mapeamento de soja e milho com mineração de dados e imagens sintéticas Landsat e MODIS / Lucas Volochen Oldoni. --- Cascavel (PR), 2018. 122 f.:il.</p> <p>Orientador: Prof. Dr. Erivelto Mercante. Coorientador: Prof. Dr. João Francisco Gonçalves Antunes. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Campus de Cascavel, 2018, Programa de Pós-Graduação em Engenharia Agrícola. Inclui Bibliografia</p> <p>1. Imagens de Sensoriamento remoto. 2. Métricas estatísticas. 3. Métricas fenológicas. I. Erivelto, Mercante. II. Antunes, João Francisco Gonçalves. III. Universidade Estadual do Oeste do Paraná. IV. Título.</p> <p>CDD 630.285</p>
------	--

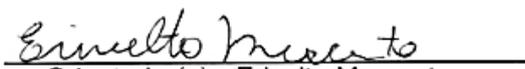
Rosângela A. A. Silva – CRB 9ª/1810

Revisão português, inglês e normas: Dhandara Capitani em 16/03/2018.

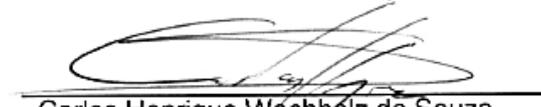
LUCAS VOLOCHEN OLDONI

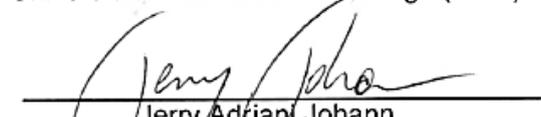
Mapeamento de Soja e Milho com Mineração de Dados e Imagens Sintéticas
LANDSAT e MODIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Mestre em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:


Orientador(a) - Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)


Carlos Henrique Wachholz de Souza
Universidade Estadual de Maringá (UEM)


Jerry Adriani Johann
Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 5 de fevereiro de 2018

BIOGRAFIA

Lucas Volochen Oldoni, nascido em 23/03/1993, natural da cidade de Cascavel, Paraná, Brasil, concluiu o curso de graduação em Engenharia Agrícola, pela Universidade Estadual do Oeste do Paraná – UNIOESTE, no ano de 2015. No ano de 2016 ingressou no Programa de Pós-Graduação em Engenharia Agrícola – Engenharia de Sistemas Biológicos e Agroindustriais, sob orientação do Prof. Dr. Erivelto Mercante, estudando o tema: Mapeamento de soja e milho com mineração de dados e imagens sintéticas Landsat e MODIS.

Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes.

Martin Luther King

AGRADECIMENTOS

Agradeço a Deus pela vida, por ter iluminado meu caminho e me abençoado com tantas graças;

Agradeço aos meus pais, Olivino e Ana, e ao meu irmão e à minha irmã, Luan e Luana, por todo o apoio nas vitórias e nas derrotas, todo o amor e a compreensão;

Agradeço ao Prof. Dr. Erivelto Mercante, meu orientador, pela sabedoria, pela paciência e a compreensão, e principalmente, pela confiança e a amizade ao longo desses anos;

Ao meu co-orientador, Dr. João Francisco Gonçalves Antunes, por toda a ajuda e o conhecimento transmitido e pelo incentivo no desenvolvimento da pesquisa;

Ao Prof. Dr. Jerry e a Profa. Dra. Maritane, pelo conhecimento e pela amizade ao longo dos anos;

Aos meus amigos da Engenharia Agrícola, PGEAGRI e de demais cursos, pela amizade, o apoio e os risos compartilhados, pois, com vocês ao meu lado, tudo ficou mais fácil;

Aos amigos do GeoLab, Carlos, Luiz, Ivã, Bruno, Isaque, Douglas, Octavio, Alex, Alex Paludo e Willyan, pela amizade, conhecimentos e auxílios prestados;

Aos antigos companheiros de GeoLab, Victor, Jefferson, Mônica, Marcus, Carlos Henrique, Suzana, Rafaela, Diego, Paulo e Luiz Peruzzo, pela amizade e por todo o conhecimento transmitido, muito obrigado;

Aos professores do curso de Engenharia Agrícola e do PGEAGRI, pelos conhecimentos transmitidos, e a todos que contribuíram de alguma forma para a minha formação;

Ao Programa de Pós-Graduação em Engenharia Agrícola e à Universidade Estadual do Oeste do Paraná, pela infraestrutura, a oportunidade e o auxílio na formulação deste trabalho;

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior– CAPES pelo apoio financeiro (bolsa) concedido.

MAPEAMENTO DE SOJA E MILHO COM MINERAÇÃO DE DADOS E IMAGENS SINTÉTICAS LANDSAT E MODIS

RESUMO

Estudos referentes ao acompanhamento da produção agrícola têm um peso determinante e estratégico no planejamento econômico do país, devido à importância do agronegócio, e também para segurança alimentar. O sensoriamento remoto orbital é uma alternativa eficaz para realizar o monitoramento das culturas agrícolas, devido ao baixo custo, grande escala de abrangência e rapidez na coleta de dados. Porém, geralmente os sensores com alta resolução espacial possuem baixa resolução temporal, e os com alta resolução temporal possuem baixa resolução espacial. Assim, para se realizar o acompanhamento de culturas agrícolas com uma resolução espacial mais alta, a cobertura por nuvens pode ser um fator limitante. Estes problemas podem ser contornados com a utilização de fusão de imagens de diversos sensores com características temporais e espaciais diferentes, criando, assim, novas imagens, também chamadas de imagens sintéticas. Deste modo, o objetivo do trabalho foi realizar o mapeamento de áreas semeadas com soja e milho utilizando fusão espaço-temporal de imagens Landsat 8 e MODIS. Na primeira parte do trabalho, foram separadas culturas agrícolas de outros alvos. A classificação gerada serviu de entrada em um dos algoritmos de classificação, o Flexible Spatiotemporal Data Fusion (FSDAF), na segunda parte do trabalho. Nessa parte, além deste algoritmo, também foram utilizados os algoritmos Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM) e Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) para gerar imagens nas safras de verão 2016/2017. Então, foram criados 5 cenários de classificação. Nos 1º e 2º foram considerados a utilização apenas das imagens espectrais das imagens Landsat 8 livres de nuvens. As 3º, 4º e 5º foram realizadas com as imagens geradas pelo STARFM, ESTARFM e FSDAF. No 3º cenário foram utilizadas as métricas espectrais das imagens Landsat 8 e as imagens espectrais gerados pelos algoritmos de fusão, no 4º foram considerados as métricas estatísticas e no 5º as métricas fenológicas extraídas do perfil temporal do Enhanced Vegetation Index (EVI). Os cenários que utilizaram métricas fenológicas do EVI a partir de imagens geradas pelo FSDAF e STARFM obtiveram melhores resultados, com exatidão global de 93,11 e 91,33%, respectivamente, resultados estes estatisticamente melhores que os obtidos apenas com as imagens Landsat 8 existentes. Assim, a utilização de métricas fenológicas obtidas de imagens sintéticas são importantes alternativas para o mapeamento de soja e milho.

Palavras-chave: Fusão de imagens espaço-temporal; métricas fenológicas; métricas estatísticas.

MAPPING OF SOYBEAN AND CORN WITH DATA MINING AND SYNTHETIC IMAGES LANDSAT AND MODIS

ABSTRACT

Studies related to the monitoring of agricultural production play a decisive and strategic role in the economic planning of the country, due to the importance of agribusiness, as well as food safety. Orbital remote sensing is an effective alternative to perform agricultural crop monitoring due to its low cost, large scale and speed of data collection. However, most of the sensors with high spatial resolution are of low temporal resolution, and the ones with higher temporal resolution have low spatial resolution. Therefore, for the monitoring of agricultural crops with a higher spatial resolution, cloud covering can be a limiting factor. Such problems can be circumvented by using a fusion of images of several sensors with different spatial and temporal characteristics, thus creating new images, also called synthetic images. Thus, the objective of the work was the mapping of areas sown with soybean and corn using space-temporal fusion, such as Landsat 8 and MODIS images. In the first part of the research, agricultural crops were separated from other targets. The generated classification served as input to one of the classification algorithms, the Flexta Spatiotemporal Data Fusion (FSDAF), in the second part of the research. In addition to this algorithm, both the Spatial and Temporal Adaptive Reflection Fusion Model (STARFM) and the Advanced and Temporal Spatial Adaptive Reflection Fusion Model (ESTARFM) were employed to generate images for the 2016/2017 summer crops. Then, 5 rating scenarios were created. In the 1st and 2nd scenarios, only the images from the Landsat 8 with no occurrence of clouds were considered. For the 3rd, 4th, and 5th were carried out using images generated by STARFM, ESTARFM and FSDAF. In the third scenario, the metric images of images, Landsat 8 and images of fusion algorithms were used, 4th as a summary of statistical metrics, and in the 5th one as phenological metrics of the temporal profile of the Enhanced Vegetation Index (EVI). The scenario using the EVI phenological metrics from images generated by FSDAF and STARFM yielded better results, with global accuracy of 93.11 and 91.33%, respectively. These results are statistically better than those obtained using only existing Landsat 8 images. Thus, the use of phenological metrics obtained from synthetic images are important alternatives for mapping soybean and corn crops.

Keywords: Fusion of spatio-temporal images; phenological metrics; statistical metrics.

SUMÁRIO

RESUMO	v
ABSTRACT	vi
LISTA DE TABELAS	ix
LISTA DE FIGURAS	x
1 INTRODUÇÃO	13
2 OBJETIVOS	15
2.1 Objetivo geral	15
2.2 Objetivos específicos.....	15
3 REVISÃO BIBLIOGRÁFICA	16
3.1 Produção de soja e milho	16
3.2 Soja.....	17
3.2.1 Exigências climáticas e aspectos biológicos da cultura da soja.....	17
3.3 Milho	19
3.3.1 Exigências climáticas e aspectos biológicos da cultura do milho	20
3.4 Sistema de acompanhamento de safras.....	21
3.5 Sensoriamento remoto	21
3.5.1 Satélite Landsat 8.....	24
3.5.2 Sensor MODIS	24
3.5.3 Sensoriamento remoto agrícola.....	25
3.6 Fusão de imagens de satélites	28
3.6.1 STARFM	31
3.6.2 ESTARFM	34
3.6.3 FSDAF	37
3.7 Índices de Vegetação	38
3.8 Mapeamento de culturas agrícolas.....	40
3.9 Mineração de dados e descoberta de conhecimento.....	43
4 MATERIAL E MÉTODOS	45
4.1 Organização da dissertação	45
5 REFERÊNCIAS	46
6 RESULTADOS	59

6.1	ARTIGO 1: Mapeamento de áreas agrícolas utilizando técnicas de mineração de dados em séries temporais de imagens Landsat 8	59
6.1.1	INTRODUÇÃO	59
6.1.2	MATERIAL E MÉTODOS	61
6.1.3	RESULTADOS E DISCUSSÃO	65
6.1.4	CONCLUSÕES	70
6.1.5	REFERÊNCIAS	71
6.2	ARTIGO 2: Mapeamento de soja e milho utilizando imagens sintéticas Landsat 8 e MODIS	75
6.2.1	INTRODUÇÃO	75
6.2.2	MATERIAL E MÉTODOS	79
6.2.3	RESULTADOS E DISCUSSÃO	86
6.2.4	CONCLUSÕES	93
6.2.5	REFERÊNCIAS	93
7	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	100
	APÊNDICE A.....	101
	APÊNDICE B.....	107
	APÊNDICE C.....	109

LISTA DE TABELAS

Tabela 1. Descrição sumária dos estádios vegetativos e reprodutivos da soja.	19
Tabela 2. Estádios vegetativos e reprodutivos do milho.....	21
Tabela 3. Comprimento de onda e resolução das imagens do sensor OLI.	24
Tabela 4. Comprimento de onda e resolução das imagens do sensor MODIS para as resoluções de 250 e 500 m comparadas com as imagens do sensor OLI.	25
Tabela 5. Resumo dos principais métodos de fusão de dados espaço temporais.....	30
Tabela 6. Datas das imagens do satélite Landsat 8, tile 223/77, utilizadas no estudo.	62
Tabela 7. Índices de acurácias gerados pelos algoritmos e pela distribuição aleatória de pontos nas classificações utilizando as métricas temporais de NDVI ($cubo_{MétricasNDVI}$) e as bandas espectrais ($cubo_{RGB}$) para os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver.	66
Tabela 8. Acurácias de produtor (AP) e usuário (AU) para área urbana, mata, cana-de-açúcar, reflorestamento, culturas agrícolas anuais, pastagem e água, obtidas pelo painel amostral para os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver nas imagens no $cubo_{MétricasNDVI}$ e $cubo_{RGB}$.	68
Tabela 9. Teste Z para comparação entre duas proporções obtidos pela distribuição aleatória de pontos em classificações para área urbana, mata, cana-de-açúcar, reflorestamento, culturas agrícolas anuais, pastagem e água com os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver nas imagens do $cubo_{MétricasNDVI}$ e $cubo_{RGB}$	68
Tabela 10. Índices de acurácias gerados pelos algoritmos e pela distribuição aleatória de pontos nas classificações utilizando as métricas temporais de NDVI ($cubo_{MétricasNDVI}$) e a imagem RGB-564 ($cubo_{RGB}$) para os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver para culturas agrícolas anuais e demais alvos.	70
Tabela 11. Teste Z para comparação entre duas proporções obtidos pela distribuição aleatória de pontos em classificações para culturas agrícolas anuais e outras culturas com os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver nas imagens do $cubo_{MétricasNDVI}$ e $cubo_{RGB}$	70
Tabela 12. Teste Z a 5% de significância entre todos os cenários de classificação	90
Tabela 13. Matriz de erros para todos os cenários de classificação.....	108

LISTA DE FIGURAS

Figura 1. Produção de soja e milho por estado para a safra 2016/2017 e proporção da produção por região. Fonte: CONAB (2018).....	16
Figura 2. Assinatura espectral da folha verde. FONTE: Adaptado de (SWAIN, 1978).	23
Figura 3. Esquema da metodologia empregada pelo STARFM. Fonte: Gao et al. (2006).	32
Figura 4. Esquema da janela móvel utilizada pelo ESTARFM. Fonte: Zhu et al. (2010).	35
Figura 5. Esquema da janela móvel utilizada pelo FSDAF. Fonte: (ZHU et al., 2016).	38
Figura 6. Fluxograma geral do trabalho.	45
Figura 7. Localização da área de estudo.	61
Figura 8. Exemplo de métricas temporais de NDVI característico de diferentes alvos (mata, reflorestamento, cultura agrícolas anuais, pastagem, cana-de-açúcar, área urbana e água) do sensor MODIS com filtro Savitzky–Golay. Fonte: Adaptado de https://www.satveg.cnptia.embrapa.br/satveg/login.html	63
Figura 9. Resultado das classificações em imagens Landsat-8 utilizando as métricas temporais de NDVI ($cubo_{MétricasNDVI}$) e as bandas espectrais ($cubo_{RGB}$) com os classificadores Árvore de Decisão, Random Forest e Maxver para área urbana, mata, cana-de-açúcar, reflorestamento, culturas agrícolas anuais, pastagem e água.....	66
Figura 10. Resultado das classificações em imagens Landsat 8 utilizando as métricas temporais de NDVI ($cubo_{MétricasNDVI}$) e o RGB-564 ($cubo_{RGB}$) com os classificadores Árvore de Decisão, Random Forest e Maxver para as classes culturas agrícolas anuais e demais alvos.....	69
Figura 11. Localização da área de estudo.	80
Figura 12. Datas dos pares de imagens utilizadas para gerar as imagens sintéticas. Mesmas cores e mesma forma para o FSDAF e STARFM indicam os pares de entrada. Para o ESTARFM, mesma cor ou mesma forma indicam os pares de entrada.	81
Figura 13. Amostras de campo, treinamento e validação.....	85
Figura 14. Imagem Landsat 8 do DOY (day of year) 329/2016 (c) e as imagens sintéticas geradas para o mesmo dia pelos algoritmos FSDAF (g), STARFM (h) e ESTARFM (i). Nos dois primeiros foram utilizados os pares MODIS-Landsat 8 (respectivamente, a e b) do DOY 297/2016 e a imagem MODIS do DOY 329/2016 (f). Para o ESTARFM utilizou-se também o par do dia 011/2017	

(d, e). Todas as imagens estão na composição colorida falsa cor (R: NIR, G: SWIR1 e B: vermelho) com contraste linear de 2%.	87
Figura 15. Gráficos de correlação de Spearman (r_s), erro quadrático médio (RMSE) e índice refinado de Wilmott (d_r) entre as imagens geradas pelo STARFM, ESTARFM e FSDAF e as imagens Landsat 8. As bandas espectrais são: B2:azul; B3: verde; B4: vermelho; B5: NIR; B6: SWIR 1; B7: SWIR 2. Para mais detalhes, consultar gráficos de dispersão no apêndice A.	88
Figura 16. Gráfico de exatidão global para todos os cenários de classificação.	89
Figura 17. Acurácia de produtor e usuário para as classes soja, milho e outros com todos os cenários de classificação.	91
Figura 18. Resultado da classificação com métricas fenológicas extraídas da série temporal de EVI das imagens geradas pelo FSDAF com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	92
Figura 19. Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 297/2016 com a Imagem Landsat 8.	102
Figura 20. Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 329/2016 com a Imagem Landsat 8.	103
Figura 21. Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 361/2016 com a Imagem Landsat 8.	104
Figura 22. Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 011/2017 com a Imagem Landsat 8.	105
Figura 23. Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 027/2017 com a Imagem Landsat 8.	106
Figura 24. Resultado da classificação para o cenário 1 com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	110
Figura 25. Resultado para o cenário 2 com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	111
Figura 26. Resultado da classificação para o cenário 3 utilizando o STARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	112
Figura 27. Resultado da classificação para o cenário 3 utilizando o ESTARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	113
Figura 28. Resultado da classificação para o cenário 3 utilizando o FSDAF com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	114

Figura 29. Resultado da classificação para o cenário 4 utilizando o STARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).....	115
Figura 30. Resultado da classificação para o cenário 4 utilizando o ESTARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).....	116
Figura 31. Resultado da classificação para o cenário 5 utilizando o STARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).....	117
Figura 32. Resultado da classificação para o cenário 5 utilizando o ESTARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).....	118
Figura 33. Resultado da classificação para o cenário 5 utilizando o FSDAF com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).	119

1 INTRODUÇÃO

A atividade agrícola é caracterizada por riscos e incertezas em função de problemas com excessos ou falta de chuvas, ocorrência de doenças e pragas, entre outros fatores. Devido ao aumento da demanda por alimentos e por conta da importância econômica do agronegócio, o monitoramento da atividade é essencial para todos os envolvidos na cadeia produtiva, seja governo, indústrias, cooperativas ou produtores, para se evitar excesso ou falta de produtos, auxiliar no planejamento e evitar perdas. As culturas da soja e do milho estão entre os principais produtos do agronegócio brasileiro. Na safra de verão, há variação entre as áreas semeadas com as duas culturas de um ano para outro, principalmente devido ao preço.

A quantificação da área semeada é uma das variáveis para estimativa da produção, sendo uma informação essencial. Os métodos tradicionais de previsão de safras, utilizados pelos órgãos oficiais, nem sempre obtêm resultado satisfatoriamente preciso, além de existir grande demora na divulgação dos dados e as informações não serem espacializadas. Por outro lado, o sensoriamento remoto orbital é uma alternativa eficaz, pois pode tornar as estimativas menos subjetivas, devido ao baixo custo, grande escala de abrangência e rapidez na coleta de dados.

Porém, ainda não existe um sensor com alta resolução temporal e espacial concomitantemente. Geralmente sensores que possuem alta resolução temporal possuem baixa resolução espacial, e aqueles com alta resolução espacial possuem baixa resolução temporal. Assim, sensores com alta resolução temporal, como o Moderate Resolution Imaging Spectroradiometer (MODIS), com ciclos de revisita de um ou dois dias possuem tamanho de pixel muito grande (melhor resolução espacial de 250 m). Por outro lado, aqueles sensores com resolução espacial melhor, como os sensores do Landsat 8, com 30 m, possuem tempo de revisita muito alto (resolução temporal de 16 dias), o que não permite acompanhar a alta dinâmica das culturas agrícolas, principalmente em regiões em que há grande cobertura por nuvens.

Nesse sentido, a utilização de métodos de fusão espaço-temporal de imagens digitais, que como resultado criam novas imagens (também chamadas de imagens sintéticas) com características espaciais iguais à do sensor de melhor resolução espacial, além de aproveitar a resolução temporal do sensor de melhor resolução temporal, podem ajudar a contornar esses problemas. Diversos métodos de fusão espaço-temporal de imagens digitais foram desenvolvidos na última década, mas ainda são poucos utilizados para melhorar a identificação e o mapeamento de culturas agrícolas. Assim, as imagens sintéticas que possuem alta resolução temporal e espacial podem melhorar o monitoramento das culturas agrícolas, pois as informações

fenológicas contidas nas séries temporais de dados de sensoriamento remoto são muito úteis para o mapeamento dessas culturas agrícolas.

Além do mais, os índices de vegetação – que são relações entre a refletância em diferentes comprimentos de ondas e que possuem alta relação com a biomassa e a condição de crescimento das culturas agrícolas – podem ser criados a partir dessas. Portanto, as séries temporais de índice de vegetação das imagens sintéticas contêm informação das características do desenvolvimento das culturas agrícolas, como o início, duração e fim do ciclo fenológico, sendo que, estas informações são particulares de cada cultura e podem, assim, ser utilizadas para diferenciá-las. Desta forma, este trabalho pretende avaliar se, com a utilização de imagens sintéticas, é possível realizar/melhorar o mapeamento de soja e milho em municípios da região Oeste do Paraná.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo do trabalho foi de realizar a identificação e o mapeamento de áreas semeadas com soja e milho utilizando imagens sintéticas geradas por métodos de fusão espaço-temporal entre Landsat 8 e MODIS.

2.2 Objetivos específicos

- a) Utilizar variáveis estatísticas de IV para gerar o mapeamento de cultura agrícola anual/não cultura;
- b) Comparar os algoritmos Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM), Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) e Flexible Spatiotemporal Data Fusion (FSDAF), testando qual deles consegue reproduzir melhor os perfis temporais das culturas agrícolas;
- c) Utilizar as métricas fenológicas, estatísticas e espectrais para identificar e mapear as culturas da soja e do milho;
- d) Avaliar as acurácias dos mapeamentos gerados.

3 REVISÃO BIBLIOGRÁFICA

3.1 Produção de soja e milho

No ano de 2014 o Brasil foi o segundo maior produtor de soja, com 86,8 milhões de toneladas (equivalente a 28,3% da produção mundial), atrás apenas dos EUA, maior produtor mundial. No mesmo ano, o Brasil foi o terceiro maior produtor de milho, com 79,9 milhões de toneladas (equivalente a 7,7% da produção mundial), perdendo apenas para os EUA e China, primeiro e segundo maiores produtores mundiais de milho respectivamente (FAOSTAT, 2018).

Já a estimativa da Companhia Nacional de Abastecimento (CONAB) é que a safra 2016/2017 de soja foi 3,2% maior e a de milho 2,9% menor que a safra anterior, sendo a região centro-oeste a maior produtora de soja e milho, seguida pela região sul (Figura 1).

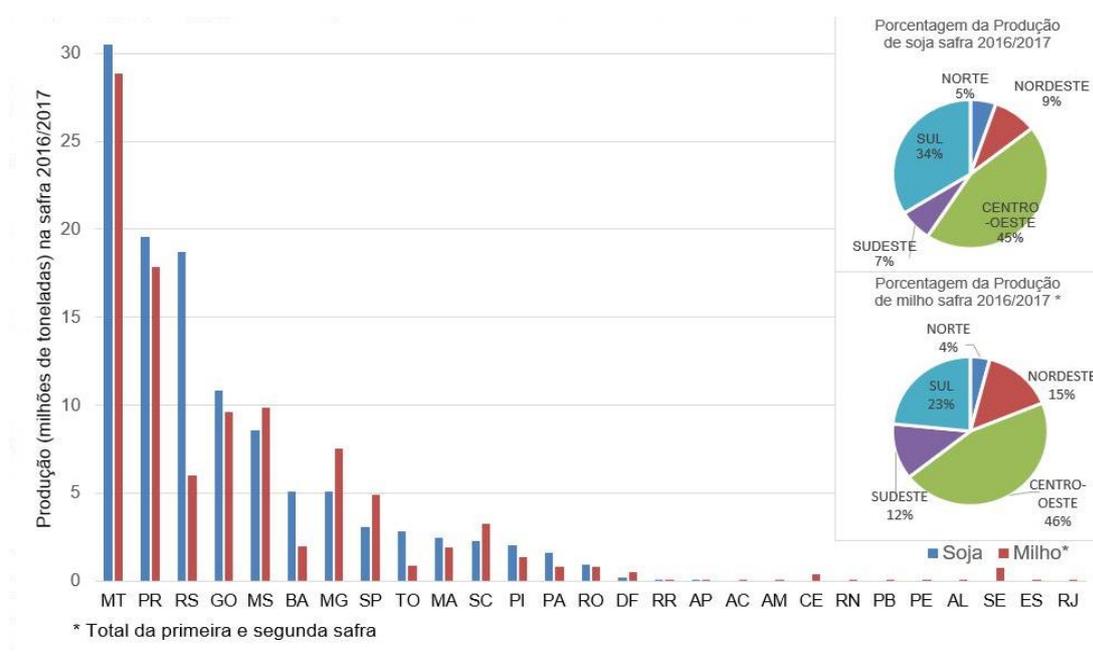


Figura 1 Produção de soja e milho por estado para a safra 2016/2017 e proporção da produção por região.
Fonte: CONAB (2018).

O estado do Paraná foi o segundo maior produtor de soja e milho na safra 2016/2017, com 19,6 e 17,8 milhões de toneladas, respectivamente (CONAB, 2018). Se considerar a produção de soja para o ano de 2016, o estado possui produção maior que a Índia, quarto maior produtor mundial (14,01 milhões de toneladas) (CONAB, 2018; FAOSTAT, 2018). Já para o milho, a produção do Paraná foi maior que da Rússia (15,31 milhões de toneladas), 9º produtor mundial (CONAB, 2018; FAOSTAT, 2018). Assim,

as produções de soja e milho no Paraná possuem grande representatividade na produção mundial.

3.2 Soja

A soja (*Glycine max (L.) Merrill*) que é cultivada atualmente é muito diferente dos ancestrais que lhe deram origem: espécies de plantas rasteiras que se desenvolviam na costa leste da Ásia, principalmente ao longo do Rio Amarelo, na China (EMBRAPA SOJA, 2004).

No agronegócio mundial, a produção de soja está entre as atividades econômicas que apresentaram crescimento mais expressivo nas últimas décadas. Isso se deve ao desenvolvimento e à estruturação de um sólido mercado internacional, relacionado com o comércio de produtos do complexo soja – especialmente para atender demandas crescentes dos setores ligados à produção de produtos de origem animal e a geração e oferta de tecnologias, que viabilizaram a expansão da exploração sojícola para diversas regiões do mundo (EMBRAPA SOJA, 2011).

3.2.1 Exigências climáticas e aspectos biológicos da cultura da soja

O crescimento e o desenvolvimento da cultura da soja dependem basicamente do potencial genético da cultivar semeada e do ambiente. A cultura é sensível a mudanças climáticas como temperatura e disponibilidade de água, de modo que quando ocorrem variações no fator ambiente ocorrem também variações na cultura, podendo ou não expressar o seu potencial de produção. Em condições de campo, o clima proporciona maior influência sobre a produção e desenvolvimento da cultura (FEHR; CAVINESS, 1977).

Assim, a disponibilidade hídrica, o fotoperíodo e a temperatura são os fatores climáticos que mais interferem no desenvolvimento da soja. A disponibilidade de água tem importância principalmente na germinação-emergência e florescimento-enchimento de grãos, sendo que, no primeiro período, tanto o déficit quanto o excesso de água são prejudiciais. A necessidade de água vai aumentando com o desenvolvimento da cultura, atingindo o máximo no florescimento-enchimento de grãos, decrescendo após este período. Deste modo, para um máximo rendimento, a soja necessita entre 450 a 800 mm/ciclo, dependendo das condições climáticas, do manejo da cultura e da duração do ciclo (EMBRAPA SOJA, 2013).

Já temperatura ideal para seus crescimento e desenvolvimento está em torno de 30 °C, se adaptando a temperaturas do ar entre 20 e 30 °C. Quando a temperatura é inferior a 10 °C o crescimento vegetativo da soja é pequeno ou nulo. A sensibilidade ao

fotoperíodo é característica variável entre cultivares, ou seja, cada cultivar possui seu fotoperíodo crítico, acima do qual o florescimento é atrasado (EMBRAPA SOJA, 2013).

Enquanto o conhecimento do ciclo fenológico de uma determinada cultura determina o melhor tipo de manejo, as características morfológicas da planta, seu momento fisiológico, associados às necessidades por parte do vegetal, possibilitam o desenvolvimento normal da cultura e, conseqüentemente, boas produtividades (SILVA, 2011).

A metodologia de descrição dos estádios fenológicos deve apresentar terminologia única, ser objetiva, precisa e universal, ser capaz de descrever um único indivíduo ou uma lavoura inteira e ser capaz de descrever qualquer cultivar (FARIAS; NEPOMUCENO; NEUMAIER, 2007). A metodologia proposta por Fehr e Caviness (1977) é a mais utilizada no mundo: ela divide o ciclo de desenvolvimento da soja em estádios vegetativos e estádios reprodutivos (Tabela 1). Os estádios vegetativos são designados pela letra V e os reprodutivos, pela letra R. Com exceção dos estádios de emergência (VE) e cotilédone (VC), as letras V e R são seguidas por índices numéricos que identificam estádios específicos.

Tabela 1 Descrição sumária dos estádios vegetativos e reprodutivos da soja

Estádio Vegetativo		
Estádio	Denominação	Descrição
VE	Emergência	Cotilédones acima da superfície do solo
VC	Cotilédone	Cotilédones completamente abertos
V1	Primeiro Nó	Folhas unifolioladas completamente desenvolvidas
V2	Segundo Nó	Primeira folha trifoliolada completamente desenvolvida
V3	Terceiro Nó	Segunda folha trifoliolada completamente desenvolvida
V4	Quarto Nó	Terceira folha trifoliolada completamente desenvolvida
V5	Quinto Nó	Quarta folha trifoliolada completamente desenvolvida
V6	Sexto Nó	Quinta folha trifoliolada completamente desenvolvida
V...
Vn	Enésimo Nó	Ante-enésima folha trifoliolada completamente desenvolvida
Estádio Reprodutivo		
Estádio	Denominação	Descrição
R1	Início do Florescimento	Uma flor aberta em qualquer nó do caule
R2	Florescimento Pleno	Uma flor aberta num dos 2 últimos nós do caule com folha completamente desenvolvida
R3	Início da formação da vagem	Vagem com 5 mm de comprimento num dos 4 últimos nós do caule com folha completamente desenvolvida
R4	Vagem completamente desenvolvida	Vagem com 2 cm de comprimento num dos 4 últimos nós do caule com folha completamente desenvolvida
R5	Início do enchimento do Grão	Grão com 3 mm de comprimento em vagem num dos 4 últimos nós do caule, com folha completamente desenvolvida
R6	Grão cheio ou completo	Vagem contendo grãos verdes preenchendo as cavidades da vagem de um dos 4 últimos nós do caule, com folha completamente desenvolvida
R7	Início da maturação	Uma vagem normal no caule com coloração de madura
R8	Maturação plena	95% das vagens com coloração de madura

Fonte: Adaptado de Farias, Nepomuceno e Neumaier (2007).

3.3 Milho

O milho (*Zea mays L. ssp. mays*) é uma espécie que possui origem Mesoamericana e que teve domesticação há cerca de 5000 a 10000 anos (DOEBLEY et al., 1999), pela América Central. No Brasil, o milho já era cultivado por povos pré-colombianos e chegou a ser descrito por colonizadores ainda no século XVI. A dispersão geográfica do milho, assim como suas numerosas formas de emprego e utilização fizeram com que seja considerado uma das espécies de maior variabilidade genética

dentre as plantas cultivadas (TEIXEIRA; COSTA, 2010). Assim, o milho é o cereal mais produzido no mundo.

A importância econômica do milho está na sua diversidade de utilização, desde a alimentação animal e humana até a indústria de alta tecnologia. Contudo, o maior destino do milho é na produção de ração para a avicultura, bovinocultura e a suinocultura, as quais são de grande importância econômica, tanto no âmbito mundial, como nacional. Estima-se que este cereal responda por 70% do volume utilizado na alimentação animal de aves, bovinos e suínos (DERAL, 2011).

3.3.1 Exigências climáticas e aspectos biológicos da cultura do milho

Para o milho atingir o máximo do seu potencial genético de produção, ele necessita que os índices dos fatores climáticos, principalmente temperatura e precipitação pluviométrica, atinjam níveis considerados ótimos (CRUZ et al., 2006).

Deste modo, a temperatura ideal para o desenvolvimento do milho, da emergência à floração, está compreendida entre 24 e 30 °C. Abaixo de 10 °C, por períodos longos, o crescimento da planta é quase nulo e, sob temperaturas acima de 30 °C, também por períodos longos, durante a noite, o rendimento de grãos decresce, em razão do consumo dos produtos metabólicos elaborados durante o dia. O milho é uma cultura muito exigente em água, necessitando aproximadamente 600 mm durante o ciclo de desenvolvimento. Durante o período compreendido entre o espigamento e a maturação, o consumo pode se elevar para 5 a 7,5 mm diários. Porém, se a temperatura estiver muito elevada e a umidade do ar muito baixa, o consumo poderá chegar a até 10 mm/dia (CRUZ et al., 2006).

O sistema de identificação empregado divide o desenvolvimento da planta em vegetativo (V) e reprodutivo (R) (Tabela 2). Subdivisões dos estádios vegetativos são designados numericamente como V1, V2, V3 até V(n); em que (n) representa a última folha emitida antes do pendoamento (Vt). O primeiro e o último estádios V são representados, respectivamente, por Ve, emergência e Vt, pendoamento (MAGALHÃES; DURÃES, 2006).

Tabela 2 Estádios vegetativos e reprodutivos do milho

VEGETATIVO	REPRODUTIVO
Ve , Emergência	R1 , Embonecamento e Polinização
V1 , 1ª Folha Desenvolvida	R2 , Grão bolha d'água
V2 , 2ª Folha Desenvolvida	R3 , Grão leitoso
V3 , 3ª Folha Desenvolvida	R4 , Grão Pastoso
Vn , nª Folha Desenvolvida	R5 , Formação de dente
Vt , Pendoamento	R6 , Maturidade Fisiológica

Fonte: Adaptado de Magalhães e Durães (2006).

3.4 Sistema de acompanhamento de safras

O monitoramento agrícola é essencial para avaliação do aumento de produtividade e da produção, do suprimento de alimentos, controlar o impacto ambiental que possa ser causado pela atividade, para gerar informações para os formuladores de políticas e as partes interessadas pelo setor agrícola (ATZBERGER, 2013), além de serem vitais para a segurança alimentar e para a indústria (POTGIETER; LAWSON; HUETE, 2013; VINTROU et al., 2013; HAO et al., 2015).

No Brasil, as estimativas oficiais de área e produção agrícola são realizadas pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e pela Companhia Nacional de Abastecimento (CONAB). Estes órgãos oficiais ainda utilizam pesquisas com produtores rurais e em cooperativas, dados de históricos e de financiamento agrícola. Estas informações são importantes, mas a forma de obtenção das informações torna as estimativas de safras sujeitas a subjetividade e imprecisões (GUSSO et al., 2012; JOHANN et al., 2012). As estimativas de safras no Brasil vêm sofrendo grandes mudanças no intuito de se tornar menos subjetiva.

Devido a isso, estão sendo utilizadas ferramentas estatísticas de amostragem e de acompanhamento de culturas. O sensoriamento remoto (SR) é uma destas ferramentas, que vem sendo utilizada para o monitoramento de culturas (MERCANTE et al., 2012). O SR pode gerar informações decisivas nas aplicações agrícolas, cobrindo áreas extensas e de difícil acesso (ESQUERDO; ZULLO JÚNIOR; ANTUNES, 2011; ATZBERGER, 2013; BISQUERT et al., 2015), podendo representar a informação de forma espacializadas (SANTOS et al., 2014), em tempo real (GAO et al., 2017) e servir para complementar os dados da metodologia adotada em programas oficiais (JOHANN et al., 2012).

3.5 Sensoriamento remoto

Sensoriamento remoto é a ciência de obter informações sobre um objeto, área ou fenômeno através da análise de dados adquiridos por um dispositivo que não está em contato com o objeto, área ou fenômeno sob investigação (LILLESAND; KIEFER;

CHIPMAN, 2015). Assim, o objetivo de qualquer tecnologia de SR é fornecer observação de algum parâmetro físico em algum tempo ou período de tempo (TOTH; JÓZKÓW, 2016).

A radiação eletromagnética (REM), provinda do sol, é a energia geralmente utilizada no SR ao estudar a superfície terrestre (ABREU; COUTINHO, 2014). A REM se propaga na forma de ondas e pode ser caracterizada por duas medidas: o comprimento de onda (distância entre duas cristas de ondas sucessivas) e a frequência (número de oscilações completas por segundo) (WENG, 2010). Já o espectro eletromagnético é uma divisão didática da distribuição da REM pelas distintas regiões, organizado de acordo com o comprimento de onda e frequência de onda (ABREU; COUTINHO, 2014).

A REM então interage com os diferentes objetos (também chamados de “alvos” na literatura) da superfície terrestre, podendo ocorrer três processos desta interação: ser transmitida, refletida ou absorvida pelo alvo (PONZONI; SHIMABUKURO; KUPLICH, 2012). Os sistemas de SR podem detectar e registrar tanto a energia refletida como a emitida em cada comprimento de onda ou faixa do espectro eletromagnético (WENG, 2010). Assim, as características dos alvos podem ser correlacionadas com a resposta espectral registrada pelos sistemas de sensores remotos (MERCANTE, 2007).

As plantas, tal como outros alvos, possuem um padrão espectral, que pode ser denominando como padrão da refletância, absortância e/ou transmitância (Figura 2). Uma folha de planta tipicamente tem uma baixa refletância na região espectral visível devido à forte absorção pela clorofila; uma refletância relativamente alta no infravermelho próximo (NIR), por causa da dispersão interna das folhas e sem absorção; uma refletância relativamente baixa no infravermelho para além de 1,3 μm , devido à forte absorção por água (KNIPLING, 1970). A refletância de um dossel vegetal é semelhante, mas é modificada pela não uniformidade da radiação solar incidente, estruturas de plantas, áreas foliares, sombras e reflexividades de fundo (KNIPLING, 1970).

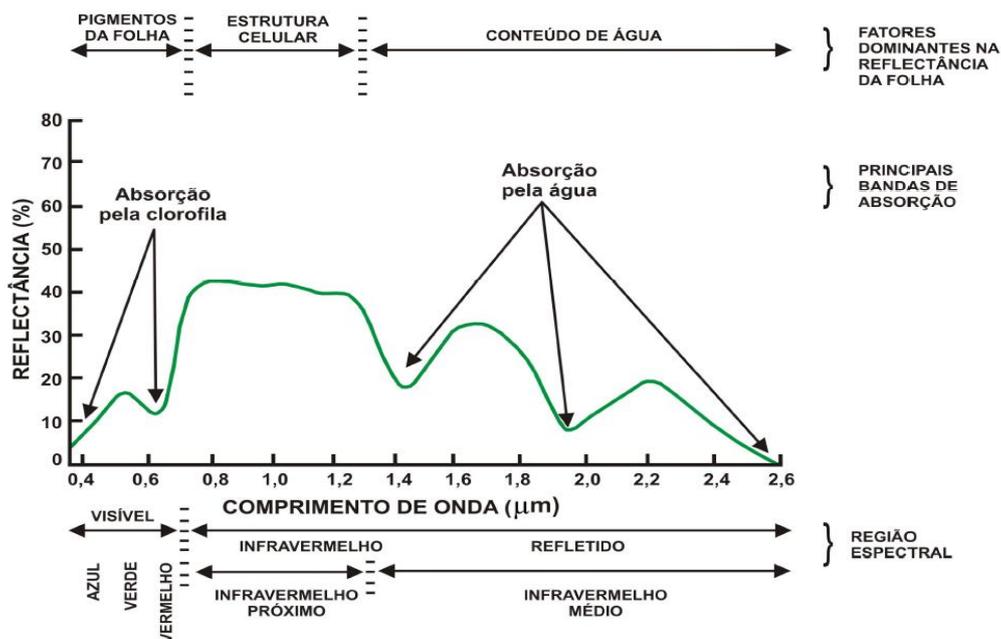


Figura 2 Assinatura espectral da folha verde.

Fonte: Adaptado de Swain (1978).

Desta forma, após a REM ser emitida, se propagar pela atmosfera e interagir com os alvos na superfície terrestre, ela é retransmitida através da atmosfera, sendo então captadas e registradas pelos equipamentos denominados de sensores (LILLESAND; KIEFER; CHIPMAN, 2015). Tradicionalmente, o termo sensoriamento remoto foi usado para plataformas de satélites e aeronaves, adquirindo dados tipicamente por sensores ópticos e de radar. Mais recentemente, todos os métodos de aquisição de imagem e de dados espaciais, incluindo o levantamento aerotransportado, levantamentos por sistema de aeronaves não tripuladas, o sistema mobile de mapeamento (usar sensores instalados em um veículo em movimento, como carros, caminhões) e as plataformas estáticas podem ser considerados sensores remotos (TOTH; JÓŽKÓW, 2016).

No SR orbital, os sensores vão embarcados nas plataformas orbitais, chamadas de satélite, e os dados são registrados em imagens (LILLESAND; KIEFER; CHIPMAN, 2015). As capacidades técnicas dos sensores orbitais dependem de quatro resoluções: (a) resolução espacial, que refere-se ao tamanho do pixel da imagem gerada; (b) resolução radiométrica, que refere-se à intensidade de radiância de cada pixel que o sensor é capaz de mensurar, representado por valores numéricos ou nível de cinza; (c) resolução espectral, que refere-se ao número de faixas espectrais do sensor; e (d) resolução temporal, que corresponde ao tempo de revisita do satélite na mesma área (MENESES et al., 2012).

3.5.1 Satélite Landsat 8

O satélite Landsat 8, tem objetivo de dar continuidade ao programa Landsat, iniciado em 23 de julho de 1972, com o lançamento do Earth Resources Technology Satellite (ERTS) (WULDER et al., 2016). O Landsat 8 foi lançado em 11 de fevereiro de 2013, sendo desenvolvido pela parceria entre a National Aeronautics and Space Administration (NASA) e o Department of the interior U.S. Geological Survey (USGS)

O sensor Operacional Terra Imager (OLI), a bordo do satélite Landsat-8, possui 9 bandas espectrais (Tabela 3). Cada cena cobre aproximadamente 190 km ao norte-sul e 180 km a Leste-Oeste. As imagens são disponibilizadas ortorretificadas com resolução espacial de 30 metros, exceto a banda 8 (pancromática), que possui resolução de 15 metros. Possuem resolução radiométrica de 16 bits, e tempo de revisita de 16 dias (ROY et al., 2014; U.S. GEOLOGICAL SURVEY, 2016).

Tabela 3 Comprimento de onda e resolução das imagens do sensor OLI

Bandas	Comprimento de onda (μm)	Resolução (metros)
Banda 1 – estudo aerossóis	0,430 - 0,450	30
Banda 2 – azul	0,452 – 0,512	30
Banda 3 – verde	0,533 - 0,590	30
Banda 4 – vermelho	0,636 - 0,673	30
Banda 5 – infravermelho próximo (NIR)	0,851 - 0,879	30
Banda 6 – infravermelho médio (SWIR 1)	1,566 - 1,652	30
Banda 7 – infravermelho médio (SWIR 2)	2,107 - 2,294	30
Banda 8 – Pancromático	0,500 - 0,680	15
Banda 9 - Cirrus	1,360 - 1,380	30

Fonte: Roy et al. (2014) e Gao et al. (2015).

3.5.2 Sensor MODIS

O MODIS (Moderate Resolution Imaging Spectroradiometer) é um sensor que está a bordo dos satélites Terra e Aqua, lançados pela NASA (National Aeronautics and Space Administration) em 18 de dezembro de 1999 e 4 de maio de 2002, respectivamente. O satélite Terra possui órbita em torno da terra com direção de norte a sul, passando sobre a linha do Equador na parte da manhã. Já o satélite Aqua passa na direção de norte a sul, passando sobre a linha do Equador na parte da tarde (JUSTICE et al., 2002).

Esses satélites fazem parte do projeto EOS (Earth Observing System), formado por diversos países para o estudo dos processos de mudança globais. A resolução temporal dos satélites Terra e Aqua permite que dentro de um a dois dias seja feita a cobertura de toda a superfície da terra, registrando dados espectrais em 36 bandas espectrais. Destas bandas, duas possuem resolução espacial de 250 m, outras 5 possuem resolução de 500 m e as demais possuem resolução de 1000 m (Tabela 4). A resolução radiométrica é 12 bits, cobrindo o intervalo do espectro eletromagnético de 0,4 a 14,4 μm (JUSTICE et al., 2002). São derivados diversos produtos do sensor MODIS, que incluem refletância da superfície, temperatura e emissividade da superfície, cobertura de nuvem, Albedo, IVs, IAF, entre outros (JUSTICE et al., 2002). Outra característica importante é que os dados do sensor MODIS são recebidos pelo sistema de operação EDOS (Eos Data and Operations System), em que se processam os dados em cinco níveis, incluindo a geolocalização e a calibração das imagens até a geração de 44 produtos MODIS (NASA, 2009).

Tabela 4 Comprimento de onda e resolução das imagens do sensor MODIS para as resoluções de 250 e 500 m comparadas com as imagens do sensor OLI

Bandas MODIS	Comprimento de onda (μm)	Resolução (metros)	Bandas OLI (30 metros)
B1	0,620 – 0,670	250	B4: 0,636 - 0,673
B2	0,841 – 0,876	250	B5: 0,851 - 0,879
B3	0,459 – 0,479	500	B2: 0,452 – 0,512
B4	0,545 – 0,565	500	B3: 0,533 - 0,590
B5	1,230 – 1,250	500	
B6	1,628 – 1,652	500	B6: 1,566 - 1,652
B7	2,105 – 2,155	500	B7: 2,107 - 2,294

Fonte: Adaptado de Townshend e Justice (2002) e Gao et al. (2015).

3.5.3 Sensoriamento remoto agrícola

A melhor maneira de obter informações sobre a agricultura de forma imparcial em grandes áreas é por meio do SR orbital (ATZBERGER, 2013). Na agricultura, o sensoriamento remoto é utilizado em diversas aplicações (ATZBERGER, 2013), como na estimativa da biomassa e da produtividade (BATTUDE et al., 2016; YU et al., 2016; GUSSO; ARVOR; DUCATI, 2017), no monitoramento do vigor da vegetação e estresse hídrico (STAGAKIS et al., 2012; DUTTA et al., 2015), na avaliação do desenvolvimento fenológico da cultura (GALFORD et al., 2008; JOHANN et al., 2016), na estimativa e mapeamento de áreas cultivadas (JOHANN et al., 2012; MERCANTE et al., 2012; SOUZA et al., 2015; GRZEGOZEWSKI et al., 2016; ZHONG et al., 2016a; GAO et al.,

2017; KING et al., 2017; TORBICK et al., 2017; ZHU; RADELOFF; IVES, 2017), no mapeamento de distúrbios e mudanças de uso e cobertura da terra (VERBESSELT et al., 2010), na agricultura de precisão (ELARAB et al., 2015; KOENIG et al., 2015; ZARCO-TEJADA; GONZÁLEZ-DUGO; FERERES, 2016), em aplicações relacionadas ao uso de água (MISHRA et al., 2013; NAGLER et al., 2013; TREZZA; ALLEN; TASUMI, 2013), entre outros.

Assim, detalhadas estimativas e mapeamentos das áreas semeadas com culturas agrícolas podem ser utilizados nos modelos de produtividade para melhorar e facilitar as estimativas de produção (XIN et al., 2013; SAKAMOTO; GITELSON; ARKEBAUER, 2014; LOBELL et al., 2015; ZHONG et al., 2016a). Além disso, existe uma necessidade de melhorias no monitoramento das terras agricultáveis (ZHONG; GONG; BIGING, 2014) e da produção de mapeamentos de soja e milho regularmente, de forma confiável e oportuna (ZHONG et al., 2016a).

Porém, o mapeamento e monitoramento das culturas em escala regional ainda é desafiadora, devido à diversidade de fenologia das culturas e a necessidade de dados de sensoriamento remoto com ampla cobertura geográfica, alta resolução temporal, adequada resolução espacial (condizente com o tamanho dos talhões) e mínimo de custo (ATZBERGER, 2013; KING et al., 2017).

Nesse sentido, há diversos trabalhos que utilizaram as imagens do sensor Moderate Resolution Imaging Spectroradiometer (MODIS) para realizar o mapeamento de culturas agrícolas (GUSSO et al., 2012, 2014; JOHANN et al., 2012; VICTORIA et al., 2012; FRITZ et al., 2015; SOUZA et al., 2015; ZHONG et al., 2016a, 2016b). Principalmente por sua resolução espacial (250 m) e um tempo de revista global quase diária (GUSSO et al., 2012; ATZBERGER, 2013).

O sensor MODIS foi lançado a bordo das plataformas EOS AM-1 (Terra) em dezembro de 1999 e EOS PM-1 (Aqua) em maio de 2002 (SAKAMOTO; GITELSON; ARKEBAUER, 2014). Esse sensor possui resolução temporal de 1-2 dias; resolução radiométrica de 12 bits (4096 níveis de cinza); 36 bandas espectrais contidas no intervalo de 0,4 a 14,4 μm do espectro eletromagnético, e resolução espacial de 250 m (bandas 1-2), 500 m (bandas 3-7) e 1000 m (bandas 8 – 36) (JUSTICE et al., 2002).

Alguns autores que utilizaram o sensor MODIS para mapeamento de culturas agrícolas relatam que em áreas mais heterogêneas, com talhões menores, a sua baixa resolução espacial pode ser um fator limitante (YAN; ROY, 2014; FRITZ et al., 2015; ZHONG et al., 2016a). Zhong et al. (2016a), por exemplo, ao utilizar um modelo automático para mapeamento de soja e milho no estado do Paraná utilizando variáveis fenológicas extraídas do perfil temporal de imagens MODIS, relatam que grande parte dos pixels possuíam algum grau de mistura. Nas regiões oeste e norte do estado, que

possuem maiores áreas de cultivos, os pixels dominados por áreas de culturas, eram classificados como culturas, causando, assim, superestimativas das áreas. Já em regiões em que os tamanhos das propriedades são menores e cercados por vegetação natural, houve o efeito contrário e a área cultivadas foram subestimadas. Lobell e Asner (2004) relatam que o erro quadrado médio da classificação diminui com o aumento do tamanho dos talhões, se estabilizando para talhões maiores que 500 ha.

Uma opção para mapeamento com melhor resolução espacial são as imagens dos sensores a bordo dos satélites Landsat (30 m) (ZHONG; GONG; BIGING, 2014; ZHONG et al., 2016a). Desde o lançamento do primeiro satélite em julho de 1972 (BELWARD; SKØIEN, 2015), o Landsat se tornou um recurso global para observações da Terra, em aplicações como monitoramento ambiental, agricultura, análise e planejamento urbano, saúde humana e ambiental, gerenciamento de água e energia e monitoramento de desastres (LULLA; NELLIS; RUNDQUIST, 2012). O mais recente satélite da série Landsat lançado é o Landsat 8, que possui resolução temporal de 16 dias e radiométrica de 16 bits. O Landsat 8 carrega a bordo dois sensores o Operacional Terra Imager (OLI) e o Thermal Infrared Sensor (TIRS). O sensor OLI possui oito bandas com resolução espacial de 30 m e a pancromática com 15 m, enquanto o sensor TIRS possui duas bandas termais com resolução espacial de 100 m (ROY et al., 2014; U.S. GEOLOGICAL SURVEY, 2016).

Porém, especialmente em regiões tropicais, a frequente cobertura de nuvens pode comprometer ou inviabilizar a análise dos dados e, somado a isso, algumas imagens Landsat não estão disponíveis em certas datas, dificultando o uso contínuo destas imagens (XU; JIA; PICKERING, 2014, 2015). Em alguns casos, em regiões com intensa presença de nuvens, pesquisadores relatam obtenção de apenas de 3 a 4 imagens livre de nuvens em um ano. Além disso, seu tempo de revista de 16 dias tem limitado suas aplicações, principalmente na rápida detecção de mudanças nas superfícies, informações essenciais em aplicações como monitoramento de culturas agrícolas (GAO et al., 2006).

Assim, uma solução para este problema é a combinação de imagens de sensores com alta ou média resolução espacial (chamado de “fine-resolution” ou FR, como o Landsat) com outros de menor resolução espacial, mas com alta resolução temporal (chamado “coarse-resolution” ou CR, como o sensor MODIS) (GAO et al., 2006). Desta forma, a fusão de dados de diferentes sensores remotos é uma alternativa viável e de relativo baixo custo para aprimorar a capacidade destas imagens no acompanhamento da dinâmica da superfície da Terra (ZHU et al., 2010).

3.6 Fusão de imagens de satélites

Os dados de SR, com uma alta resolução espacial e temporal dificilmente podem ser encontrados no mesmo sensor, porém existe uma grande necessidade de dados com essas características para melhorar a capacidade de monitorar mudanças rápidas na superfície da terra (ZHU et al., 2010; ZHANG et al., 2013).

Para suprir essa necessidade, pode ser utilizada a fusão entre imagens de diferentes sensores ou bandas espectrais, que possui objetivo de gerar um produto com as melhores qualidades de ambos, integrando dados espaciais, espectrais (GHASSEMIAN, 2016) e temporais (GAO et al., 2006; ZHU et al., 2010, 2016; BISQUERT et al., 2015) do mesmo sensor ou entre sensores diferentes.

Os algoritmos de fusão mais tradicionais combinam as bandas multiespectrais com a banda pancromática para explorar as características espacial ou espectrais (GHASSEMIAN, 2016). Porém, os resultados desta técnica não são calibrados para refletância espectral, podendo não capturar mudanças quantitativas na reflectância da superfície causadas pela fenologia (GAO et al., 2006). Também não são eficazes na melhoria da resolução espacial e na cobertura temporal, simultaneamente (ZHU et al., 2010). Por outro lado, os algoritmos de fusão espaço-temporal conseguem melhoria da resolução espacial e temporal simultaneamente, utilizando dados de entrada de diferentes sensores.

Intrinsicamente os métodos de fusão espaço-temporal usam a informação espacial da imagem de entrada fine-resolution (FR – imagem com maior resolução espacial, porém com baixa resolução temporal, como o LANDSAT) e a informação temporal da imagem coarse-resolution (CR – imagem com menor resolução espacial, porém com alta resolução temporal, como o MODIS) (ZHU et al., 2016). Como a refletância da superfície da imagem de FR é desconhecida na data predita, os métodos de fusão espaço-temporal trabalham com uma abordagem não supervisionada (GAO et al., 2006). O resultado é uma imagem sintética com FR na data predita (ZHU et al., 2016).

Os métodos de fusão de dados espaço-temporal existentes podem ser divididos em três grupos: os baseados em função ponderada, os com base na mistura espectral, e os baseados em aprendizagem de par de dicionário (ZHU et al., 2016).

Os métodos baseados em função ponderada assumem que a imagem de CR e de FR são comparáveis. Obtém-se então uma relação entre os pixels das imagens de CR e FR. Após, é utilizada uma janela móvel para procurar por pixels semelhantes ao pixel central. A informação dos pixels vizinhos é utilizada para ponderar a relação entre os pixels das imagens de CR e FR, com objetivo de reduzir os efeitos de possíveis

contaminações (nuvens, ruídos) não eliminadas no pré-processamento e erros de posição geométrica entre os pixels. Em seguida, é calculado o pixel da imagem predita (GAO et al., 2006; ZHU et al., 2010, 2016; BISQUERT et al., 2015).

Já o método baseado na mistura espectral necessita de quatro passos: (1) agrupamento do conjunto de dados de FR para definir os membros finais (classes), (2) cálculo das frações ou abundâncias de cada membro final em cada pixel de CR, (3) desmembração do pixel de CR e (4) atribuição da refletância para os pixels de FR (GEVAERT; GARCÍA-HARO, 2015).

Por fim, os algoritmos baseados no aprendizado de pares de dicionários estabelecem correlações entre imagens de FR e CR com base em sua similaridade estrutural, que pode ser usada para captar as principais características, incluindo as mudanças no tipo de cobertura, nas previsões (ZHU et al., 2016).

Vários algoritmos de fusão espaço-temporal foram desenvolvidos na última década (Tabela 5), mostrando boa capacidade para melhorar as resoluções espaciais e temporais das imagens. São utilizados para monitorar diferentes tipos de uso e cobertura da terra e diversas aplicações, como áreas urbanas (ZHU et al., 2010, 2015; SONG; HUANG, 2013), áreas de inundação (EMELYANOVA et al., 2013), evapotranspiração (YANG et al., 2016, 2017), análise da fenologia ou distúrbios de florestas e vegetação (WALKER et al., 2012; TEWES et al., 2015; GÄRTNER; FÖRSTER; KLEINSCHMIT, 2016), monitoramento de culturas agrícolas e seu desenvolvimento (AMORÓS-LÓPEZ et al., 2013; GAO et al., 2015, 2017), estimativa do índice de área foliar (WU et al., 2015), estimativa de biomassa (ZHANG et al., 2016), produtividade de culturas agrícolas (LIU; WANG, 2010; WANG et al., 2014), mapeamento do uso e cobertura da terra (JIA et al., 2014a, 2014c), mapeamento de florestas (JIA et al., 2014b) e mapeamento de culturas agrícolas anuais (ZHU; RADELOFF; IVES, 2017).

Tabela 5 Resumo dos principais métodos de fusão de dados espaço temporais

Nome do método	Categoria	Requerimento de entrada	Referência
STARFM	P	Um par ou mais	(GAO et al., 2006)
STAARCH	P	Duas imagens de FR e uma serie temporal de imagens CR	(HILKER et al., 2009a)
ESTARFM	P	Dois pares	(ZHU et al., 2010)
MMT	M	Uma imagem de FR	(ZHUKOV et al., 1999)
Constrained Unmixing	M	Uma imagem de FR	(ZURITA-MILLA; CLEVERS; SCHAEPMAN, 2008)
STDFA	M	Dois pares ou mais	(WU et al., 2012)
Spatial Unmixing	M	Uma serie temporal de imagens FR	(AMORÓS-LÓPEZ et al., 2013)
STRUM	M	Um par ou mais	(GEVAERT; GARCÍA-HARO, 2015)
WA e WP	M	Um par	(BISQUERT et al., 2015)
FSDAF	M	Um par	(ZHU et al., 2016)

Nota: P - com base em função ponderada, M - com base em mistura espectral.

Fonte: Adaptado de Zhu et al. (2016).

O Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM – GAO et al., 2006) foi um dos primeiros métodos de fusão espaço temporal e vem sendo amplamente utilizado e validado (GAO et al., 2006, 2015, 2017, HILKER et al., 2009a, 2009b; LIU; WANG, 2010; ZHU et al., 2010, 2016; WATTS et al., 2011; BHANDARI; PHINN; GILL, 2012; WALKER et al., 2012; EMELYANOVA et al., 2013; JIA et al., 2014c, 2014a, 2014b; SENF et al., 2015; GEVAERT; GARCÍA-HARO, 2015; YANG et al., 2016, 2017; ZHANG et al., 2016; ZHUANG et al., 2016; ZHU; RADELOFF; IVES, 2017), mostrando bom desempenho para áreas homogêneas em que há grande variação temporal, porém não mostra um resultado tão bom para áreas heterogêneas.

O Enhanced STARFM ou Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) (ZHU et al., 2010) foi desenvolvido com base no STARFM, buscando melhorar a predição em áreas heterogêneas ao utilizar dois pares de imagens. Recentemente foi desenvolvido o Flexible Spatiotemporal Data Fusion (FSDAF), com o objetivo de prever imagens com resolução espacial FR com maior precisão em áreas heterogêneas capturando mudanças da cobertura da terra gradual e abrupta com o mínimo de dados de entrada, necessitando de apenas uma imagem de resolução espacial FR (ZHU et al., 2016).

Mais detalhes do STARFM, ESTARFM e FSDAF são apresentados nas seções 3.6.1, 3.6.2 e 3.6.3, respectivamente.

3.6.1 STARFM

O STARFM (GAO et al., 2006) é um algoritmo desenvolvido originalmente para prever a refletância da superfície diária da resolução espacial do satélite Landsat sensor Enhanced Thematic Mapper Plus (ETM+) (30 m) utilizando um ou mais pares de imagens ETM+(FR) e MODIS (CR). Desse modo, é possível obter imagens com a resolução das imagens do satélite Landsat com informações confiáveis das dinâmicas da vegetação, bem como possíveis alterações ao longo do tempo.

Inicialmente necessita-se que dados de diferentes plataformas sejam calibrados e atmosféricamente corrigidos para a refletância de superfície para serem comparáveis espacialmente e temporalmente. O STARFM se baseia na premissa que as imagens de FR e CR possuem a mesma refletância, com pequenos desvios causados pelo processamento dos dados, horário de aquisição, largura de banda, erros de geometria entre pixels (GAO et al., 2006).

É necessário pelo menos um par de imagem (uma imagem de FR e outra de CR, podendo ser utilizado dois pares) no tempo (t_k), e uma imagem de CR correspondente à data da imagem de FR a ser predita (tempo t_p) (GAO et al., 2006).

O STARFM supõe que as variações da refletância são consistentes e comparáveis nas imagens de FR e CR, se os pixels na imagem de CR forem pixels puros, ou seja, se esse pixel apenas inclui um tipo de cobertura da terra. Neste caso, as mudanças derivadas do pixel de CR podem ser diretamente adicionadas ao pixel de FR para se obter o pixel predito (GAO et al., 2006; ZHU et al., 2016). Como esta situação raramente ocorre, uma janela móvel é utilizada para atribuir um peso maior para os pixels puros da imagem de CR com base na informação dos pixels vizinhos da imagem de FR. Assim, a informação dos pixels vizinhos é utilizada a fim de evitar problemas causados pela heterogeneidade do pixel de CR (pode conter mistura de cobertura da terra na resolução do pixel de FR), a distribuição da cobertura da terra pode mudar durante o período de predição, e por mudanças temporais (fenologia da vegetação ou Bidirectional Reflectance Distribution Function - BRDF) (GAO et al., 2006).

São atribuídos pesos (W_{ik}) para cada pixel vizinho, com base em três medidas: diferença espectral entre o sensor de FR e o sensor de CR, diferença temporal entre a imagem de CR no tempo t_k e t_p , e a distância espacial entre o pixel central predito e o candidato a pixel vizinho espectralmente similar, assim determinando o quanto cada pixel vizinho (x_i, y_i) irá contribuir para estimar o valor de refletância do pixel central (GAO et al., 2006).

Desta maneira, é criada uma função (Equação 1) com diferentes pesos para cada pixel vizinho ao pixel central dentro desta janela móvel, sendo utilizados somente aqueles com boa similaridade espectral e livre de nuvens.

$$F\left(\frac{x_w}{2}, \frac{y_w}{2}, t_p\right) = \sum_{k=1}^P \sum_{i=1}^N W_{ik} \times \left(F(x_i, y_i, t_k) + \left(C(x_i, y_i, t_p) - C(x_i, y_i, t_k) \right) \right) \quad \text{Eq.(1)}$$

em que, N é o número de pixels vizinhos utilizados para prever o pixel central, P é o número de pares de imagens observadas, $F\left(\frac{x_w}{2}, \frac{y_w}{2}, t_p\right)$ é o valor do pixel de FR predito (t_p), w é o tamanho da janela móvel, W_{ik} é o peso de cada i -ésimo pixel similar, $\left(\frac{x_w}{2}, \frac{y_w}{2}\right)$ é o pixel central desta janela móvel, $C(x_i, y_i, t_p)$ é a refletância da imagem de CR para o pixel em x_i, y_i observada no t_p , $F(x_i, y_i, t_k)$ e $C(x_i, y_i, t_k)$ são as reflectâncias das imagens de FR e CR observadas no tempo t_k , respectivamente (GAO et al., 2006, 2015).

Para a implementação, primeiro os dados da imagem de FR são usados para procurar pixels (o) que são espectralmente similares ao pixel central (+) dentro da janela móvel (Figura 3). Em seguida ocorre uma filtragem destas amostras para assegurar uma boa seleção dos pixels. Ambos os dados, de FR e CR, são utilizados para determinar o peso das amostras de acordo com uma função de peso (o pixel de cor preta possui o maior peso). Por último, o valor predito é computado com base no peso dos pixels vizinhos selecionados.

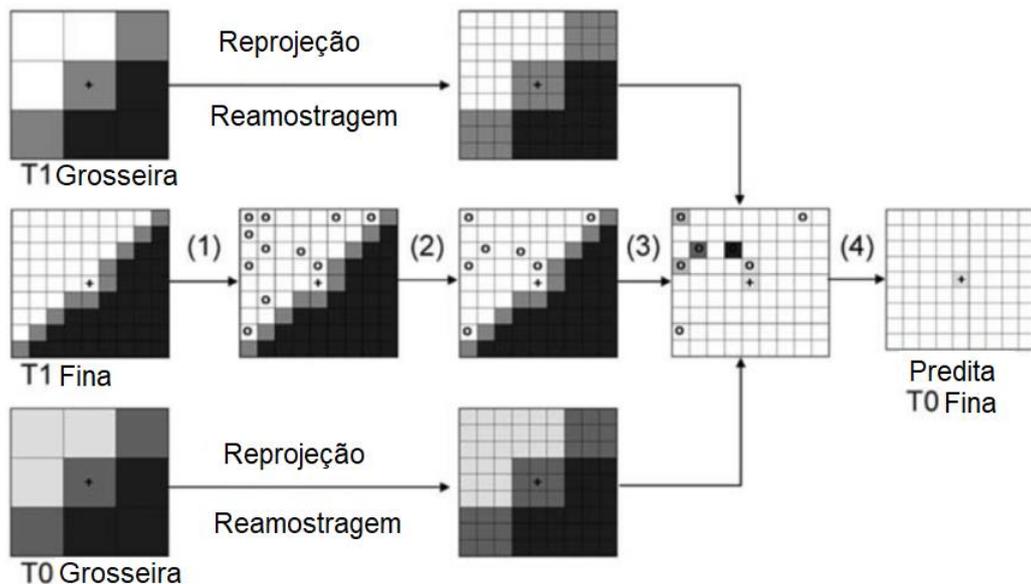


Figura 3 Esquema da metodologia empregada pelo STARFM.
Fonte: Gao et al. (2006).

O algoritmo STARFM foi testado e validado por Gao et al. (2006), utilizando o produto MODIS MOD09GHK, que é um produto diário de refletância da superfície com

500 metros de resolução espacial e imagens Landsat-7 ETM+ e concluíram que os dados preditos apresentaram boa acurácia, preservando a alta resolução espacial das imagens ETM+ e alta resolução temporal das imagens do sensor MODIS. Em regiões que apresentaram paisagem mais complexa, alguns parâmetros, como o tamanho da janela móvel deve ser ajustado para melhorar a performance do algoritmo. Além do mais, verifica-se que a predição pode ser realizada com apenas um par de imagens TM/ETM+ e MODIS como dados de entrada, mas o resultado pode ser melhorado com a utilização de mais um par de imagens, e que mudanças ocorridas em uma escala menor que o pixel MODIS não são preditas pelo STARFM.

Hilker et al. (2009b), utilizando os produtos MOD09A1/ MYD09A1 do sensor MODIS, que formam uma composição de imagens de 8 dias da refletância de superfície e o Landsat 5 TM, testaram o uso do STARFM para avaliação das mudanças sazonais em regiões de florestas boreais e sub-boreais utilizando as bandas do vermelho, NIR (Near Infrared) e Shortwave Infrared (SWIR), além do NDVI (Normalized Difference Vegetation Index) e encontraram bons resultados. As imagens preditas mantiveram os detalhes espaciais, porém o algoritmo foi menos eficaz em prever eventos de distúrbio. As predições para as bandas de comprimento de onda menor se mostraram menos precisas que para o NIR.

Gao et al. (2017) utilizaram os produtos de refletância diária de superfície de 250 m (MOD09GQ), 500 m (MOD09GA), o MODIS Bidirectional Reflectance Distribution Function (BRDF) com 500 m de resolução (MCD43A1), os tipos de cobertura de terra MODIS a 500 m de resolução (MCD12Q1) e imagens do Landsat 5 TM, Landsat 7 ETM+ e Landsat 8 OLI para captar a variabilidade espacial e sazonal entre as classes de milho, soja e floresta, para a região do Corn Belt, em Iowa Central nos EUA. Ao comparar a imagem sintéticas com a imagem Landsat da mesma data, obtiveram vieses médios maiores para o NIR do que para o vermelho. Segundo eles, quando há um maior viés entre a imagem Landsat e MODIS, causados principalmente pela diferença do ângulo de visão, menor a precisão das imagens sintéticas. Os autores concluíram que sensor OLI possui menor variação durante a período de desenvolvimento das culturas (soja e milho) para a região de estudo em comparação com o TM e ETM+.

Zhu, Radeloff e Ives (2017) utilizaram o produto de 8 dias do MODIS NBAR (MCD43A4), que é uma composição de refletância de 16 dias, das bandas do azul, verde, vermelho, NIR, SWIR1 e SWIR2 para gerar imagens com o STARFM e mapear cultura agrícolas (soja, milho, trigo e alfafa) em Wisconsin, nos EUA. As imagens da banda NIR, seguida pela SWIR1, verde e azul tiveram maiores precisões, enquanto o SWIR2 e o vermelho tiveram os piores resultados. Eles obtiveram resultados iguais ou inferiores utilizando dois pares observados de entrada, em comparação com apenas um

par. Constataram também que as datas das imagens observadas de entrada também têm grande influência no resultado das imagens sintéticas preditas. Segundo eles, ao utilizar par de imagens observadas das datas em que as culturas agrícolas estão próximas ao máximo desenvolvimento vegetativo é melhor do que as datas próximas ao plantio ou senescência.

3.6.2 ESTARFM

O ESTARFM (ZHU et al., 2010) foi desenvolvido com base no STARFM para melhorar a predição em áreas com cobertura da terra heterogêneas utilizando a refletância em dois pontos no tempo, ou seja, utiliza dois pares de imagens (cada par possui uma imagem de FR e outra de CR adquiridas no mesmo dia), e uma imagem de CR na data a ser predita a imagem de resolução espacial FR.

O ESTARFM assume que os dados de SR de diferentes sensores adquiridos na mesma data são comparáveis e correlacionados após a calibração radiométrica, retificação geométrica e correção atmosférica, podendo haver vieses sistemáticos causados por diferenças nos sistemas dos sensores como parâmetros orbitais, largura de banda, horário de aquisição e função da resposta espectral (ZHU et al., 2010).

Enquanto o STARFM assume que as mudanças nos pixels da imagem de FR são equivalentes às mudanças que ocorrem no pixel equivalente da imagem de CR, o ESTARFM considera que as mudanças ocorridas nas imagens de FR são proporcionais às mudanças ocorridas nos pixels de resolução espacial CR, introduzindo um coeficiente $v(x, y)$ para ponderar as mudanças na refletância da superfície da imagem de CR na escala de FR (GAO et al., 2015). Para ponderação média são considerados três fatores: a diferença espectral entre a imagem de FR e CR na mesma data, a diferença temporal entre as duas imagens de CR e a distância espacial entre os pixels similares na janela móvel e o pixel central (BISQUERT et al., 2015).

Semelhante ao STARFM, o ESTARFM também utiliza uma janela móvel para procurar por pixels similares. Porém, o ESTARFM pode utilizar pixel de resolução espacial FR fora da janela móvel para calcular o coeficiente de ponderação $v(x, y)$, desde que estes pixels estejam dentro do pixel de resolução espacial CR e que parte deste esteja dentro da janela móvel (Figura 4) (ZHU et al., 2010).

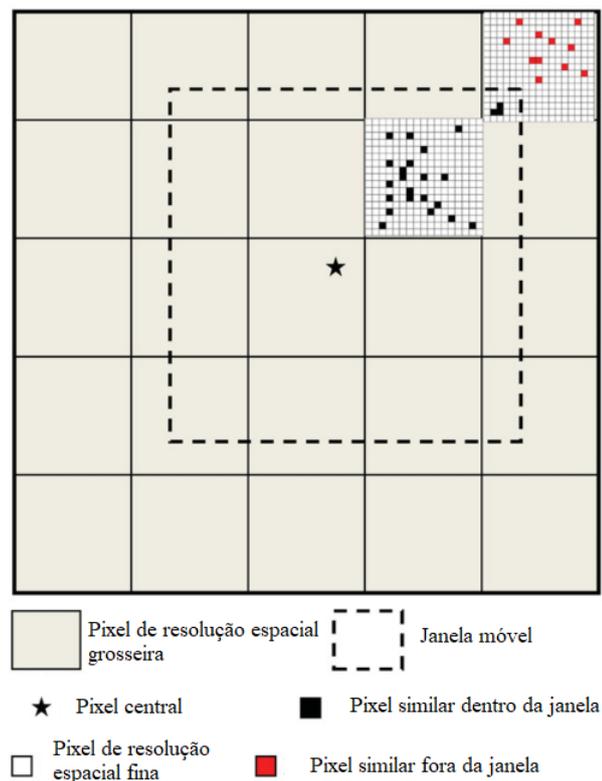


Figura 4 Esquema da janela móvel utilizada pelo ESTARFM.
Fonte: Zhu et al. (2010).

Para pixels homogêneos na imagem de resolução espacial CR, o ESTARFM considera que qualquer diferença detectada entre as refletâncias das imagens de CR e FR são vieses sistemáticos – assim, permitindo que este viés varie através dos pixels grosseiros utilizando um coeficiente de conversão, como a razão de variação de refletância entre as refletâncias FR e CR para cada pixel CR. Já para os pixels de CR com mistura espectral, um modelo linear de mistura espectral é aplicado para estimar o coeficiente de conversão efetivo para cada pixel de FR, com base na mistura de classes no pixel de CR (ZHU et al., 2010; GAO et al., 2015).

Para a computação do ESTARFM, são realizados quatro passos (TEWES et al., 2015): (1) Duas imagens de FR são usadas para procurar por pixel semelhantes ao pixel central em uma janela móvel, (2) as distâncias espectral e espacial entre cada pixel similar e o pixel a ser predito são calculados ponderando cada pixel similar w_i , (3) Uma regressão linear dos valores de CR nos dois pares observados (t_1 e t_2) e os valores do pixel de FR do pixel similar é usada para determinar o coeficiente de conversão $v(x,y)$, que é então utilizado para converter a alteração encontrada a partir do valor da imagem de CR para as imagens de FR, (4) a refletância da imagem de FR é predita para a data t_p a partir da imagem de CR (Equação 2) (ZHU et al., 2010; GAO et al., 2015).

$$F\left(\frac{x_w}{2}, \frac{y_w}{2}, t_p\right) = \sum_{k=1}^2 T_k \times F\left(\frac{x_w}{2}, \frac{y_w}{2}, t_k\right) + \sum_{i=1}^N W_{ik} \times v(x_i, y_i) \times \left(C(x_i, y_j, t_p) - C(x_i, y_j, t_k)\right) \quad \text{Eq.(2)}$$

em que, T_k determina a contribuição de cada par de imagens, com base na magnitude de mudança da imagem de resolução espacial CR da data predita a cada par de imagem de entrada na CR, sendo que o par com menor magnitude de mudança contribui mais na predição final, N é o número de pixels vizinhos utilizados para predizer o pixel central, $F\left(\frac{x_w}{2}, \frac{y_w}{2}, t_p\right)$ é o valor do pixel de FR predito (t_p), w é o tamanho da janela móvel, W_{ik} é o peso de cada i -ésimo pixel similar, $\left(\frac{x_w}{2}, \frac{y_w}{2}\right)$ é o pixel central desta janela móvel, $C(x_i, y_j, t_p)$ é a refletância da imagem de CR para o pixel em x_i, y_j observada no t_p , $F(x_i, y_i, t_k)$ e $C(x_i, y_i, t_k)$ são as refletâncias das imagens de FR e CR no tempo t_k , respectivamente.

O algoritmo ESTARFM foi testado e validado por Zhu et al. (2010), que também o compararam com o STARFM. Eles utilizaram o produto de refletância diária do sensor MODIS (MOD09GA) e imagens Landsat-7 ETM+ em uma região heterogênea que possui predomínio de floresta, solo, água e área urbana. O ESTARFM mantinha detalhes espaciais, enquanto as imagens preditas pelo STARFM pareciam “borradas” em algumas áreas. Ambos os algoritmos conseguiram capturar as mudanças de refletância causadas pela fenologia da vegetação. O ESTARFM obteve melhores resultados na banda NIR em comparação com STARFM, em regiões homogêneas e heterogêneas. A banda NIR teve menor diferença média, quando comparado com a imagem predita com a imagem original, seguida pela banda verde e vermelho. Segundo os autores, o STARFM teve pior desempenho com dois pares de entrada do que apenas com um. Além do mais, eles fazem algumas ponderações e cuidados ao utilizar o ESTARFM: que o algoritmo não pode predizer com precisão mudanças transitórias de curto prazo que não são capturadas nas imagens de FR predita; que o ESTARFM pode não ser adequados para sensores com bandas espectrais muito diferentes; e que é melhor utilizar imagens observadas de datas próximas às da imagem predita do que imagens de datas muito distantes.

Emelyanova et al. (2013) realizaram uma detalhada avaliação dos algoritmos STARFM e ESTARFM utilizando o produto MODIS Terra MOD09GA e imagens Landsat 7 ETM+ e Landsat 5 TM em duas áreas de estudo que contrastavam dinâmicas espacial e temporais. Eles concluíram que o tipo de cobertura da terra está fortemente associado com a performance do algoritmo e está intrinsecamente ligado às características do domínio do local, variações espaciais e temporais e das bandas espectrais. O

ESTARFM de forma geral obteve resultado superior quando a variação espacial era dominante. Já o STARFM geralmente foi melhor quando dada uma banda espectral a variação temporal é maior.

3.6.3 FSDAF

O FSDAF requer um par de imagem de FR e CR adquiridas no tempo t_k e uma imagem de CR no tempo t_p , e a saída é uma imagem de FR no tempo t_p (ZHU et al., 2016). O FSDAF assume uma relação linear entre as previsões da alteração total de um valor de pixel fino entre o tempo de aquisição de imagem FR t_k e o tempo de simulação t_p (ZHUANG et al., 2016).

É necessário que as imagens de CR e FR sejam convertidas para a mesma grandeza física (como refletância no topo da atmosfera ou refletância da superfície) e sejam georreferenciadas (ZHU et al., 2016). O processo de georreferenciamento pode ser realizado seguindo os seguintes passos: reprojeção do sistema de coordenadas para o mesmo sistema caso seja diferentes, reamostragem da imagem de CR para o tamanho de pixel da imagem de FR pelo método do vizinho mais próximo, georreferenciar uma imagem para a outra utilizando pontos de controle ou maximizando a correlação entre as duas imagens, e recortando para a mesma área (EMELYANOVA et al., 2013; GEVAERT; GARCÍA-HARO, 2015; ZHU et al., 2016).

O FSDAF inclui seis passos principais: (1) classificar a imagem de resolução espacial FR em t_k (pode ser uma classificação previa ou o próprio algoritmo realiza uma classificação não supervisionada ISODATA); (2) estimar a mudança temporal de cada classe da imagem de resolução espacial CR de t_k para t_p ; (3) prever a imagem de resolução espacial FR em t_p usando a mudança temporal ao nível de classe e calculando os resíduos de cada pixel de resolução espacial CR; (4) prever a imagem de resolução espacial FR a partir da imagem de resolução espacial CR em t_p com um interpolador Thin Plate Spline (TPS); (5) distribuir os resíduos com base na predição TPS; (6) obter a previsão final da imagem de FR (Equação 3) usando informações na vizinhança (ZHU et al., 2016).

$$F(x_{ij}, y_{ij}, t_p) = F(x_{ij}, y_{ij}, t_k) + \sum_{k=1}^N W_k \times \Delta F(x_k, y_k) \quad \text{Eq.(3)}$$

em que, (x_i, y_i) é a coordenada do i -ésimo pixel, i é o índice do pixel de CR, j é o índice do pixel de FR dentro do pixel grosseiro, $F(x_{ij}, y_{ij}, t_p)$ é o valor do j -ésimo pixel de FR dentro do pixel de CR na localização (x_i, y_i) predito no tempo t_p , $F(x_{ij}, y_{ij}, t_p)$ é o valor do j -ésimo pixel de FR dentro do pixel de CR na localização (x_i, y_i) observado no tempo t_k ,

W_k é o peso de cada *i*-ésimo pixel similar e $\Delta F(x_k, y_k)$ significa o *i*-ésimo pixel calculado pela função ΔF (Equação Eq.(4)).

$$\Delta F(x_i, y_i) = r(x_i, y_i) + \Delta F(c) \quad \text{Eq.(4)}$$

em que, $r(x_i, y_i)$ é um parâmetro que usa a mudança temporal da imagem de FR e um TPS recuperado utilizando a imagem de CR para prever alterações de mudança gradual e de tipo de cobertura de solo, $\Delta F(c)$ é a mudança de valor da classe c na FR entre t_k e t_s .

Outra diferença do FSDAF para o STARFM e ESTARFM é que utiliza apenas os pixels que são da mesma classe e que estão dentro da janela móvel (Figura 5).

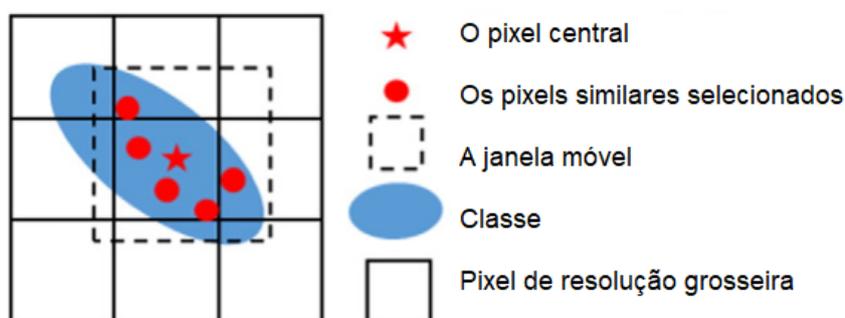


Figura 5 Esquema da janela móvel utilizada pelo FSDAF.

Fonte: Zhu et al. (2016).

Zhu et al. (2016) testaram e validaram o FSDAF utilizando a mesma base de dados utilizados por Emelyanova et al. (2013), e compararam as imagens preditas pelo FSDAF com as preditas pelo STARFM. Também verificaram que o FSDAF foi mais eficiente em prever mudanças que ocorreram entre a data da imagem de FR observada e a data da imagem predita para áreas pequenas (como pequenos talhões agrícolas). O FSDAF obteve maiores acurácias em comparação com o STARFM. Por fim, concluíram que embora o FSDAF possa prever tanto a mudança gradual de refletância como a mudança de tipo de cobertura de terra entre as datas de entrada e de previsão, não pode capturar pequenas alterações no tipo de cobertura de terra, por exemplo, se ocorre em apenas alguns pixels finos e não ocorre na imagem de CR.

3.7 Índices de Vegetação

Os índices de vegetação (IV) são combinações da refletância de diferentes comprimentos de onda, principalmente do visível e do infravermelho próximo (NIR), com objetivo de estimar remotamente características biofísicas da vegetação (VIÑA et al., 2011). Os IVs derivados de dados de satélites são os parâmetros mais utilizados e eficazes para analisar as características da superfície de vegetação (ZHANG, 2015). O

IV Normalized Difference Vegetation Index (NDVI) (ROUSE et al., 1974) é amplamente utilizado na agricultura, pois é de fácil aplicação, possibilitando uma rápida e eficiente detecção das variações na vegetação (BERNARDI et al., 2014). Vários estudos já foram conduzidos comprovando a forte relação do NDVI com a radiação fotossinteticamente ativa (RFA) (GAMON et al., 1995), índice de área foliar (IAF) (FASSNACHT et al., 1997), quantidade de biomassa e com o nitrogênio das culturas agrícolas (HANSEN; SCHJOERRING, 2003). O NDVI também é frequentemente utilizado para classificar culturas agrícolas (ARAÚJO et al., 2011; VICTORIA et al., 2012; SHAHRIAR PERVEZ; BUDDE; ROWLAND, 2014; FAN et al., 2015; SOUZA et al., 2015), monitorar o seu desenvolvimento (ESQUERDO; ZULLO JÚNIOR; ANTUNES, 2011; GAO et al., 2017) e para estimativa de produtividade (WANG et al., 2014; SUN et al., 2017).

Além do mais, o NDVI é um indicador da evolução temporal da biomassa verde de culturas ao longo do ciclo, apresentando baixos valores no início do ciclo, cresce gradualmente até um máximo de biomassa e decresce com o término do ciclo da cultura (ESQUERDO; ZULLO JÚNIOR; ANTUNES, 2011; RODRIGUES et al., 2013). Porém, em condições em que há maior cobertura do solo com plantas, o NDVI pode saturar, tornando-se insensível as alterações de IAF e biomassa (POVH et al., 2008).

Já o Enhanced Vegetation Index (EVI) utiliza informações de refletância das bandas do vermelho, NIR e azul e foi desenvolvido com o objetivo de otimizar o sinal da vegetação com sensibilidade melhorada em regiões de alta biomassa e melhorar o monitoramento da vegetação através de um desacoplamento entre o sinal de fundo do dossel e uma redução nas influências da atmosfera (HUETE et al., 2002). Muitos trabalhos utilizam o índice de vegetação EVI para realizar o mapeamento de áreas semeadas com culturas, o qual tem se mostrado eficiente para o monitoramento agrícola (ARAÚJO et al., 2011; GUSSO et al., 2012; JOHANN et al., 2012; SOUZA et al., 2015; GRZEGOZEWSKI et al., 2016; BECKER et al., 2017a).

SOUZA et al. (2015) compararam a utilização de perfis espectro temporais de NDVI, EVI e Wide Dynamic Range Vegetation Index (WDRVI) para mapeamento de soja e milho no estado do Paraná, observando que diferentes IVs apresentam diferenças na sensibilidade a vegetação, e que podem influenciar no resultado da classificação.

Ao classificar e monitorar culturas agrícolas, diversos estudos utilizam a análise temporal dos índices de vegetação, principalmente dos dados derivados do sensor MODIS, devido a sua alta resolução temporal (JOHANN et al., 2012, 2016; SANTOS et al., 2014; SOUZA et al., 2015; ZHONG; WANG; WU, 2015; GRZEGOZEWSKI et al., 2016; MENGUE; FONTANA, 2016; ZHONG et al., 2016a). Com o surgimento na última década de métodos de fusão espaço-temporal, torna-se possível também a análise temporal dos IVs com melhores resoluções espaciais (como a do Landsat – 30 m).

Nesse caso, Jarihani et al. (2014) sugerem que a geração de imagens por métodos de fusão espaço-temporal pode obter uma precisão melhor quando diretamente aplicados aos IVs, do que quando aplicado as bandas espectrais, e então calcula os IVs, devido a menor propagação de erros.

3.8 Mapeamento de culturas agrícolas

Informações como extensão de áreas, tipos de culturas e dinâmica de rotação de culturas são muito importantes para os responsáveis pela tomada de decisão (ZHONG; GONG; BIGING, 2014). Também podem ser utilizados em modelos de estimativas de rendimento das culturas agrícolas (SAKAMOTO; GITELSON; ARKEBAUER, 2014), e é uma das variáveis para a estimativa da produção (produção = área x produtividade).

Alguns estudos utilizaram a informação espectral de imagens Landsat para realizar o mapeamento de culturas agrícolas (RIZZI; RUDORFF, 2005; SUGAWARA; RUDORFF; ADAMI, 2008; DELGADO et al., 2012; MERCANTE et al., 2012). Outros, como Zhong, Gong e Biging (2014), utilizaram métricas fenológicas extraídas do perfil temporal de EVI do Landsat 5 TM e Landsat 7 ETM+ para mapear soja e milho. Porém, as altas incidências de nuvens durante o período de desenvolvimento das culturas podem dificultar a classificação ou até inviabilizar o uso do Landsat (SANO et al., 2007; SUGAWARA; RUDORFF; ADAMI, 2008).

Assim, para o monitoramento da atividade agrícola é imprescindível a análise de múltiplas datas, para obter informações do comportamento espectro-temporal (perfil) ao longo de todos os estádios fenológicos da cultura (JENSEN et al., 2002). Muitos estudos utilizaram a análise temporal dos IVs extraídos de imagens do sensor MODIS (GUSSO et al., 2012, 2014; JOHANN et al., 2012; SILVA JUNIOR; FRANK; RODRIGUES, 2014; SOUZA et al., 2015; ZHONG; WANG; WU, 2015; GRZEGOZEWSKI et al., 2016; ZHONG et al., 2016a, 2016b). Alguns desses estudos extraíram métricas do perfil temporal de IV, como valores de máximos e mínimos, mostrando bons resultados (GUSSO et al., 2012, 2014; SILVA JUNIOR; FRANK; RODRIGUES, 2014; SOUZA et al., 2015; GRZEGOZEWSKI et al., 2016). Porém, esta metodologia necessita de informações prévias da data de semeadura e de máximo desenvolvimento vegetativo, que podem variar de uma região para outra e de um ano para outro.

Outra metodologia que vem sendo utilizada é a extração de métricas fenológicas do perfil espectral de IVs. A fenologia é o estudo de eventos biológicos periódicos e seus fatores de controle, e as métricas fenológicas, representam os estádios fenológicos e o progresso sazonal da cultura ou de outros tipos de vegetação (ZHONG; GONG; BIGING, 2014). Os dados de SR vêm sendo utilizado para fornecer informações da

fenologia da vegetação, como início do crescimento, máximo desenvolvimento vegetativo e senescência (ZHANG et al., 2003; JOHANN et al., 2016; GAO et al., 2017). Diferentes tipos de vegetação possuem diferentes características fenológicas, mostrando diferentes perfis de crescimento em dados de séries temporais de IV obtidos por SR, podendo fornecer informações valiosas para a classificação do tipo de cobertura da terra (JIA et al., 2014c). A utilização de parâmetros fenológicos na classificação de culturas tem o potencial de possibilitar a transferência interanual de algoritmos de classificação, podendo alcançar um desempenho estável em relação aos valores das imagens originais (ZHONG; GONG; BIGING, 2014).

Segundo Gao et al. (2017), geralmente são utilizadas funções matemáticas para ajustar séries temporais de IVs, então as variáveis ou parâmetros fenológicos são extraídos com base em um limiar de IV predefinido (JÖNSSON; EKLUNDH, 2002, 2004) ou nos pontos de inflexão da função de ajuste (ZHANG et al., 2003). Jönsson e Eklundh (2002, 2004) desenvolveram o software TIMESAT que extrai 11 variáveis fenológicas. O TIMESAT suaviza os valores dos IVs e ajusta a função selecionada usando Savitzky–Golay (SAVITZKY; GOLAY, 1964), Gaussian Asymmetric (JÖNSSON; EKLUNDH, 2002) e Double Logistic (BECK et al., 2006). As datas de semeadura e colheita, por exemplo, são identificadas como as datas em que o IV passa por limites pré-definidos (porcentagem da amplitude sazonal – valor de máximo menos valor de mínimo) (EKLUNDH; JÖNSSON, 2015). Estes limiares devem ser adequadamente definidos para captar os estádios de crescimento (GAO et al., 2017). O método de Zhang et al. (2003) utiliza uma função logística para o ajuste da função, e as características da série temporal que indicam a início de crescimento, o início da maturidade, início da senescência e o fim do ciclo são determinados pela curvatura da função logística, sendo que esta abordagem não requer nenhum limiar pré-definido (GAO et al., 2017).

Becker et al. (2017) utilizaram onze variáveis fenológicas extraídas do perfil temporal de EVI do sensor MODIS pelo software TIMESAT para classificar soja e milho no estado do Paraná por meio de Árvore de Decisão, e obtiveram bons resultados com exatidão global de 96,3%.

Zhong et al. (2016a) utilizaram variáveis fenológicas extraídas do perfil temporal de EVI junto com variáveis espectrais do sensor MODIS para realizar o mapeamento de soja e milho no estado do Paraná de forma automática. Os autores realizaram o treinamento do modelo de classificação no ano de 2012 e o aplicaram para os anos de 2010, 2011, 2013 e 2015, obtendo exatidão global de 87,2% e coeficiente de determinação (R^2) acima de 0,93 quando compararam a área obtida pelo mapeamento com dados oficiais (IBGE), porém relatam que a resolução espacial do MODIS pode influenciar nos resultados.

Zhong et al. (2016b) desenvolveram um estudo semelhante para a região do Corn Belt nos EUA, utilizando variáveis fenológicas e espectrais, realizando treinamento do classificador utilizando dados de referência de anos diferentes ao utilizado para a classificação. Os autores compararam uma metodologia que considera o pixel MODIS inteiro (hard) e uma que considera que o MODIS possui mistura espectral (fuzzy). Ao final, obtiveram um R^2 médio acima de 0,89 para a metodologia fuzzy ao compararem o resultado deles com dados oficiais (USDA). Os autores relatam que a metodologia fuzzy obteve R^2 muito superior à Hard, o que é esperado, segundo eles, devido à resolução do sensor MODIS, que possui muitos pixels mistos (com mistura espectral).

Essas classificações de uso e cobertura da terra utilizando dados de séries temporais de sensoriamento remoto geralmente são realizados utilizando imagens com resolução espacial baixa (CR), devido à dificuldade de se conseguir dados de FR com alta frequência temporal (JIA et al., 2014c). A utilização de métodos de fusão de imagens espaço-temporal pode servir para obtenção de dados temporais de imagens com FR (GAO et al., 2017).

Jia et al. (2014c) utilizaram o STARFM para gerar imagem sintéticas e compararam métricas espectrais e métricas extraídas do perfil espectro-temporal de NDVI (máximo, mínimo média e desvio padrão) para classificar seis classes de uso e cobertura do solo (água, culturas, solo, áreas impermeáveis, grama e floresta) em Beijing na China. Eles concluíram que as características temporais extraídas de séries temporais de imagens com resolução espacial CR têm abundante informação do crescimento da vegetação e possuem significativo efeito em melhorar o resultado da classificação em imagens de resolução espacial FR.

Senf et al. (2015) compararam vários cenários para mapear o uso e ocupação da terra (solo, campos de cereais, florestas, água, grama e mata) para Beja em Portugal. Os cenários eram: a utilização de uma única imagem; uma imagem Landsat e uma imagens do período em que a culturas estavam com mínimo de desenvolvimento vegetativo e outra que estavam com o máximo geradas pelo STARFM; uma imagem Landsat e todas as imagens geradas pelo STARFM (31 no total); utilizando imagens Landsat próxima ao máximo e mínimo; e todas as seis imagens Landsat disponíveis. Os autores concluíram que quando a quantidade de imagens Landsat disponíveis é limitada a utilização de imagens sintéticas gerados pelo STARFM aumenta a precisão da classificação.

Jia et al. (2014a) avaliaram a eficácia de variáveis fenológicas (início e final do ciclo, a duração do ciclo, a amplitude, e o máximo valor de NDVI ajustado) extraída de serie temporais de NDVI gerados pelo STARFM, comparando com a utilização apenas de variáveis espectrais (valor de refletância das bandas espectrais) e variáveis

estatísticas (máximo, mínimo, médio e desvio padrão) extraídas do perfil temporal de NDVI para classificar seis classes de uso e cobertura do solo (água, culturas, solo, áreas impermeáveis, grama e floresta) em Beijing na China. Para culturas agrícolas, as variáveis estatísticas obtiveram acurácia de produtor e usuário 3% maiores do que as obtidas com variáveis fenológicas. Para vegetação as variáveis fenológicas e estatísticas obtiveram resultado semelhante, sendo superior às variáveis espectrais, concluindo que as variáveis estatísticas extraídas das séries temporais de IV podem ter vantagem sobre as variáveis fenológicas por não precisarem de um ano ou ciclo completo de imagens e o tempo entre duas cenas consecutivas não precisam ser o mesmo (VALERO et al., 2016).

Zhu, Radeloff e Ives (2017) utilizaram imagens geradas pelo STARFM para mapear soja, milho, trigo, alfafa, pastagem e floresta em Wisconsin, nos EUA, utilizando três cenários. Os cenários eram: utilização de uma ou duas imagens Landsat; utilização de uma ou duas imagens Landsat mais todas as imagens preditas pelo STARFM para o ano (intervalo de 16 dias entre imagens); e a utilização de uma ou duas imagens Landsat mais as imagens preditas pelo STARFM para datas chaves (períodos importantes para o desenvolvimento das culturas). Os autores relatam que a inclusão de imagens preditas pelo STARFM em datas chaves pode melhorar o resultado da classificação, enquanto a inclusão de todas as imagens preditas pelo STARFM, aumenta o erro de classificação. Segundo eles, isto ocorre por que a informação espectral com alta correlação no tempo causa redundância dos dados, e as imagens preditas pelo STARFM apresentam alguns erros, que podem se acumular, reduzindo a acurácia da classificação.

Apesar de vários métodos de fusão espaço-temporal terem sido desenvolvidos nos últimos anos, ainda são poucos utilizados para melhorar a precisão do uso e cobertura da terra (JIA et al., 2014b). Neste contexto, ainda são necessários estudos para avaliarem se variáveis (espectrais, estatísticas, fenológicas) extraídas de imagens geradas a partir de métodos de fusão espaço-temporais podem aprimorar os resultados dos mapeamentos e diferenciação de culturas agrícolas, como a soja e o milho, em áreas heterogêneas espacialmente, como na região oeste do Paraná.

3.9 Mineração de dados e descoberta de conhecimento

Nos últimos anos tem aumento o número de sensores e as resoluções dos sensores orbitais; assim, houve um enorme crescimento da quantidade de dados gerados (PRUDENTE et al., 2017). Uma das soluções que podem ser utilizadas para a análise desta grande quantidade de dados é a mineração de dados, que é a principal etapa do processo de descoberta de conhecimento em base de dados (Knowledge

Discovery in Databases – KDD) (FAYYAD; PIATETSKY-SHAPITO; SMYTH, 1996). O processo de KDD tem por objetivo encontrar relações ou padrões ocultos em base de dados, convertendo dados brutos em informações úteis, dispondo de ferramentas baseadas em aprendizagem de máquina, para facilitar o processo de extração, reconhecimento de padrões e a descoberta de conhecimento. O KDD pode ser dividido em cinco etapas (FAYYAD; PIATETSKY-SHAPITO; SMYTH, 1996): i) seleção dos dados; ii) pré-processamento; iii) formatação/transformação; iv) mineração de dados; v) interpretação/avaliação.

Vários tipos de técnicas de mineração podem ser utilizados como generalização, caracterização, classificação, agrupamento, associação, entre outras (LIAO; CHU; HSIAO, 2012). Nas técnicas de classificação amostras desconhecidas são classificadas usando a informação de amostras de treinamento (MUCHERINO; PAPAJORGJI; PARDALOS, 2009).

Algoritmos baseados em aprendizado de máquina (AM) são uma alternativa que tem alcançado resultados extremamente eficientes para classificação de alvos agrícolas (VALERO et al., 2016). Os métodos comumente utilizados são Redes Neurais (RN), Support Vector Machines (SVM), Árvore de Decisão (AD) e Random Forests (RF), ou algumas vezes, até combinações destes algoritmos (PEÑA et al., 2014; LARY et al., 2016).

Sharma, Ghosh e Joshi (2013) conseguiram melhores resultados utilizando AD em comparação ao Maxver e ao Isodata para classificar Landsat 5/TM na Índia. Segundo esses autores, o algoritmo de AD consegue se adaptar melhor a ruídos e relações não-linear entre as classes de uso da terra. Por não ser um classificador paramétrico também não é sensível a outliers.

Estel et al. (2015) conseguiram altas acurácias utilizando o algoritmo RF para mapear áreas agrícolas abandonadas e recultivadas na Europa com séries temporais de NDVI MODIS. Müller et al. (2015) também conseguiram bons resultados utilizando RF em séries temporais de Landsat para classificar culturas, pastagem e vegetação natural com exatidão global de até 93%.

Pelletier et al. (2016) aplicaram o RF e o SVM em métricas espectrais, de NDVI, temporais e combinação destas, extraídas de imagens Landsat-8 e SPOT-4 para mapear o uso e a ocupação da terra na França. RF mostrou melhor trade-off entre a performance de classificação e o tempo gasto para processamento, chegando a uma exatidão global de 83,3%.

4 MATERIAL E MÉTODOS

4.1 Organização da dissertação

A Figura 6 apresenta o fluxograma geral do trabalho. O trabalho está dividido em dois artigos científicos, que são detalhados nos itens: (6) Mapeamento de áreas agrícolas utilizando técnicas de mineração de dados em séries temporais de imagens Landsat 8; (7) Mapeamento de soja e milho utilizando fusão de imagens Landsat 8 e MODIS.

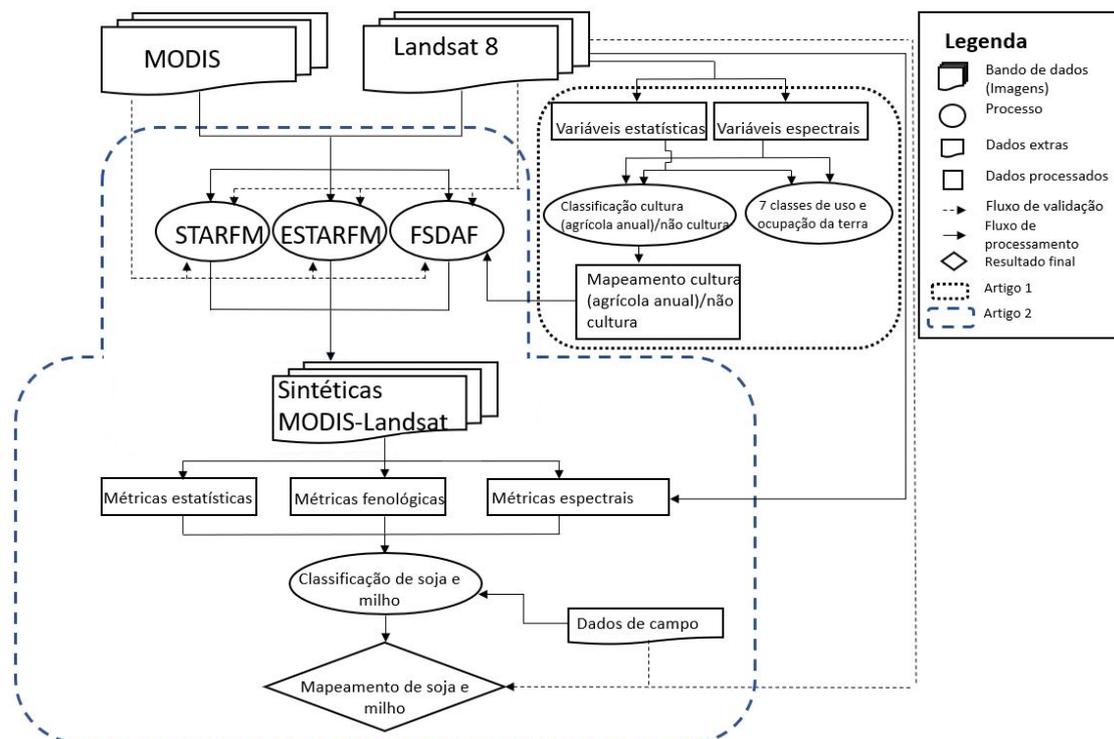


Figura 6 Fluxograma geral do trabalho.

A primeira parte teve o objetivo principal de separar e mapear culturas agrícolas de outros alvos. Foram comparadas técnicas de mineração de dados e a utilização de métricas estatísticas com métodos tradicionais utilizando apenas as bandas espectrais e classificador de Máxima Verossimilhança. Já na segunda parte da dissertação, foram comparados três métodos de fusão espaço-temporal para gerar imagens sintéticas a partir de imagens Landsat 8 e MODIS. O melhor resultado gerado na primeira parte serviu de entrada em um dos algoritmos de fusão espaço-temporal, o FSDAF. Então, foi avaliado se, utilizando as imagens sintéticas com resolução espacial de 30 m e temporal de 8 dias, é possível melhorar o mapeamento de soja e milho em comparação com a utilização de apenas as imagens Landsat 8 livre de nuvens existentes.

5 REFERÊNCIAS

ABREU, K. M. P. de; COUTINHO, L. M. Remote sensing applied to the study of vegetation with emphasis on index of vegetation and landscapes metrics. **Revista Vértices**, v. 16, n. 1, p. 173-198, 2014. Disponível em: <<http://www.gnresearch.org/doi/10.5935/1809-2667.20140012>>. Acesso em: 8 jan. 2017.

AMORÓS-LÓPEZ, J.; GÓMEZ-CHOVA, L.; ALONSO, L.; GUANTER, L.; ZURITA-MILLA, R.; MORENO, J.; CAMPS-VALLS, G. Multitemporal fusion of Landsat/TM and ENVISAT/MERIS for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, n. 1, p. 132-141, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2012.12.004>>. Acesso em: 10 jan. 2017.

ARAÚJO, G. K. D.; ROCHA, J. V.; LAMPARELLI, R. A. C.; ROCHA, A. M. Mapeamento de culturas de verão no estado do Paraná por meio de composições decendiais de NDVI do sensor Spot Vegetation. **Engenharia Agrícola**, v. 31, n. 4, p. 760-770, 2011.

ATZBERGER, C. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013.

BATTUDE, M.; AL BITAR, A.; MORIN, D.; CROS, J.; HUC, M.; MARAIS SICRE, C.; LE DANTEC, V.; DEMAREZ, V. Estimating maize biomass and yield over large areas using high spatial and temporal resolution Sentinel-2 like remote sensing data. **Remote Sensing of Environment**, v. 184, p. 668-681, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.07.030>>. Acesso em: 7 jan. 2017.

BECK, P. S. A.; ATZBERGER, C.; HØGDA, K. A.; JOHANSEN, B.; SKIDMORE, A. K. Improved monitoring of vegetation dynamics at very high latitudes: A new method using MODIS NDVI. **Remote Sensing of Environment**, v. 100, n. 3, p. 321-334, 2006.

BECKER, W. R.; JOHANN, J. A.; RICHETTI, J.; SILVA, L. C. de A. Técnicas de mineração de dados para separação de mapeamentos de culturas de verão obtidas com imagens de satélite. **Engenharia Agrícola**, v. 37, n. 4, 2017.

BELWARD, A. S.; SKØIEN, J. O. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 115-128, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2014.03.009>>. Acesso em: 10 out. 2017.

BERNARDI, A. C. de C.; RABELLO, L. M.; INAMASU, R. Y.; GREGO, C. R.; ANDRADE, R. G. Variabilidade espacial de parâmetros físico-químicas do solo e biofísicos de superfície em cultivo do sorgo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 6, p. 623-630, 2014.

BHANDARI, S.; PHINN, S.; GILL, T. Preparing Landsat Image Time Series (LITS) for monitoring changes in vegetation phenology in Queensland, Australia. **Remote Sensing**, v. 4, n. 6, p. 1856-1886, 2012.

BISQUERT, M.; BORDOGNA, G.; BÉGUÉ, A.; CANDIANI, G.; TEISSEIRE, M.; PONCELET, P. A simple fusion method for image time series based on the estimation of image temporal validity. **Remote Sensing**, v. 7, n. 1, p. 704-724, 2015.

CONAB. **Levantamento de Safras – Séries Históricas (1976-2018)**. Disponível em: <http://www.conab.gov.br/conteudos.php?a=1252&&Pagina_objcmsconteudos=2#A_objcmsconteudos>. Acesso em: 19 jan. 2018.

CRUZ, J. C.; FILHO, I. a. P.; ALVARENGA, R. C.; NETO, M. M. G.; VIANA, J. H. M.; de OLIVEIRA, M. F.; SANTANA, D. P. **Circular Técnica 87 - Manejo da cultura do Milho**. Embrapa Milho e Sorgo, 2006.

DELGADO, R. C.; SEDIYAMA, G. C.; COSTA, M. H.; SOARES, V. P.; ANDRADE, R. G. Classificação espectral de área plantada com a cultura da cana-de-açúcar por meio da árvore de decisão. **Engenharia Agrícola**, v. 32, n. 2, p. 369-380, 2012.

DERAL. **Análise da conjuntura agropecuária Safra 2011/12**. Secretaria da Agricultura e do Abastecimento, Departamento de Economia Rural. 2011.

DOEBLEY, J.; WANG, R.-L.; STEC, A.; HEY, J.; LUKENS, L. The limits of selection during maize domestication. **Nature**, v. 398, n. 6724, p. 236-239, 1999. Disponível em: <<http://www.nature.com/doi/10.1038/18435>>. Acesso em: 10 nov. 2017.

DUTTA, D.; KUNDU, A.; PATEL, N. R.; SAHA, S. K.; SIDDIQUI, A. R. Assessment of agricultural drought in Rajasthan (India) using remote sensing derived Vegetation Condition Index (VCI) and Standardized Precipitation Index (SPI). **Egyptian Journal of Remote Sensing and Space Science**, v. 18, n. 1, p. 53-63, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.ejrs.2015.03.006>>. Acesso em: 10 dez. 2017.

EKLUNDH, L.; JÖNSSON, P. **TIMESAT 3.2 with parallel processing Software Manual**. 2015.

ELARAB, M.; TICLAVILCA, A. M.; TORRES-RUA, A. F.; MASLOVA, I.; MCKEE, M. Estimating chlorophyll with thermal and broadband multispectral high resolution imagery from an unmanned aerial system using relevance vector machines for precision agriculture. **International Journal of Applied Earth Observation and Geoinformation**, v. 43, p. 32-42, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2015.03.017>>. Acesso em: 10 jan. 2017.

EMBRAPA SOJA. **Tecnologia de produção de soja - região central do Brasil – 2014**. Londrina, PR, Brasil. Embrapa Soja, 2013.

EMBRAPA SOJA. **Evolução e perspectiva de desempenho econômico associados com a produção de soja nos contextos mundial e brasileiro** [recurso eletrônico]: / Marcelo Hiroshi Hirakuri, Joelsio José Lazzarotto. 3. ed. – Londrina: Embrapa Soja, 2011. – (Documentos/ Embrapa Soja, ISSN 2176-2937; n. 319)

EMELYANOVA, I. V.; MCVICAR, T. R.; VAN NIEL, T. G.; LI, L. T.; VAN DIJK, A. I. J. M. Assessing the accuracy of blending Landsat-MODIS surface reflectances in two landscapes with contrasting spatial and temporal dynamics: A framework for algorithm selection. **Remote Sensing of Environment**, v. 133, p. 193-209, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.02.007>>. Acesso em: 10 jan. 2017.

ESQUERDO, J. C. D. M.; ZULLO JÚNIOR, J.; ANTUNES, J. F. G. Use of NDVI/AVHRR time-series profiles for soybean crop monitoring in Brazil. **International Journal of Remote Sensing**, v. 32, n. 13, p. 3711-3727, 2011. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431161003764112>>. Acesso em: 8 fev. 2017.

ESEL, S.; KUEMMERLE, T.; ALCÁNTARA, C.; LEVERS, C.; PRISHCHEPOV, A.; HOSTERT, P. Mapping farmland abandonment and recultivation across Europe using MODIS NDVI time series. **Remote Sensing of Environment**, v. 163, p. 312-325, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.03.028>>. Acesso em: 25 jan. 2017.

FAN, H.; FU, X.; ZHANG, Z.; WU, Q. Phenology-based vegetation index differencing for mapping of rubber plantations using landsat OLI data. **Remote Sensing**, v. 7, n. 5, p. 6041-6058, 2015.

FAOSTAT. **Production quantities by country - Average 1993-2016**. Disponível em: <<http://faostat3.fao.org>>. Acesso em: 19 jan. 2018.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. **Ecofisiologia da soja - Circular Técnica 48**. Embrapa Soja. 2007.

FASSNACHT, K. S.; GOWER, S. T.; MACKENZIE, M. D.; NORDHEIM, E. V.; LILLESAND, T. M. Estimating the leaf area index of North Central Wisconsin forests using the landsat thematic mapper. **Remote Sensing of Environment**, v. 61, n. 2, p. 229-245, 1997. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425797000059>>. Acesso em: 10 jan. 2017.

FAYYAD, U.; PIATETSKY-SHAPITO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **American Association for Artificial Intelligence Menlo Park**, v. 17, n. 3, p. 37-54, 1996.

FEHR, W. R.; CAVINESS, C. E. Stages of Soybean Development. **Special report**, v. 80, n. March, p. 11, 1977. Disponível em: <http://www.agencia.cnptia.embrapa.br/Repositorio/STAGES.+FEHR_000g50w2l4s02wx5ok0dkla0sik2sqav.pdf%5Cnhttps://books.google.de/books?id=DrJQHQAACAAJ>. Acesso em: 11 set. 2017.

FRITZ, S.; SEE, L.; MCCALLUM, I.; YOU, L.; BUN, A.; MOLTCHANOVA, E.; DUERAUER, M.; ALBRECHT, F.; SCHILL, C.; PERGER, C.; HAVLIK, P.; MOSNIER, A.; THORNTON, P.; WOOD-SICHTA, U.; HERRERO, M.; BECKER-RESHEF, I.; JUSTICE, C.; HANSEN, M.; GONG, P.; ABDEL AZIZ, S.; CIPRIANI, A.; CUMANI, R.; CECCHI, G.; CONCHEDDA, G.; FERREIRA, S.; GOMEZ, A.; HAFFANI, M.; KAYITAKIRE, F.; MALANDING, J.; MUELLER, R.; NEWBY, T.; NONGUIERMA, A.; OLUSEGUN, A.; ORTNER, S.; RAJAK, D. R.; ROCHA, J.; SCHEPASCHENKO, D.; SCHEPASCHENKO, M.; TEREKHOV, A.; TIANGWA, A.; VANCUTSEM, C.; VINTROU, E.; WENBIN, W.; VAN DER VELDE, M.; DUNWOODY, A.; KRAXNER, F.; OBERSTEINER, M. Mapping global cropland and field size. **Global Change Biology**, v. 21, n. 5, p. 1980-1992, 2015.

GALFORD, G. L.; MUSTARD, J. F.; MELILLO, J.; GENDRIN, A.; CERRI, C. C.; CERRI, C. E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, v. 112, n. 2, p. 576-587, 2008.

GAMON, J. A.; FIELD, C. B.; GOULDEN, M. L.; GRIFFIN, K. L.; HARTLEY, E.; JOEL, G.; PEÑUELAS, J.; VALENTINI, R. Relationships between NDVI, canopy structure, and photosynthesis in three Californian vegetation types. **Ecological Applications**, v. 5, n. 1, p. 28-41, 1995. Disponível em: <<http://www.jstor.org/stable/1942049>>. Acesso em: 10 jan. 2017.

GAO, F.; ANDERSON, M. C.; ZHANG, X.; YANG, Z.; ALFIERI, J. G.; KUSTAS, W. P.;

MUELLER, R.; JOHNSON, D. M.; PRUEGER, J. H. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. **Remote Sensing of Environment**, v. 188, p. 9-25, 2017.

GAO, F.; HILKER, T.; ZHU, X.; ANDERSON, M.; MASEK, J.; WANG, P.; YANG, Y. Fusing Landsat and MODIS Data for Vegetation Monitoring. **IEEE Geoscience and Remote Sensing Magazine**, v. 3, n. 3, p. 47-60, 2015.

GAO, F.; MASEK, J.; SCHWALLER, M.; HALL, F. On the blending of the landsat and MODIS surface reflectance: Predicting daily landsat surface reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 8, p. 2207-2218, 2006.

GÄRTNER, P.; FÖRSTER, M.; KLEINSCHMIT, B. The benefit of synthetically generated RapidEye and Landsat 8 data fusion time series for riparian forest disturbance monitoring. **Remote Sensing of Environment**, v. 177, p. 237-247, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.01.028>>. Acesso em: 10 jan. 2017.

GEVAERT, C. M.; GARCÍA-HARO, F. J. A comparison of STARFM and an unmixing-based algorithm for Landsat and MODIS data fusion. **Remote Sensing of Environment**, v. 156, n. May, p. 34-44, 2015.

GHASSEMIAN, H. A Review of Remote Sensing Image Fusion Methods. **Information Fusion**, v. 32, 2016. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1566253516300173>>. Acesso em: 10 jan. 2017.

GRZEGOZEWSKI, D. M.; JOHANN, J. A.; URIBE-OPAZO, M. A.; MERCANTE, E.; COUTINHO, A. C. Mapping soya bean and corn crops in the State of Paraná, Brazil, using EVI images from the MODIS sensor. **International Journal of Remote Sensing**, v. 37, n. 6, p. 1257-1275, 2016.

GUSSO, A.; ARVOR, D.; DUCATI, J. R. Model for soybean production forecast based on prevailing physical conditions. **Pesquisa Agropecuária Brasileira**, v. 52, n. 2, p. 95-103, 2017. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2017000200095&lng=en&nrm=iso&tlng=en>. Acesso em: 10 mar. 2017.

GUSSO, A.; ARVOR, D.; RICARDO DUCATI, J.; VERONEZ, M. R.; DA SILVEIRA, L. G. Assessing the modis crop detection algorithm for soybean crop area mapping and expansion in the Mato Grosso state, Brazil. **The Scientific World Journal**, v. 2014, n. 1, 2014.

GUSSO, A.; FORMAGGIO, A. R.; RIZZI, R.; ADAMI, M.; RUDORFF, B. F. T. Soybean crop area estimation by Modis/Evi data. **Pesquisa Agropecuaria Brasileira**, v. 47, n. 3, p. 425-435, 2012.

HANSEN, P. M.; SCHJOERRING, J. K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. **Remote Sensing of Environment**, v. 86, n. 4, p. 542-553, 2003. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425703001317>>. Acesso em: 10 jan. 2017.

HAO, P.; ZHAN, Y.; WANG, L.; NIU, Z.; SHAKIR, M. Feature selection of time series MODIS data for early crop classification using random forest: A case study in Kansas,

USA. **Remote Sensing**, v. 7, n. 5, p. 5347-5369, 2015.

HILKER, T.; WULDER, M. A.; COOPS, N. C.; LINKE, J.; MCDERMID, G.; MASEK, J. G.; GAO, F.; WHITE, J. C. A new data fusion model for high spatial- and temporal-resolution mapping of forest disturbance based on Landsat and MODIS. **Remote Sensing of Environment**, v. 113, n. 8, p. 1613-1627, 2009a. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2009.03.007>>. Acesso em: 10 jan. 2017.

HILKER, T.; WULDER, M. A.; COOPS, N. C.; SEITZ, N.; WHITE, J. C.; GAO, F.; MASEK, J. G.; STENHOUSE, G. Generation of dense time series synthetic Landsat data through data blending with MODIS using a spatial and temporal adaptive reflectance fusion model. **Remote Sensing of Environment**, v. 113, n. 9, p. 1988-1999, 2009b. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425709001709>>. Acesso em: 15 abr. 2017.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.; GAO, X.; FERREIRA, L.. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195-213, 2002. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425702000962>>. Acesso em: 10 jan. 2017.

JARIHANI, A. A.; MCVICAR, T. R.; VAN NIEL, T. G.; EMELYANOVA, I. V.; CALLOW, J. N.; JOHANSEN, K. Blending landsat and MODIS data to generate multispectral indices: A comparison of “index-then-blend” and “Blend-Then-Index” approaches. **Remote Sensing**, v. 6, n. 10, p. 9213-9238, 2014.

JENSEN, J. R.; BOTCHWEY, K.; BRANNAN-GALVIN, E.; JOHANNSEN, C. J.; JUMA, C.; MABOGUNJE, A. L.; MILLER, R. B.; PRICE, K. P.; REINING, P. A. C.; SKOLE, D. L.; STANCIOFF, A.; TAYLOR, D. R. F. **Down to earth: geographical information for sustainable development in africa**. 1. ed. Washington, USA: National Academy of Sciences, 2002.

JIA, K.; LIANG, S.; WEI, X.; YAO, Y.; SU, Y.; JIANG, B.; WANG, X. Land cover classification of landsat data with phenological features extracted from time series MODIS NDVI data. **Remote Sensing**, v. 6, n. 11, p. 11518-11532, 2014a.

JIA, K.; LIANG, S.; ZHANG, L.; WEI, X.; YAO, Y.; XIE, X. Forest cover classification using Landsat ETM+ data and time series MODIS NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, n. 1, p. 32-38, 2014b. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.04.015>>. Acesso em: 10 out. 2017.

JIA, K.; LIANG, S.; ZHANG, N.; WEI, X.; GU, X.; ZHAO, X.; YAO, Y.; XIE, X. Land cover classification of finer resolution remote sensing data integrating temporal features from time series coarser resolution data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 93, p. 49-55, 2014c. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2014.04.004>>. Acesso em: 10 jan. 2017.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná - Brasil. **Engenharia Agrícola**, v. 36, n. 1, p. 126-142, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162016000100126&lng=pt&nrm=iso&tlng=en>. Acesso em: 10 jan. 2017.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C. Estimativa de áreas

com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa Agropecuaria Brasileira**, v. 47, n. 9, p. 1295-1306, 2012.

JÖNSSON, P.; EKLUNDH, L. Seasonality extraction by function fitting to time-series of satellite sensor data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 40, n. 8, p. 1824-1832, 2002.

JÖNSSON, P.; EKLUNDH, L. TIMESAT - A program for analyzing time-series of satellite sensor data. **Computers and Geosciences**, v. 30, n. 8, p. 833-845, 2004.

JUSTICE, C. O.; TOWNSHEND, J. R. G.; VERMOTE, E. F.; MASUOKA, E.; WOLFE, R. E.; SALEOUS, N.; ROY, D. P.; MORISETTE, J. T. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 3-15, 2002.

KING, L.; ADUSEI, B.; STEHMAN, S. V.; POTAPOV, P. V.; SONG, X.-P.; KRYLOV, A.; DI BELLA, C.; LOVELAND, T. R.; JOHNSON, D. M.; HANSEN, M. C. A multi-resolution approach to national-scale cultivated area estimation of soybean. **Remote Sensing of Environment**, v. 195, p. 13-29, 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425717301505>>. Acesso em: 10 jan. 2018.

KNIPLING, E. B. Physical and physiological basis for the reflectance of visible and near infrared radiation from vegetation. **Remote Sensing of Environment**, v. 1, p. 155-159, 1970.

KOENIG, K.; HÖFLE, B.; HÄMMERLE, M.; JARMER, T.; SIEGMANN, B.; LILIENTHAL, H. Comparative classification analysis of post-harvest growth detection from terrestrial LiDAR point clouds in precision agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 104, p. 112-125, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2015.03.003>>. Acesso em: 10 jan. 2017.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, jan. 2016. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1674987115000821>>. Acesso em: 10 jan. 2017.

LIAO, S.-H.; CHU, P.-H.; HSIAO, P.-Y. Data mining techniques and applications – A decade review from 2000 to 2011. **Expert Systems with Applications**, v. 39, n. 12, p. 11303-11311, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2012.02.063>>. Acesso em: 10 jan. 2017.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. [s.l.] Wiley, 2015.

LIU, F.; WANG, Z. Synthetic Landsat data through data assimilation for winter wheat yield estimation. **2010 18th International Conference on Geoinformatics**, p. 1-6, 2010. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5567524>>. Acesso em: 10 jan. 2017.

LOBELL, D. B.; ASNER, G. P. Cropland distributions from temporal unmixing of MODIS data. **Remote Sensing of Environment**, v. 93, n. 3, p. 412-422, 2004.

LOBELL, D. B.; THAU, D.; SEIFERT, C.; ENGLE, E.; LITTLE, B. A scalable satellite-

based crop yield mapper. **Remote Sensing of Environment**, v. 164, p. 324-333, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.04.021>>. Acesso em: 10 jan. 2017.

LULLA, K.; NELLIS, M. D.; RUNDQUIST, B. Celebrating 40 years of Landsat program's Earth observation accomplishments. **Geocarto International**, v. 27, n. 6, p. 459-459, 2012. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/10106049.2012.727604>>. Acesso em: 10 jan. 2017.

MAGALHÃES, P. C.; DURÃES, F. O. M. Circular Técnica 76 - Fisiologia da Produção de Milho. **Circulares Técnicas Embrapa**, p. 10, 2006.

MENESES, P. R.; ALMEIDA, T. de; SANTA ROSA, A. N. de C.; SANO, E. E.; SOUZA, E. B. de; BAPTISTA, G. m de M.; BRITES, R. S. **Introdução ao processamento de imagens de sensoriamento remoto**. 1. Ed. 2012.

MENGUE, V. P.; FONTANA, D. C. Identification of suitable areas for irrigated rice cropping using modis images and hand model. **Engenharia Agrícola**, v. 36, n. 2, p. 329-341, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162016000200329&lng=en&nrm=iso&tlng=en>. Acesso em: 10 jan. 2017.

MERCANTE, E. **Dinâmica espectral da cultura da soja ao longo do ciclo vegetativo e sua relação com a produtividade na região oeste do paraná**. 2007. Universidade Estadual de Campinas, 2007.

MERCANTE, E.; LIMA, L. E. P. de; JUSTINA, D. D. D.; URIBE-OPAZO, M. A.; LAMPARELLI, R. A. C. Detection of soybean planted areas through orbital images based on culture spectral dynamics. **Engenharia Agrícola**, v. 32, n. 5, p. 920-931, 2012.

MISHRA, V.; CRUISE, J. F.; MECIKALSKI, J. R.; HAIN, C. R.; ANDERSON, M. C. A remote-sensing driven tool for estimating crop stress and yields. **Remote Sensing**, v. 5, n. 7, p. 3331-3356, 2013.

MUCHERINO, A.; PAPAJORGJI, P.; PARDALOS, P. M. A survey of data mining techniques applied to agriculture. **Operational Research**, v. 9, n. 2, p. 121-140, 2009. Disponível em: <<http://link.springer.com/10.1007/s12351-009-0054-6>>. Acesso em: 10 jan. 2017.

NAGLER, P. L.; GLENN, E. P.; NGUYEN, U.; SCOTT, R. L.; DOODY, T. Estimating riparian and agricultural actual evapotranspiration by reference evapotranspiration and MODIS enhanced vegetation index. **Remote Sensing**, v. 5, n. 8, p. 3849-3871, 2013.

NASA, N. A. and S. A. **MODIS - Moderate Resolution Imaging Espectroradiometer**. 2009.

PELLETIER, C.; VALERO, S.; INGLADA, J.; CHAMPION, N.; DEDIEU, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. **Remote Sensing of Environment**, v. 187, p. 156-168, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.10.010>>. Acesso em: 10 out. 2017.

PEÑA, J.; GUTIÉRREZ, P.; HERVÁS-MARTÍNEZ, C.; SIX, J.; PLANT, R.; LÓPEZ-GRANADOS, F. Object-Based image classification of summer crops with Machine Learning methods. **Remote Sensing**, v. 6, n. 6, p. 5019-5041, 2014. Disponível em:

<<http://www.mdpi.com/2072-4292/6/6/5019/>>. Acesso em: 10 jan. 2017.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012.

POTGIETER, A. B.; LAWSON, K.; HUETE, A. R. Determining crop acreage estimates for specific winter crops using shape attributes from sequential MODIS imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, n. 1, p. 254-263, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2012.09.009>>. Acesso em: 10 jan. 2017.

POVH, F. P.; MOLIN, J. P.; GIMENEZ, L. M.; PAULETTI, V.; MOLIN, R.; SALVI, J. V. Comportamento do NDVI obtido por sensor ótico ativo em cereais. **Pesquisa Agropecuária Brasileira**, v. 43, n. 8, p. 1075-1083, 2008. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2008000800018&lng=pt&nrm=iso&tlng=pt>. Acesso em: 10 jan. 2017.

PRUDENTE, V. H. R.; SILVA, B. B. da; JOHANN, J. A.; MERCANTE, E.; OLDONI, L. V. Comparative Assessment Between Per-Pixel and Object-Oriented for Mapping Land Cover and Use. **Engenharia Agrícola**, v. 37, n. 5, p. 1015-1027, 2017. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162017000501015&lng=en&tlng=en>. Acesso em: 10 jan. 2018.

RIZZI, R.; RUDORFF, B. F. T. Soybean crop area estimation in Rio Grande do Sul through Landsat images. **Revista Brasileira de Cartografia**, v. 3, p. 226-234, 2005.

RODRIGUES, C. P.; FONTANA, D. C.; MORAES, O. L. L. de; ROBERTI, D. R. NDVI e fluxo de CO₂ em lavoura de soja no Rio Grande do Sul. **Revista Brasileira de Meteorologia**, v. 28, n. 1, p. 95-104, 2013.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. **NASA/GSFC, Final Report, Greenbelt, MD, USA**, n. September 1972, p. 1-137, 1974. Disponível em: <http://scholar.google.com/scholar?q=related:kfZY0xukQScJ:scholar.google.com/&hl=en&num=20&as_sdt=0,5%5Cnpapers2://publication/uuid/FB22B85B-B2F9-442E-AF63-58F3517012FC>. Acesso em: 10 jan. 2017.

ROY, D. P.; WULDER, M. A.; LOVELAND, T. R.; C.E., W.; ALLEN, R. G.; ANDERSON, M. C.; HELDER, D.; IRONS, J. R.; JOHNSON, D. M.; KENNEDY, R.; SCAMBOS, T. A.; SCHAAF, C. B.; SCHOTT, J. R.; SHENG, Y.; VERMOTE, E. F.; BELWARD, A. S.; BINDSCHADLER, R.; COHEN, W. B.; GAO, F.; HIPPLE, J. D.; HOSTERT, P.; HUNTINGTON, J.; JUSTICE, C. O.; KILIC, A.; KOVALSKYY, V.; LEE, Z. P.; LYMBURNER, L.; MASEK, J. G.; MCCORKEL, J.; SHUAI, Y.; TREZZA, R.; VOGELMANN, J.; WYNNE, R. H.; ZHU, Z. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, p. 154-172, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.02.001>>. Acesso em: 10 jan. 2017.

SAKAMOTO, T.; GITELSON, A. A.; ARKEBAUER, T. J. Near real-time prediction of U.S. corn yields based on time-series MODIS data. **Remote Sensing of Environment**, v. 147, p. 219-231, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.03.008>>. Acesso em: 10 jan. 2017.

SANO, E. E.; FERREIRA, L. G.; ASNER, G. P.; STEINKE, E. T. Spatial and temporal

probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v. 28, n. 12, p. 2739-2752, 2007.

SANTOS, J. S.; FONTANA, D. C.; SILVA, T. S. F.; RUDORFF, B. F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 54-63, 2014.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SENF, C.; LEITÃO, P. J.; PFLUGMACHER, D.; VAN DER LINDEN, S.; HOSTERT, P. Mapping land cover in complex Mediterranean landscapes using Landsat: Improved classification accuracies from integrating multi-seasonal and synthetic imagery. **Remote Sensing of Environment**, v. 156, p. 527-536, 2015.

SHAHRIAR PERVEZ, M.; BUDDE, M.; ROWLAND, J. Mapping irrigated areas in Afghanistan over the past decade using MODIS NDVI. **Remote Sensing of Environment**, v. 149, p. 155-165, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.04.008>>. Acesso em: 10 jan. 2017.

SHARMA, R.; GHOSH, a.; JOSHI, P. K. Decision tree approach for classification of remotely sensed satellite data using open source support. **Journal of Earth System Science**, v. 122, n. 5, p. 1237-1247, 2013.

SILVA, D. F. Da. **Uso de modelo agrometeorológicos de estimativa de produtividade e de risco climático para a soja no vale do médio paranapanema – sp.** 2011. 2011.

SILVA JUNIOR, C. a.; FRANK, T.; RODRIGUES, T. C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 44-53, 2014. Disponível em: <<http://www.agriambi.com.br/revista/v18n01/v18n01a07.pdf>>. Acesso em: 10 jan. 2017.

SONG, H.; HUANG, B. Spatiotemporal satellite image fusion through one-pair image learning. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 4, p. 1883-1896, 2013.

SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809-1824, 2015. Disponível em: <<http://www.tandfonline.com/doi/full/10.1080/01431161.2015.1026956>>. Acesso em: 10 jan. 2017.

STAGAKIS, S.; GONZÁLEZ-DUGO, V.; CID, P.; GUILLÉN-CLIMENT, M. L.; ZARCO-TEJADA, P. J. Monitoring water stress and fruit quality in an orange orchard under regulated deficit irrigation using narrow-band structural and physiological remote sensing indices. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 71, p. 47-61, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2012.05.003>>. Acesso em: 10 jan. 2017.

SUGAWARA, L. M.; RUDORFF, B. F. T.; ADAMI, M. Viabilidade de uso de imagens do Landsat em mapeamento de área cultivada com soja no Estado do Paraná. **Pesquisa**

Agropecuaria Brasileira, v. 43, n. 12, p. 1763-1768, 2008.

SUN, L.; GAO, F.; ANDERSON, M.; KUSTAS, W.; ALSINA, M.; SANCHEZ, L.; SAMS, B.; MCKEE, L.; DULANEY, W.; WHITE, W.; ALFIERI, J.; PRUEGER, J.; MELTON, F.; POST, K. Daily Mapping of 30 m LAI and NDVI for Grape Yield Prediction in California Vineyards. **Remote Sensing**, v. 9, n. 4, p. 317, 2017. Disponível em: <<http://www.mdpi.com/2072-4292/9/4/317>>. Acesso em: 8 jan. 2018.

SWAIN, P. H. **Remote sensing: the quantitative approach**. New York: Mcgraw-Hill, 1978.

TEIXEIRA, F. F.; COSTA, F. M. **Caracterização de Recursos Genéticos de Milho. Embrapa Milho e Sorgo**. 2010.

TEWES, A.; THONFELD, F.; SCHMIDT, M.; OOMEN, R. J.; ZHU, X.; DUBOVYK, O.; MENZ, G.; SCHELLBERG, J. Using RapidEye and MODIS data fusion to monitor vegetation dynamics in semi-arid rangelands in South Africa. **Remote Sensing**, v. 7, n. 6, p. 6510-6534, 2015.

TORBICK, N.; CHOWDHURY, D.; SALAS, W.; QI, J. Monitoring rice agriculture across Myanmar using time series Sentinel-1 assisted by Landsat-8 and PALSAR-2. **Remote Sensing**, v. 9, n. 2, p. 119, 2017. Disponível em: <<http://www.mdpi.com/2072-4292/9/2/119>>. Acesso em: 10 dez. 2017.

TOTH, C.; JÓZKÓW, G. Remote sensing platforms and sensors: A survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 22-36, 2016. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271611000426>>. Acesso em: 10 jan. 2017.

TOWNSHEND, J. R. G.; JUSTICE, C. O. Towards operational monitoring of terrestrial systems by moderate-resolution remote sensing. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 351-359, 2002.

TREZZA, R.; ALLEN, R. G.; TASUMI, M. Estimation of actual evapotranspiration along the Middle Rio Grande of New Mexico using MODIS and landsat imagery with the METRIC model. **Remote Sensing**, v. 5, n. 10, p. 5397-5423, 2013.

U.S. GEOLOGICAL SURVEY. **Landsat 8 (L8) Data Users Handbook**. Sioux Falls, 2016.

VALERO, S.; MORIN, D.; INGLADA, J.; SEPULCRE, G.; ARIAS, M.; HAGOLLE, O.; DEDIEU, G.; BONTEMPS, S.; DEFOURNY, P.; KOETZ, B. Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions. **Remote Sensing**, v. 8, n. 1, p. 1-21, 2016.

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM, G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 1, p. 106-115, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2009.08.014>>. Acesso em: 10 jan. 2017.

VICTORIA, D. de C.; PAZ, A. R. da; COUTINHO, A. C.; KASTENS, J.; BROWN, J. C. Cropland area estimates using Modis NDVI time series in the state of Mato Grosso, Brazil. **Pesq. agropec. bras.**, v. 47, n. 9, p. 1270-1278, 2012.

VIÑA, A.; GITELSON, A. A.; NGUY-ROBERTSON, A. L.; PENG, Y. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops.

Remote Sensing of Environment, v. 115, n. 12, p. 3468-3478, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.08.010>>. Acesso em: 10 jan. 2017.

VINTROU, E.; IENCO, D.; BEGUE, A.; TEISSEIRE, M. Data mining, a promising tool for large-area cropland mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 5, p. 2132-2138, 2013.

WALKER, J. J.; BEURS, K. M. de; WYNNE, R. H.; GAO, F. Evaluation of Landsat and MODIS data fusion products for analysis of dryland forest phenology. **Remote Sensing of Environment**, v. 117, p. 381-393, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.10.014>>. Acesso em: 10 jan. 2017.

WANG, L.; TIAN, Y.; YAO, X.; ZHU, Y.; CAO, W. Predicting grain yield and protein content in wheat by fusing multi-sensor and multi-temporal remote-sensing images. **Field Crops Research**, v. 164, n. 1, p. 178-188, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.fcr.2014.05.001>>. Acesso em: 10 jan. 2017.

WATTS, J. D.; POWELL, S. L.; LAWRENCE, R. L.; HILKER, T. Improved classification of conservation tillage adoption using high temporal and synthetic satellite imagery. **Remote Sensing of Environment**, v. 115, n. 1, p. 66-75, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2010.08.005>>. Acesso em: 10 jan. 2017.

WENG, Q. **Remote sensing and gis integration theories, methods, and applications**. 2010.

WU, M.; NIU, Z.; WANG, C.; WU, C.; WANG, L. Use of MODIS and Landsat time series data to generate high-resolution temporal synthetic Landsat data using a spatial and temporal reflectance fusion model. **Journal of Applied Remote Sensing**, v. 6, n. 1, p. 63507, 2012. Disponível em: <<http://remotesensing.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JRS.6.063507>>. Acesso em: 10 jan. 2017.

WU, M.; WU, C.; HUANG, W.; NIU, Z.; WANG, C. High-resolution Leaf Area Index estimation from synthetic Landsat data generated by a spatial and temporal data fusion model. **Computers and Electronics in Agriculture**, v. 115, p. 1-11, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2015.05.003>>. Acesso em: 10 jan. 2017.

WULDER, M. A.; WHITE, J. C.; LOVELAND, T. R.; WOODCOCK, C. E.; BELWARD, A. S.; COHEN, W. B.; FOSNIGHT, E. A.; SHAW, J.; MASEK, J. G.; ROY, D. P. The global Landsat archive: Status, consolidation, and direction. **Remote Sensing of Environment**, v. 185, p. 271-283, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.11.032>>. Acesso em: 10 jan. 2017.

XIN, Q.; GONG, P.; YU, C.; YU, L.; BROICH, M.; SUYKER, A. E.; MYNENI, R. B. A production efficiency model-based method for satellite estimates of corn and soybean yields in the midwestern US. **Remote Sensing**, v. 5, n. 11, p. 5926-5943, 2013.

XU, M.; JIA, X.; PICKERING, M. AUTOMATIC CLOUD REMOVAL FOR LANDSAT 8 OLI IMAGES USING CIRRUS BAND. **IEEE International Geoscience and Remote Sensing Symposium**, p. 2511-2514, 2014.

XU, M.; JIA, X.; PICKERING, M. Cloud effects removal via sparse representation. In: 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2, **Anais...IEEE**, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7325836/>>. Acesso em: 8 mar. 2017.

YAN, L.; ROY, D. P. Automated crop field extraction from multi-temporal Web Enabled Landsat Data. **Remote Sensing of Environment**, v. 144, p. 42-64, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.01.006>>. Acesso em: 10 jan. 2017.

YANG, Y.; ANDERSON, M. C.; GAO, F.; HAIN, C. R.; SEMMENS, K. A.; KUSTAS, W. P.; NOORMETS, A.; WYNNE, R. H.; THOMAS, V. A.; SUN, G. Daily Landsat-scale evapotranspiration estimation over a forested landscape in North Carolina, USA using multi-satellite data fusion. **Hydrology and Earth System Sciences Discussions**, n. June, p. 1-45, 2016. Disponível em: <<http://www.hydrol-earth-syst-sci-discuss.net/hess-2016-198/>>. Acesso em: 10 jan. 2017.

YANG, Z.; WU, W.; DI, L.; ÜSTÜNDAĞ, B. Remote sensing for agricultural applications. **Journal of Integrative Agriculture**, v. 16, n. 2, p. 239-241, 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S2095311916615496>>. Acesso em: 10 dez. 2017.

YU, N.; LI, L.; SCHMITZ, N.; TIAN, L. F.; GREENBERG, J. A.; DIERS, B. W. Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. **Remote Sensing of Environment**, v. 187, p. 91-101, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.10.005>>. Acesso em: 10 jan. 2017.

ZARCO-TEJADA, P. J.; GONZÁLEZ-DUGO, M. V.; FERERES, E. Seasonal stability of chlorophyll fluorescence quantified from airborne hyperspectral imagery as an indicator of net photosynthesis in the context of precision agriculture. **Remote Sensing of Environment**, v. 179, p. 89-103, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.03.024>>. Acesso em: 10 jan. 2017.

ZHANG, B.; ZHANG, L.; XIE, D.; YIN, X.; LIU, C.; LIU, G. Application of synthetic NDVI time series blended from landsat and MODIS data for grassland biomass estimation. **Remote Sensing**, v. 8, n. 1, p. 1-21, 2016.

ZHANG, W.; LI, A.; JIN, H.; BIAN, J.; ZHANG, Z.; LEI, G.; QIN, Z.; HUANG, C. An enhanced spatial and temporal data fusion model for fusing landsat and modis surface reflectance to generate high temporal landsat-like data. **Remote Sensing**, v. 5, n. 10, p. 5346-5368, 2013.

ZHANG, X. Reconstruction of a complete global time series of daily vegetation index trajectory from long-term AVHRR data. **Remote Sensing of Environment**, v. 156, p. 457-472, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.10.012>>. Acesso em: 10 jan. 2017.

ZHANG, X.; FRIEDL, M. A.; SCHAAF, C. B.; STRAHLER, A. H.; HODGES, J. C. F.; GAO, F.; REED, B. C.; HUETE, A. Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, v. 84, n. 3, p. 471-475, 2003. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425702001359>>. Acesso em: 10 jan. 2017.

ZHONG, C.; WANG, C.; WU, C. MODIS-based fractional crop mapping in the U.S. Midwest with spatially constrained phenological mixture analysis. **Remote Sensing**, v. 7, n. 1, p. 512-529, 2015.

ZHONG, L.; GONG, P.; BIGING, G. S. Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery. **Remote Sensing of Environment**, v. 140, p. 1-13, 2014. Disponível em:

<<http://dx.doi.org/10.1016/j.rse.2013.08.023>>. Acesso em: 10 jan. 2017.

ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. S. Automated mapping of soybean and corn using phenology. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151-164, 2016a.

ZHONG, L.; YU, L.; LI, X.; HU, L.; GONG, P. Rapid corn and soybean mapping in US Corn Belt and neighboring areas. **Scientific Reports**, v. 6, n. May, p. 36240, 2016b. Disponível em: <<http://www.nature.com/articles/srep36240>>. Acesso em: 10 jan. 2017.

ZHU, L.; RADELOFF, V. C.; IVES, A. R. Improving the mapping of crop types in the Midwestern U.S. by fusing Landsat and MODIS satellite data. **International Journal of Applied Earth Observation and Geoinformation**, v. 58, n. February, p. 1-11, 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0303243417300120>>. Acesso em: 10 out. 2017.

ZHU, X.; CHEN, J.; GAO, F.; CHEN, X.; MASEK, J. G. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. **Remote Sensing of Environment**, v. 114, n. 11, p. 2610-2623, 2010.

ZHU, X.; HELMER, E. H.; GAO, F.; LIU, D.; CHEN, J.; LEFSKY, M. A. A flexible spatiotemporal method for fusing satellite images with different resolutions. **Remote Sensing of Environment**, v. 172, p. 165-177, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.11.016>>. Acesso em: 10 jan. 2017.

ZHU, Z.; WOODCOCK, C. E.; HOLDEN, C.; YANG, Z. Generating synthetic Landsat images based on all available Landsat data: Predicting Landsat surface reflectance at any given time. **Remote Sensing of Environment**, v. 162, p. 67-83, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.02.009>>. Acesso em: 10 jan. 2017.

ZHUANG, X.; ZHAO, S.; LI, X.; CONG, D. Landsat and MODIS Data Fusion products based phenology analysis of dryland in Shan Dong province. In: 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), **Anais...IEEE**, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7729669/>>. Acesso em: 10 jan. 2017.

ZHUKOV, B.; OERTEL, D.; LANZL, F.; REINHACKEL, G. Unmixing-based multisensor multiresolution image fusion. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 3, p. 1212-1226, 1999. Disponível em: <<http://ieeexplore.ieee.org/document/763276/>>. Acesso em: 10 jan. 2017.

ZURITA-MILLA, R.; CLEVERS, J. G. P. W.; SCHAEPMAN, M. E. Unmixing-based landsat TM and MERIS FR data fusion. **IEEE Geoscience and Remote Sensing Letters**, v. 5, n. 3, p. 453-457, 2008.

6 RESULTADOS

6.1 ARTIGO 1: Mapeamento de áreas agrícolas utilizando técnicas de mineração de dados em séries temporais de imagens Landsat 8

RESUMO: No estado do Paraná, Brasil não há grandes alterações nas áreas cultivadas com culturas agrícolas anuais, devido principalmente às leis ambientais, que não permitem expansões para novas áreas. Dentre as culturas anuais, há predominância da soja e do milho na primeira safra, do milho na 2ª safra, e do trigo no inverno, com grande importância para suprir a demanda interna e econômica nas exportações. Assim, a área e a distribuição das culturas agrícolas são informações de grande importância. Novas metodologias, como a mineração de dados (Data Mining – DM), estão sendo testadas com o objetivo de analisar e melhorar seu potencial de uso para classificação do uso e cobertura da terra. Neste trabalho foram utilizados os classificadores Árvore de Decisão (AD) e Random Forest (RF) em métricas obtidas de estatísticas temporais de NDVI de imagens Landsat-8. Os resultados foram comparados com metodologias tradicionais (imagens espectrais e classificador Maxver) para classificar o uso e cobertura da terra. Primeiramente foram consideradas sete classes (água, cana-de-açúcar, área urbana, culturas agrícolas anuais, mata, pastagem e reflorestamento), e depois apenas duas (culturas agrícolas anuais e demais alvos). As metodologias comparadas tiveram resultados equivalentes quando utilizadas para classificar as sete classes, com exatidão global de até 84% e com acurácias de produtor (AP) e usuário (AU) para a classe de culturas agrícolas anuais utilizando as métricas temporais de NDVI de 86 e 100%, respectivamente. Quando consideradas apenas duas classes (culturas agrícolas anuais/demais alvos), as classificações utilizando as métricas temporais de NDVI obtiveram exatidão global de até 98%, AP e AU superiores a 94%.

PALAVRAS-CHAVE: Árvore de Decisão, Random Forest, Séries temporais de NDVI.

6.1.1 INTRODUÇÃO

A agricultura é uma atividade de risco e incertezas, que decorrem de instabilidade climática, ameaças sanitárias e oscilações do mercado. Uma adequada gestão de riscos agrícolas pode contribuir positivamente para a estabilidade financeira da atividade. No entanto, o monitoramento agrícola é complexo, exigindo boa capacidade gerencial, elevado conhecimento tecnológico e, sobretudo, um alto nível de informações permanentemente atualizadas (GUIMARÃES; NOGUEIRA, 2009).

Mapeamentos que distinguem áreas agrícolas de outros alvos podem servir de base para o correto monitoramento das condições de cultivo durante o desenvolvimento das culturas (VALERO et al., 2016). O sensoriamento remoto, pelo seu caráter sinóptico e pela agilidade na aquisição de informações, destaca-se como uma técnica que permite o acompanhamento de culturas agrícolas ao longo do seu ciclo de desenvolvimento (DELGADO et al., 2012; MERCANTE et al., 2012; JOHANN et al., 2016). Existem diversos sensores remotos orbitais com diferentes características e tipos de resoluções (espacial, temporal, radiométrica e espectral) (TOTH; JÓŽKÓW, 2016); porém, para a maioria dos atuais sensores

orbitais, diferentes culturas agrícolas podem ter a descrição de suas características espectrais semelhantes (YAO et al., 2015).

Para contornar esse problema, novas metodologias, como a mineração de dados (Data Mining – DM), estão sendo testadas com o objetivo de analisar e melhorar seu potencial de uso para a diferenciação espectral (SILVA JUNIOR et al., 2014; GRANDE; et al., 2016). A DM é uma das fases do processo de descoberta de conhecimento em base de dados (Knowledge Discovery in Databases – KDD) (FAYYAD et al., 1996), que dispõe de ferramentas baseadas em aprendizagem de máquina, para facilitar o processo de extração, reconhecimento de padrões e a descoberta de conhecimento.

Outra abordagem para auxiliar no processo de classificação de imagens multiespectrais é a análise multitemporal de Índices de Vegetação (IV) empregada na detecção de alvos agrícolas, pois seus perfis espectro-temporais são fortemente atrelados a dinâmica da agricultura (KUPLICH et al., 2013; BORGES; SANO, 2014; ZHAO et al., 2015). O Normalized Difference Vegetation Index (NDVI) (ROUSE et al., 1973) vem sendo amplamente utilizado, e tem sido empregado em trabalhos com imagens orbitais para detecção e monitoramento de áreas agrícolas, potencializando a capacidade de separação dos algoritmos de classificação de imagens (PELLETIER et al., 2016).

Os classificadores de imagens orbitais, comumente utilizados, são fundamentados em algoritmos estatísticos que se baseiam na análise pixel a pixel, sendo o Maxver (Máxima Verossimilhança) um dos mais utilizados. O Maxver pode apresentar resultados confiáveis quanto ao mapeamento do uso e cobertura da terra por imagens orbitais (SILVA et al., 2013), porém, expõem algumas dificuldades ao confundir alvos que apresentarem classes espectralmente semelhantes, o que dificulta a interpretação dos resultados mesmo em sensores de alta resolução espacial (AMARAL et al., 2009).

Algoritmos baseados em aprendizado de máquina (AM) são uma alternativa que tem alcançado resultados extremamente eficientes para a classificação de alvos agrícolas (VALERO et al., 2016). Os métodos comumente utilizados são Redes Neurais (RN), Support Vector Machines (SVM), Árvore de Decisão (AD) e Random Forest (RF) ou, algumas vezes, até combinações destes algoritmos (PEÑA et al., 2014; LARY et al., 2016).

Neste contexto, o objetivo deste trabalho foi comparar duas abordagens de classificação de imagens orbitais: uma, utilizando técnicas de mineração de dados para realizar a classificação em séries temporais de NDVI de imagens Landsat 8; e outra, realizando a classificação utilizando apenas a informação espectral em 4 datas de imagens.

6.1.2 MATERIAL E MÉTODOS

O desenvolvimento do trabalho seguiu o processo de KDD (FAYYAD et al., 1996), que é dividido em cinco etapas, sendo elas: 1) Seleção dos dados, 2) Pré-Processamento, 3) Formatação/Transformação, 4) Mineração de dados e 5) Interpretação/Avaliação.

6.1.2.1 Seleção dos dados

As imagens utilizadas são provenientes do sensor Operational Land Imager (OLI) a bordo do satélite Landsat 8, quadrante 223/77, que delimita a área de estudo (Figura 7). Esta é uma região de grande produção agrícola no Oeste Paranaense, principalmente soja e milho (JOHANN et al., 2012; FRANÇA JUNIOR et al., 2015).

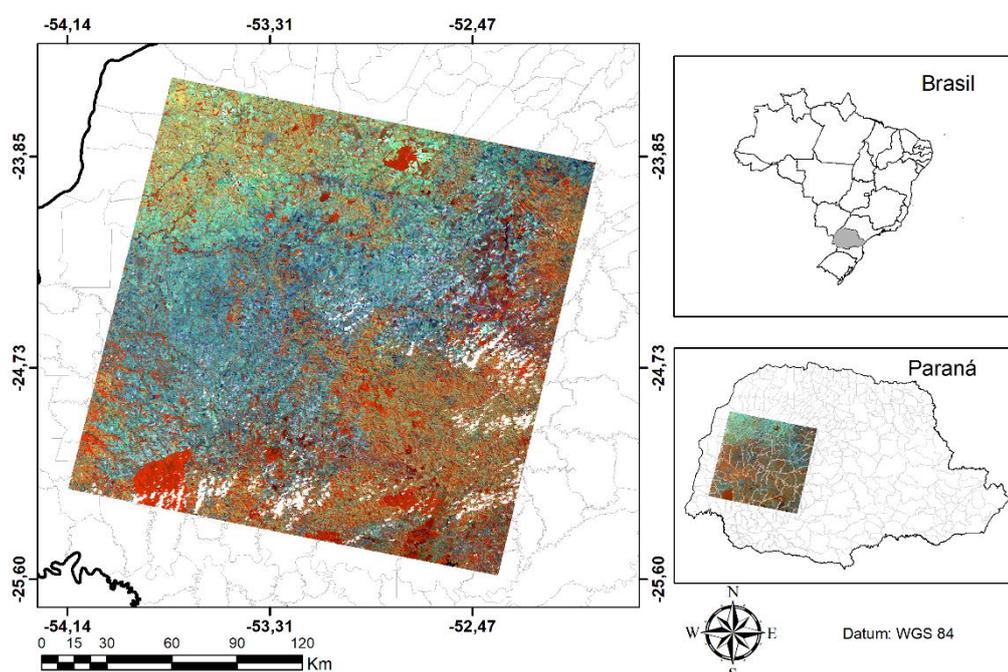


Figura 7 Localização da área de estudo.

O sensor OLI possui 9 bandas espectrais (USGS, 2016), resolução radiométrica de 16 bits, tempo de revisita de 16 dias, sendo disponibilizadas ortorretificadas com resolução espacial de 15 metros para a pancromática e de 30 metros para as demais bandas pelo portal do US Geological Survey (USGS). Foram baixadas as imagens Landsat 8 de refletância da superfície de alto nível (nível 2) disponibilizadas por demanda pelo USGS (disponível em: <<https://earthexplorer.usgs.gov/>>). Essas imagens são processadas pelo Landsat Surface Reflectance Code (LaSRC) (VERMOTE et al., 2016). Foram selecionadas 11 imagens, entre os anos de 2015 e 2017, que tinham como característica menos de 3% de nuvens (Tabela 6). Então foram eliminados os pixels com nuvem e sombra de nuvem nas imagens selecionadas utilizando a banda de qualidade (ZHU; WOODCOCK, 2012; ZHU; WANG; WOODCOCK, 2015), que é distribuída juntamente com o as imagens Landsat 8 de refletância da superfície. Foram utilizadas as bandas que compreendem a faixa do azul (0,45 – 0,51 μm , Banda 2),

verde (0,53 – 0,59 μm , Banda 3), vermelho (0,64 – 0,67 μm , Banda 4), NIR – Near Infrared (0,85 – 0,88 μm , Banda 5) e do infravermelho de ondas curtas, onde está a banda SWIR 1– Shortwave Infrared 1 (1,57 – 1,65 μm , Banda 6) e do SWIR 2 (2,11 – 2,29 μm , Banda 7).

Tabela 6 Datas das imagens do satélite Landsat 8, tile 223/77, utilizadas no estudo

Dia Juliano	Data	Porcentagem de nuvem	Dia Juliano	Data	Porcentagem de nuvem
294	21/10/2015	2,99	281	07/10/2016	1,15
073	13/03/2016	0,11	297	23/10/2016	0,00
089	29/03/2016	0,85	329	24/11/2016	0,51
121	30/04/2016	0,14	027	27/01/2017	1,00
185	03/07/2016	0,00	059	28/02/2017	2,11
265	21/09/2016	0,01			

6.1.2.2 Pré-processamento

Inicialmente reprojeteram-se as imagens para o sistema de referência Universal Transversa de Mercator (UTM), zona 22 sul. Em seguida, foi gerado o índice de vegetação NDVI (ROUSE et al., 1973), que é resultante de uma razão da diferença pela soma da refletância do infravermelho próximo pela refletância do vermelho. Este índice de vegetação é muito difundido no âmbito do monitoramento e mapeamento agrícola (SHAHRIAR PERVEZ et al., 2014; ESTEL et al., 2015), pois explora o contraste da vegetação em relação a outros tipos de alvos.

As culturas agrícolas anuais possuem grande variação espectro-temporal (Figura 8), com valores de NDVI variando de valores próximos a zero (no início do ciclo da cultura) que aumentam até o máximo desenvolvimento vegetativo (estádios de floração, frutificação e formação de grãos) e, em seguida, decrescem até próximo de zero novamente (senescência, restos culturais e solo exposto), seguido de um novo ciclo de cultura anual com as mesmas características (ESQUERDO et al., 2011). Os alvos cidade, reflorestamento e mata possuem pequena variação espectro-temporal, com valores médios de NDVI próximos à 1,0 para reflorestamento e mata, e valores próximos a 0,5 para áreas urbanas (Figura 8). As culturas de cana-de-açúcar e pastagem possuem média variação espectro-temporal, com menor intensidade quando comparadas as culturas agrícolas anuais. Já a água por possuir refletância muito baixa no infravermelho próximo apresenta valores de NDVI próximo ou abaixo de zero (Figura 8).

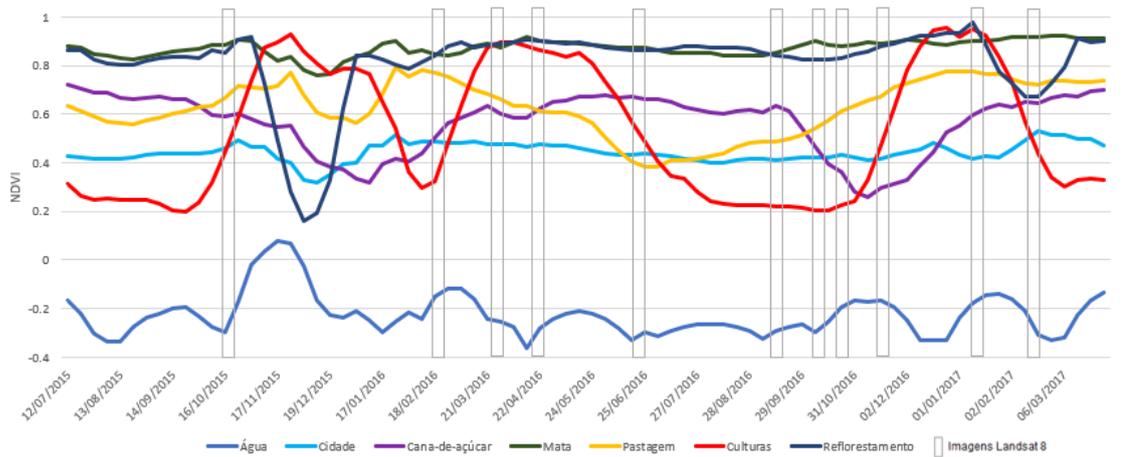


Figura 8 Exemplo de métricas temporais de NDVI característico de diferentes alvos (mata, reforestamento, cultura agrícolas anuais, pastagem, cana-de-açúcar, área urbana e água) do sensor MODIS com filtro Savitzky–Golay.

Fonte: Adaptado de <<https://www.satveg.cnptia.embrapa.br/satveg/login.html>>.

Para quantificar a variação temporal do NDVI das culturas agrícolas anuais, foi calculado o somatório das diferenças ($NDVI_{SD}$) das imagens de NDVI (Equação 1) do Landsat-8, criando uma nova variável que pudesse ser utilizada para diferenciar as culturas agrícolas anuais dos demais alvos.

$$NDVI_{SD} = \sum_{i=1}^n |NDVI_i - NDVI_{i+1}| \quad \text{Eq.(1)}$$

em que:

n é a quantidade de imagens da série temporal;

$NDVI_i$ é a imagem i da série temporal;

$NDVI_{i+1}$ é a imagem $i+1$ da série temporal.

Após isso, foram calculadas métricas estatísticas (média, mínimo, máximo, desvio padrão, coeficiente de variação, amplitude, mediana e soma) da série temporal de NDVI, usadas como dados de entrada para a tarefa de classificação, juntamente com o $NDVI_{SD}$, chamadas a partir daqui de métricas temporais de NDVI.

6.1.2.3 Transformação dos dados

No pré-processamento foi criado um cubo com as métricas temporais mencionados ($\text{cubo}_{\text{MétricasNDVI}}$), e outro cubo com as bandas espectrais 2, 3, 4, 5, 6 e 7 das datas 30/04/2016, 21/09/2016, 24/11/2016 e 11/01/2017, denominado cubo_{RGB} , que foi utilizado nas classificações para comparação com o $\text{cubo}_{\text{MétricasNDVI}}$. Para a coleta de amostras foi gerada a composição colorida falsa cor RGB-564.

6.1.2.4 Mineração dos dados

Para a tarefa classificação supervisionada foram utilizadas as técnicas Árvore de Decisão e Random Forest, nos dois cubos de imagens ($\text{cubo}_{\text{MétricasNDVI}}$ e cubo_{RGB}). Para

comparação foi realizada uma classificação supervisionada com o algoritmo de Máxima verossimilhança (Maxver) no cubo_{RGB} .

Foram utilizados os algoritmos de classificação Árvore de Decisão e Random Forest, da biblioteca Scikit-Learn (PEDREGOSA et al., 2011) de Machine Learn para Python. Esta biblioteca utiliza uma versão otimizada do algoritmo Classification e Regression Tree (CART) (BREIMAN et al., 1984), que suportam atributos meta numérico baseado em um conjunto de atributos de entrada, possibilitando também a regressão. O Random Forest é um método que combina k árvores binárias do CART. É uma combinação de preditores de Árvore de Decisão de modo que cada uma depende dos valores de um vetor aleatório amostrado independentemente e com a mesma distribuição para todas as árvores na floresta (BREIMAN, 2001).

Coletaram-se 1000 amostras para cada uma das sete classes de uso e ocupação da terra para treinamento e validação. Para avaliar o desempenho dos algoritmos de classificação, foi utilizada validação cruzada com 2 partições, sendo 66% para treinamento, 33% para validação e com 3 repetições. As mesmas amostras foram utilizadas por todos os classificadores. Num segundo momento, foram avaliadas apenas duas classes: culturas agrícolas anuais e demais alvos. Sendo agrupados as amostras das classes água, cana-de-açúcar, área urbana, culturas agrícolas anuais, mata, pastagem e reflorestamento na classe de demais alvos.

6.1.2.5 Avaliação

Inicialmente avaliou-se a Exatidão Global (EG), que representa o total de acertos em relação ao total de amostras, e o Índice Kappa (K) (COHEN, 1960), gerados pelos algoritmos de classificação, com objetivo de verificar os melhores parâmetros a serem utilizados.

As avaliações da acurácia espacial dos mapeamentos foram realizadas por meio das matrizes de erros. Utilizou-se da metodologia chamada de painel amostral, que se caracteriza pela distribuição aleatória de pontos amostrais dentro do limite da área, com o objetivo de se realizar um levantamento das classes de uso e cobertura do solo de cada ponto (LUIZ et al., 2002). Utilizaram-se de 350 pontos amostrais espalhados de forma aleatória nos mapeamentos, sendo 50 pontos por classe de uso e cobertura da terra. A avaliação dos pontos foi realizada por meio de inspeção visual nas imagens de alta resolução do Google Earth, com o auxílio do cubo_{RGB} , gerando as matrizes de erros para cada mapeamento. A partir da matriz de erros, calculou-se a Exatidão Global e o Índice Kappa, no intuito de avaliar as acurácias do mapeamento.

Também se determinou as métricas de Acurácia de Produtor (AP), que se refere à probabilidade de um determinado pixel ter sido corretamente classificado e a Acurácia de Usuário (AU), que indica a probabilidade que um pixel classificado na imagem de fato representa aquela categoria no campo (CONGALTON, 1991). Para avaliar diferenças

significativas das medidas de precisão entre diferentes resultados de classificação foi utilizado o teste Z (Equação 2) (FOODY, 2009b). Para este teste assume-se que se o valor de $|Z| > 1,96$ indicará que as duas classificações comparadas são significativamente diferentes no nível de significância de 5% (FOODY, 2009a).

$$Z = \frac{P_1 - P_2}{\sqrt{\bar{p}(1-\bar{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \quad \text{Eq.(2)}$$

em que:

$\bar{p} = \frac{x_1 + x_2}{n_1 + n_2}$, com x_1 e x_2 representando o número de casos alocados corretamente nas classificações de dados com tamanho n_1 e n_2 , respectivamente.

6.1.3 RESULTADOS E DISCUSSÃO

6.1.3.1 Mapeamento das sete classes de uso e cobertura da terra

Os classificadores utilizados tiveram diferentes desempenhos quanto ao mapeamento das sete classes de uso e à cobertura da terra (Figura 9) com as duas bases de dados (cubo_{RGB} e $\text{cubo}_{\text{MétricasNDVI}}$). Os classificadores Árvore de Decisão (AD) e Random Forest (RF), utilizando o cubo_{RGB} , confundiram mais a classe pastagem com a classe culturas agrícolas anuais (Figura 9a e 9b). Por sua vez, os classificadores utilizando o $\text{cubo}_{\text{MétricasNDVI}}$ (Figura 9d e 9e), geraram confusão entre as classes cana-de-açúcar e a classe pastagem. Todos os classificadores conseguiram identificar o Parque Nacional do Iguaçu na região sudeste da cena (Figura 9), o qual representa uma grande área homogênea e preservada de Mata Atlântica (SALAMUNI et al., 2002).

Nas classificações que utilizaram as métricas temporais de NDVI ($\text{cubo}_{\text{MétricasNDVI}}$) ocorreram quantidades maiores de áreas classificadas como a classe cana-de-açúcar, principalmente, na região norte da área de estudo (Figura 9d e 9e). Adami et al. (2012 a e b) mostram a existência de cana-de-açúcar apenas na região norte no ano agrícola 2010/2011. Chechin Jr. et al. (2017) também identificou cana-de-açúcar apenas na região norte, ao mapear a cultura no estado do Paraná entre os anos 2010 a 2014, utilizando o classificador Maxver em imagens Landsat 5 TM, Landsat 8 OLI e IRS LISS-3, com EG superior a 93%.

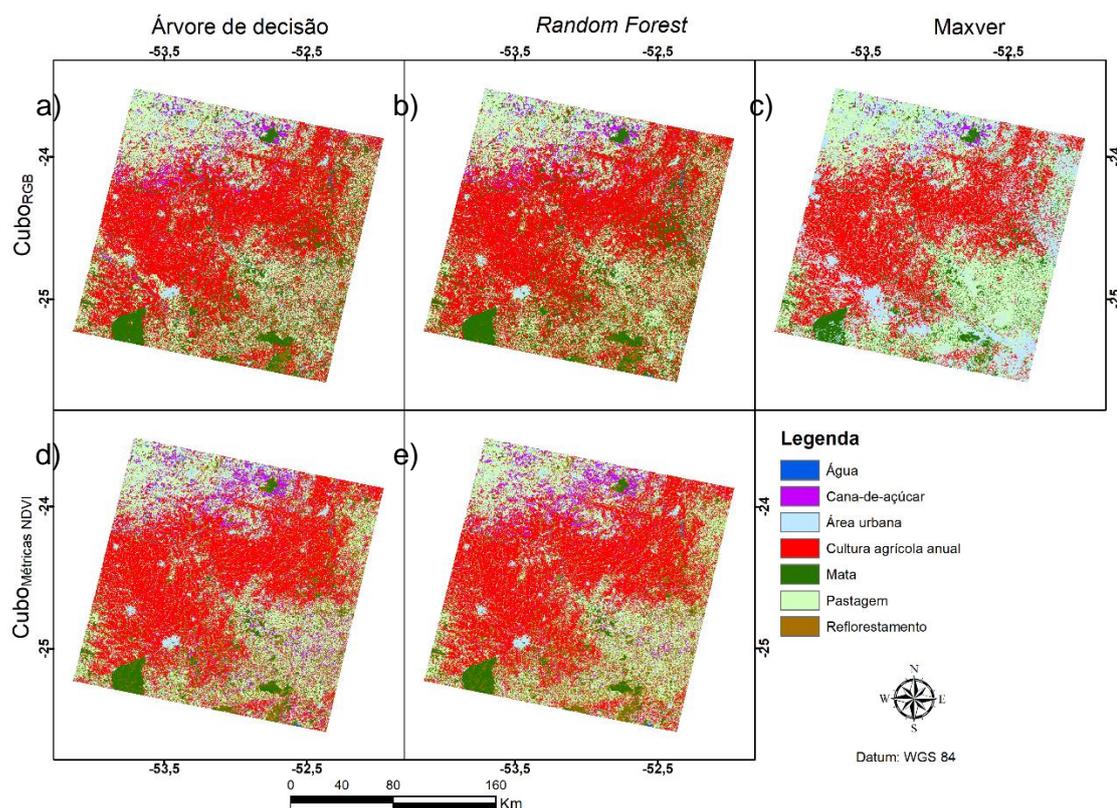


Figura 9 Resultado das classificações em imagens Landsat-8 utilizando as métricas temporais de NDVI ($cubo_{MétricasNDVI}$) e as bandas espectrais ($cubo_{RGB}$) com os classificadores Árvore de Decisão, Random Forest e Maxver para área urbana, mata, cana-de-açúcar, reflorestamento, culturas agrícolas anuais, pastagem e água.

As classificações utilizando o $cubo_{MétricasNDVI}$ também identificaram maiores áreas de culturas agrícolas anuais, concentrando as áreas do Oeste para o norte da área de estudo, corroborando com os resultados de outros trabalhos (ESQUERDO et al., 2011; JOHANN et al., 2012; SOUZA et al., 2015; ZHONG et al., 2016).

O algoritmo Random Forest (RF) apresentou o melhor desempenho na análise da acurácia dos mapeamentos realizados (Tabela 7), tanto com as imagens do $cubo_{RGB}$, como também para as métricas espectro-temporais de NDVI do $cubo_{MétricasNDVI}$. Na avaliação da classificação para a imagem inteira por meio do painel amostral, o mapeamento realizado com o NDVI AD (EG: 84% e K: 0,81) obteve o melhor resultado, seguido pelo algoritmo Maxver (EG: 82% e K: 0,79) e o NDVI RF (EG: 82% e K: 0,79) (Tabela 7).

Tabela 7 Índices de acurácias gerados pelos algoritmos e pela distribuição aleatória de pontos nas classificações utilizando as métricas temporais de NDVI ($cubo_{MétricasNDVI}$) e as bandas espectrais ($cubo_{RGB}$) para os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver

		NDVI AD	NDVI RF	RGB AD	RGB RF	RGB Maxver
Algoritmos	EG (%)	98,34	99,10	98,90	99,93	-
	K	0,9807	0,9930	0,9872	0,9992	-
Painel amostral	EG (%)	84	82	72	76	82
	K	0,81	0,79	0,68	0,72	0,79

Nota: EG - Exatidão global; K - Índice Kappa.

As classificações sobre as imagens do cubo_{RGB} (AD, RF e Maxver) obtiveram baixas acurácias de usuário (Tabela 8), classificando outras classes como cidade, principalmente culturas agrícolas anuais. Isto ocorreu, pois, algumas áreas agrícolas encontravam-se em pousio ou com o solo revolvido, podendo ser espectralmente semelhante a área urbana. O RGB Maxver conseguiu os resultados melhores para a classe cana-de-açúcar, com AP de 100% e AU de 58%.

As classificações utilizando as métricas temporais de NDVI obtivera baixa AP para mata (AD: 72% e RF: 75%) e de usuário para reflorestamento (AD: 66% e RF: 70%), deixando de classificar áreas de mata e classificando-as como reflorestamento. A pastagem também apresentou baixa AP (AD: 73% e RF: 68%). Isto ocorreu principalmente pela confusão entre as classes de pastagem e cana-de-açúcar. Este problema também é relatado por IPPOLITI-RAMILO et al. (2003), XAVIER et al. 2006 e ADAMI et al. (2012a). Segundo XAVIER et al. (2006), isto ocorre pela semelhança do comportamento temporal de índice de vegetação das duas classes.

As culturas agrícolas anuais obtiveram melhores resultados utilizando as métricas temporais de NDVI, tanto para AD (AP: 86%; AU: 100) quanto para RF (AP: 77%; AU: 100). Jia et al. (2014a) também obtiveram melhores resultados para culturas agrícolas utilizando métricas estatísticas temporais de NDVI (valores máximo, mínimo, médio e desvio padrão), quando comparados com métricas fenológicas (datas de início e término da estação de crescimento, a duração da estação de crescimento, a amplitude sazonal e o valor máximo de NDVI ajustado) e com dados espectrais em imagens do sensor OLI. Segundo eles, o melhor resultado das métricas estatísticas temporais de NDVI ocorre porque não são sensíveis ao período de plantio e colheita. Já quando se utiliza informações espectrais as datas têm grande influência nos resultados (SENF et al., 2015), pois algumas áreas podem estar com culturas em desenvolvimento e outras terem sido colhidas. Para as culturas agrícolas anuais, ocorreram menores confusões utilizando as métricas temporais de NDVI, ocasionando as confusões em outras classes (principalmente mata com reflorestamento e cana-de-açúcar com pastagem). Por consequência, neste trabalho, foram também avaliadas as classificações separando apenas as culturas agrícolas anuais dos demais alvos.

Tabela 8 Acurácias de produtor (AP) e usuário (AU) para área urbana, mata, cana-de-açúcar, reflorestamento, culturas agrícolas anuais, pastagem e água, obtidas pelo painel amostral para os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver nas imagens no cubo_{MétricasNDVI} e cubo_{RGB}

	NDVI AD		NDVI RF		RGB AD		RGB RF		RGB Maxver	
	AP (%)	AU (%)	AP (%)	AU (%)	AP (%)	AU (%)	AP (%)	AU (%)	AP (%)	AU (%)
Área urbana	82	80	90	72	100	60	97	58	95	42
Mata	72	96	75	98	75	98	75	82	68	98
Cana-de-açúcar	100	60	89	68	96	52	89	62	93	82
Reflorestamento	94	66	95	70	79	60	95	76	93	84
Culturas agrícolas anuais	86	100	77	100	54	90	49	80	75	94
Pastagem	73	90	68	92	56	80	65	80	71	80
Água	98	96	100	74	97	66	98	92	100	96

As classificações realizadas com o NDVI RF, NDVI AD e RGB Maxver não diferiram estatisticamente pelo Teste Z ($|Z| < 1,96$) (Tabela 9), apresentando acurácias superiores aos demais. O mesmo ocorreu com as classificações obtidas com RGB RF e RGB AD; porém, estes apresentaram as menores acurácias.

Tabela 9 Teste Z para comparação entre duas proporções obtidos pela distribuição aleatória de pontos em classificações para área urbana, mata, cana-de-açúcar, reflorestamento, culturas agrícolas anuais, pastagem e água com os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver nas imagens do cubo_{MétricasNDVI} e cubo_{RGB}

Métodos	RGB Maxver	RGB AD	NDVI AD	RGB RF
RGB AD	3,16*	-	-	-
NDVI AD	0,61 ^{ns}	3,75*	-	-
RGB RF	2,13*	1,03 ^{ns}	2,73*	-
NDVI RF	0,10 ^{ns}	3,06*	0,70 ^{ns}	2,04*

Nota: * significativo a 5% de probabilidade; ns - não significativo.

6.1.3.2 Mapeamento de culturas agrícolas anuais e demais alvos

Todas as classificações que utilizaram apenas as informações espectrais (cubo_{RGB}) apresentaram mais ruídos de classificação e confusões entre culturas agrícolas anuais e demais alvos em comparação com as classificações que utilizaram as métricas temporais de NDVI (cubo_{MétricasNDVI}) (Figura 10). As avaliações das acurácias pelos algoritmos obtiveram bons resultados (EG: 94,4 a 100%; K: 0,98 a 1,0) (Tabela 10). Porém, quando se avalia a acurácia do mapeamento por meio do painel amostral, os valores diminuem. As classificações no cubo_{MétricasNDVI}, tanto a AD (EG: 98%; K: 0,96) quanto o RF (EG: 96%; K: 0,92) obtiveram resultados superiores em comparação com as classificações utilizando o cubo_{RGB} (melhor resultado ocorre com o RGB RF; EG: 88%; K: 0,76). Outros autores obtiveram resultados equivalentes. Müller et al. (2015), utilizando métricas de variação espectro-temporal de NDVI, obtiveram EG de 93% para separação de pastagens em áreas de cerrado. Jia et al. (2014b) também obtiveram resultados similares com EG de 93% e Índice Kappa de 0,87 para

classificação de cobertura florestal por meio de métricas de variação temporal de NDVI. As métricas temporais de NDVI conseguiram melhorar a EG em aproximadamente 11% e o K em 16%. Assim, valores estatísticos extraídos do perfil de NDVI, mostraram sua capacidade de melhoria da caracterização do uso e cobertura do solo (JIA et al., 2014a; PELLETIER et al., 2016; VALERO et al., 2016).

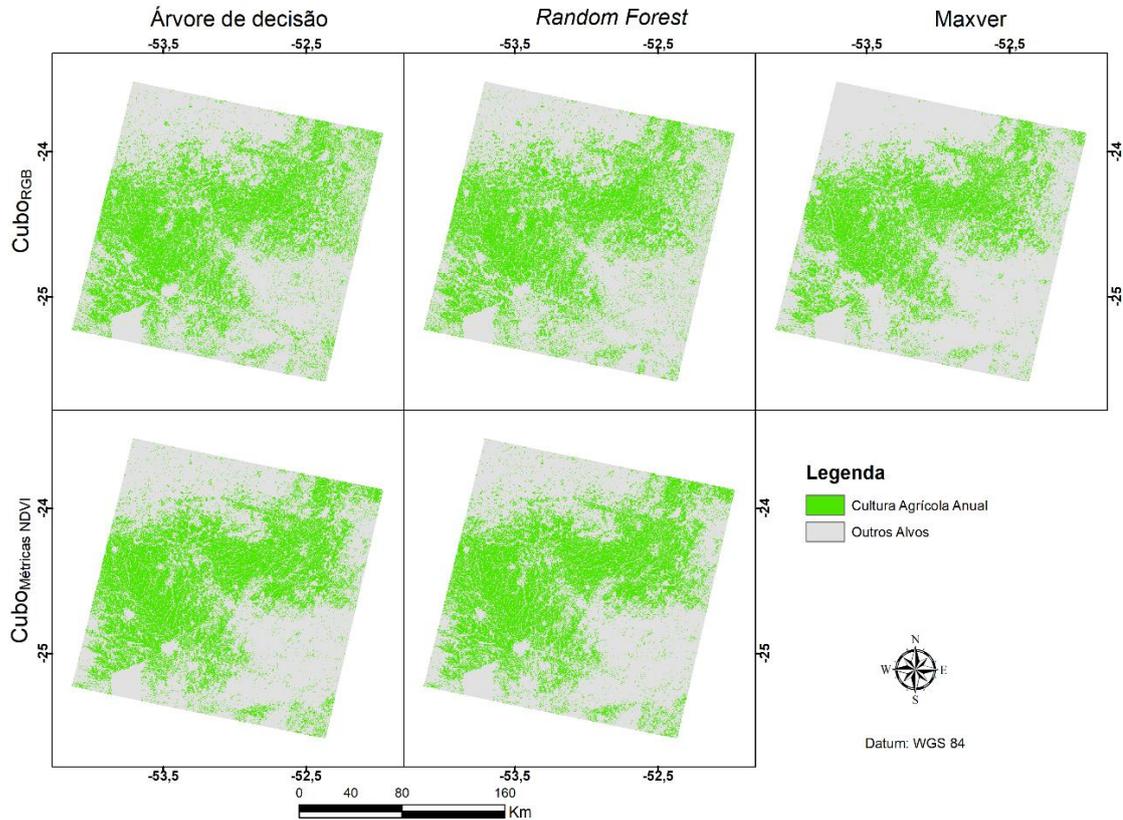


Figura 10 Resultado das classificações em imagens Landsat 8 utilizando as métricas temporais de NDVI ($\text{cubo}_{\text{MétricasNDVI}}$) e o RGB-564 (cubo_{RGB}) com os classificadores Árvore de Decisão, Random Forest e Maxver para as classes culturas agrícolas anuais e demais alvos.

Unir as classes área urbana, mata, cana-de-açúcar, reflorestamento, pastagem e água em uma única classe contribuiu para a melhoria do resultado geral da classificação (EG: de 84 para 98%; K: de 0,80 para 0,96). A melhoria nos resultados ocorre por haver muita confusão entre estas classes ao tentar diferenciá-las, reduzindo o número de classes em classificações pode se obter melhores acurácias (SENF et al., 2015).

A classificação no $\text{cubo}_{\text{MétricasNDVI}}$ e o classificador AD obteve alta AP e AU (acima de 96 %) para ambas as classes (Tabela 10), tendo obtido AP de 100% para demais alvos (ou seja, todos os pontos de demais alvos foram classificados corretamente) e AU de 100% para a classe de culturas (todos os pontos classificados como cultura são realmente da classe culturas). Assim, o erro de omissão foi de apenas 3,8% para culturas e erros de inclusão de 4% para demais alvos.

Tabela 10 Índices de acurácias gerados pelos algoritmos e pela distribuição aleatória de pontos nas classificações utilizando as métricas temporais de NDVI ($\text{cubo}_{\text{MétricasNDVI}}$) e a imagem RGB-564 (cubo_{RGB}) para os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver para culturas agrícolas anuais e demais alvos

Métodos	Algoritmos		Painel Amostral		Acurácia do Produtor AP (%)		Acurácia do usuário - AU (%)	
	Exatidão global (%)	Kappa	Exatidão global (%)	Kappa	Culturas	Demais alvos	Culturas	Demais alvos
NDVI AD	99,4	0,99	98,0	0,96	96,2	100	100	96
NDVI RF	100	1,0	96,0	0,92	94,2	97,9	98	94
RGB AD	99,6	0,98	85,0	0,7	85,7	84,3	84	86
RGB RF	99,9	0,99	88,0	0,76	86,5	89,6	90	86
RGB Maxver	-	-	87,0	0,74	82,5	93	94	80

As classificações utilizando o cubo_{RGB} não foram diferentes significativamente entre si pelo Teste Z ($|Z| < 1,96$) (Tabela 11). O mesmo ocorre entre as classificações utilizando o $\text{cubo}_{\text{MétricasNDVI}}$. Portanto, para diferenciar culturas agrícolas anuais de outros alvos, a utilização das métricas temporais de NDVI tem mais influência no resultado do que o algoritmo de classificação utilizado.

Tabela 11 Teste Z para comparação entre duas proporções obtidos pela distribuição aleatória de pontos em classificações para culturas agrícolas anuais e outras culturas com os classificadores Árvore de Decisão (AD), Random Forest (RF) e Maxver nas imagens do $\text{cubo}_{\text{MétricasNDVI}}$ e cubo_{RGB}

Métodos	RGB Maxver	RGB AD	NDVI AD	RGB RF
RGB AD	0,41 ^{ns}	-		
NDVI AD	2,95*	3,30*	-	
RGB RF	0,21 ^{ns}	0,62 ^{ns}	2,77*	-
NDVI RF	2,28*	2,65*	0,83 ^{ns}	2,09*

Nota: * significativo a 5% de probabilidade; ns - não significativo.

6.1.4 CONCLUSÕES

Considerando sete classes de uso e ocupação da terra, o melhor resultado foi obtido utilizando as métricas temporais de NDVI ($\text{cubo}_{\text{MétricasNDVI}}$) e o classificador Árvore de Decisão. Pelo teste Z, esta classificação não diferenciou das métricas de NDVI com o classificador Random Forest e do Maxver com as métricas espectrais (cubo_{RGB}). As métricas temporais de NDVI obtiveram boas acurácias de produtor e usuário com a classe de culturas agrícolas anuais, enquanto que para esta classe com o cubo_{RGB} houve maiores confusões para todos os algoritmos de classificação utilizados.

Considerando somente duas classes (culturas agrícolas anuais/demais alvos), as classificações utilizando as métricas temporais de NDVI obtiveram altas acurácias, com Exatidão global de até 98% e Índice Kappa de até 0,96, sendo superior às classificações que utilizaram as métricas espectrais.

Assim, o resultado da classificação depende mais das métricas utilizadas do que dos algoritmos de classificação. A utilização de informações da série temporal de NDVI, que evidenciam as variações fenológicas das culturas agrícolas, em conjunto com técnicas de mineração de dados, demonstraram-se eficazes na diferenciação de culturas agrícolas anuais dos demais alvos, gerando um mapeamento preciso.

6.1.5 REFERÊNCIAS

ADAMI, M.; MELLO, M. P.; AGUIAR, D. A.; RUDORFF, B. F. T.; SOUZA, A. F. de. A web platform development to perform thematic accuracy assessment of sugarcane mapping in South-Central Brazil. **Remote Sensing**, v. 4, n. 10, p. 3201-3214, 2012a.

ADAMI, M.; RUDORFF, B. F. T.; FREITAS, R. M.; AGUIAR, D. A.; SUGAWARA, L. M.; MELLO, M. P. Remote sensing time series to evaluate direct land use change of recent expanded sugarcane crop in Brazil. **Sustainability**, v. 4, n. 4, p. 574-585, 2012b.

AMARAL, M. V. F.; SOUZA, A. L. De; SOARES, V. P.; SOARES, C. P. B.; LEITE, H. G.; MARTINS, S. V.; FERNANDES FILHO, E. I.; LANA, J. M. De. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v. 33, n. 3, p. 575-582, 2009.

BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p. 526-547, 2014.

BREIMAN, L., FRIEDMAN, J.H., OLSHEN, R.A., STONE, C. J. **Classification and regression trees**. 1. ed. Belmont: Wadsworth, 1984.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

COHEN, J. A Coefficient of Agreement for Nominal Scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37-46, 1960.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, 1991.

DELGADO, R. C.; SEDIYAMA, G. C.; COSTA, M. H.; SOARES, V. P.; ANDRADE, R. G. Classificação espectral de área plantada com a cultura da cana-de-açúcar por meio da árvore de decisão. **Engenharia Agrícola**, v. 32, n. 2, p. 369-380, 2012.

ESQUERDO, J. C. D. M.; ZULLO JÚNIOR, J.; ANTUNES, J. F. G. Use of NDVI/AVHRR time-series profiles for soybean crop monitoring in Brazil. **International Journal of Remote Sensing**, v. 32, n. 13, p. 3711-3727, 2011. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431161003764112>>. Acesso em: 10 jan. 2017.

ESTEL, S.; KUEMMERLE, T.; ALCÁNTARA, C.; LEVERS, C.; PRISHCHEPOV, A.; HOSTERT, P. Mapping farmland abandonment and recultivation across Europe using MODIS NDVI time series. **Remote Sensing of Environment**, v. 163, p. 312-325, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.03.028>>. Acesso em: 10 jan. 2017.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, n. 3, p. 37, 1996.

FOODY, G. M. Classification accuracy comparison: Hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority. **Remote Sensing of Environment**, v. 113, n. 8, p. 1658-1663, 2009a. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2009.03.014>>. Acesso em: 10 jan. 2017.

FOODY, G. M. Sample size determination for image classification accuracy assessment and comparison. **International Journal of Remote Sensing**, v. 30, n. 20, p. 5273-5291, 2009b. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160903130937>>. Acesso em: 10 jan. 2017.

FRANÇA JUNIOR, P.; VILLA, M. E. C. D.; VILLA, J. F. D. Características Geomorfológicas E a Produção De Culturas Temporárias No Estado Do Paraná-Brasil. **Revista Formação**, v. 1, n. 22, p. 71-86, 2015.

GRANDE, T. O. de; ALMEIDA, T. de; CICERELLI, R. E. Classificação orientada a objeto em associação às ferramentas reflectância acumulada e mineração de dados. **Pesquisa Agropecuária Brasileira**, v. 51, n. 12, p. 1983-1991, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2016001201983&lng=pt&nrm=iso&tlng=en>. Acesso em: 11 nov. 2017.

GUIMARÃES, M. F.; NOGUEIRA, J. M. A experiência norte-americana com o seguro agrícola: lições ao Brasil? **Revista de Economia e Sociologia Rural**, v. 47, n. 1, p. 27-58, 2009. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-20032009000100002&lng=pt&nrm=iso&tlng=pt>. Acesso em: 10 jan. 2017.

IPPOLITI-RAMILO, G. A.; EPIPHANIO, J. C. N.; SHIMABUKURO, Y. E. Landsat-5 Thematic Mapper data for pre-planting crop area evaluation in tropical countries. **International Journal of Remote Sensing**, v. 24, n. 7, p. 1521-1534, 2003.

JIA, K.; LIANG, S.; WEI, X.; YAO, Y.; SU, Y.; JIANG, B.; WANG, X. Land cover classification of landsat data with phenological features extracted from time series MODIS NDVI data. **Remote Sensing**, v. 6, n. 11, p. 11518-11532, 2014a.

JIA, K.; LIANG, S.; ZHANG, L.; WEI, X.; YAO, Y.; XIE, X. Forest cover classification using Landsat ETM+ data and time series MODIS NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, n. 1, p. 32-38, 2014b. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.04.015>>. Acesso em: 10 jan. 2017.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná - Brasil. **Engenharia Agrícola**, v. 36, n. 1, p. 126-142, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162016000100126&lng=pt&nrm=iso&tlng=en>. Acesso em: 10 jan. 2017.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1295-1306, 2012.

JUNIOR, C. C.; JOHANN, J. A.; ANTUNES, J. F. G. Mapping of sugarcane crop area in the Paraná State using Landsat / TM / OLI and IRS / LISS-3 images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 6, p. 427-432, 2017.

KUPLICH, T. M.; MOREIRA, A.; FONTANA, D. C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 55, p. 1116-1123, 2013.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Geoscience Frontiers Machine

- learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3-10, 2016.
- LUIZ, A. J. B.; OLIVEIRA, J. C.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Auxílio das imagens de satélite aos levantamentos por amostragem em agricultura. **Agricultura em São Paulo**, v. 49, n. 1, p. 41-54, 2002.
- MERCANTE, E.; LIMA, L. E. P. de; JUSTINA, D. D.; URIBE-OPAZO, M. A.; LAMPARELLI, R. A. C. Detection of soybean planted areas through orbital images based on culture spectral dynamics. **Engenharia Agrícola**, v. 32, n. 5, p. 920-931, 2012.
- MÜLLER, H.; RUFIN, P.; GRIFFITHS, P.; BARROS SIQUEIRA, A. J.; HOSTERT, P. Mining dense Landsat time series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape. **Remote Sensing of Environment**, v. 156, p. 490-499, 2015.
- PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, É. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825-2830, 2011. Disponível em: <<http://dl.acm.org/citation.cfm?id=2078195>><<http://arxiv.org/abs/1201.0490>>. Acesso em: 10 jan. 2017.
- PELLETIER, C.; VALERO, S.; INGLADA, J.; CHAMPION, N.; DEDIEU, G. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. **Remote Sensing of Environment**, v. 187, p. 156-168, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.10.010>>. Acesso em: 10 jan. 2017.
- PEÑA, J.; GUTIÉRREZ, P.; HERVÁS-MARTÍNEZ, C.; SIX, J.; PLANT, R.; LÓPEZ-GRANADOS, F. Object-Based image classification of summer crops with Machine Learning methods. **Remote Sensing**, v. 6, n. 6, p. 5019-5041, 2014. Disponível em: <<http://www.mdpi.com/2072-4292/6/6/5019/>>. Acesso em: 10 jan. 2017.
- SENF, C.; LEITÃO, P. J.; PFLUGMACHER, D.; VAN DER LINDEN, S.; HOSTERT, P. Mapping land cover in complex Mediterranean landscapes using Landsat: Improved classification accuracies from integrating multi-seasonal and synthetic imagery. **Remote Sensing of Environment**, v. 156, p. 527-536, 2015.
- SHAHRIAR PERVEZ, M.; BUDDE, M.; ROWLAND, J. Mapping irrigated areas in Afghanistan over the past decade using MODIS NDVI. **Remote Sensing of Environment**, v. 149, p. 155-165, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.04.008>>. Acesso em: 10 jan. 2017.
- SILVA, C. R. da; SOUZA, K. B. de; FURTADO, W. F. Evaluation of the Progress of Intensive Agriculture in the Cerrado Piauiense – Brazil. **IERI Procedia**, v. 5, p. 51-58, 2013. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2212667813000725>>. Acesso em: 10 jan. 2017.
- SILVA JUNIOR, C. a.; FRANK, T.; RODRIGUES, T. C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 44-53, 2014. Disponível em: <<http://www.agriambi.com.br/revista/v18n01/v18n01a07.pdf>>. Acesso em: 10 jan. 2017.
- SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809-1824, 2015. Disponível em: <<http://www.tandfonline.com/doi/full/10.1080/01431161.2015.1026956>>. Acesso em: 10 jan.

2017.

TOTH, C.; JÓZKÓW, G. Remote sensing platforms and sensors: A survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 22-36, 2016. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271611000426>>. Acesso em: 10 jan. 2017.

VALERO, S.; MORIN, D.; INGLADA, J.; SEPULCRE, G.; ARIAS, M.; HAGOLLE, O.; DEDIEU, G.; BONTEMPS, S.; DEFOURNY, P.; KOETZ, B. Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions. **Remote Sensing**, v. 8, n. 1, p. 1-21, 2016.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46-56, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.04.008>>. Acesso em: 10 jan. 2017.

XAVIER, A. C.; RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; BERKA, L. M. S.; MOREIRA, M. A. Multi-temporal analysis of MODIS data to classify sugarcane crop. **International Journal of Remote Sensing**, v. 27, n. 4, p. 755-768, 2006. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160500296735>>. Acesso em: 10 jan. 2017.

YAO, F.; TANG, Y.; WANG, P.; ZHANG, J. Estimation of maize yield by using a process-based model and remote sensing data in the Northeast China Plain. **Physics and Chemistry of the Earth**, v. 87-88, p. 142-152, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.pce.2015.08.010>>. Acesso em: 10 jan. 2017.

ZHAO, J.; LI, J.; LIU, Q.; FAN, W.; ZHONG, B.; WU, S.; YANG, L.; ZENG, Y.; XU, B.; YIN, G. Leaf area index retrieval combining HJ1/CCD and Landsat8/OLI data in the Heihe River Basin, China. **Remote Sensing**, v. 7, n. 6, p. 6862-6885, 2015.

ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. S. Automated mapping of soybean and corn using phenology. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151-164, 2016.

ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v. 159, n. January, p. 269-277, 2015.

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, p. 83-94, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.10.028>>. Acesso em: 10 jan. 2017.

6.2 ARTIGO 2: Mapeamento de soja e milho utilizando imagens sintéticas Landsat 8 e MODIS

RESUMO: O monitoramento da atividade agrícola é essencial para todos os envolvidos com o setor e também uma questão de segurança alimentar. O sensoriamento remoto orbital é uma alternativa eficaz para realizar o monitoramento das culturas agrícolas, devido ao baixo custo, grande escala de abrangência e rapidez na coleta de dados. Porém, geralmente os sensores com alta resolução espacial possuem baixa resolução temporal, e os com alta resolução temporal possuem baixa resolução espacial. Assim, em áreas com grande cobertura de nuvens pode haver limitações no mapeamento de culturas agrícolas. Este problema pode ser contornado com a utilização de fusão de imagens de diversos sensores com características temporais e espaciais diferentes, criando, assim, novas imagens, também chamadas de imagens sintéticas. Assim, o objetivo do trabalho é realizar o mapeamento de áreas semeadas com soja e milho em municípios da região Oeste do Paraná por meio da utilização de imagens sintéticas criadas a partir da fusão das imagens dos satélites Landsat 8 e do sensor MODIS. Foram utilizados os algoritmos Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM), Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) e Flexible Spatiotemporal Data Fusion (FSDAF) para gerar imagens no ano-safra verão 2016/2017. Desta forma, foram criados 5 cenários de classificação: utilizando apenas as imagens Landsat 8 livre de nuvens existentes, classificadas juntas (1) e também separadas (2), a utilização das imagens existentes mais as imagens sintéticas (3), a utilização de métricas fenológicas (4) e estatísticas (5) extraídas do perfil temporal do Enhanced Vegetation Index (EVI) das imagens geradas pelos algoritmos de fusão espaço-temporal. O cenário que utilizou as métricas fenológicas do EVI a partir de imagens geradas pelo FSDAF e STARFM obtiveram melhores resultados em relação aos outros cenários, com exatidão global de 93,11 e 91,33%, respectivamente. Assim, a utilização de métricas fenológicas obtidas de imagens sintéticas são uma importante alternativa para mapeamento de soja e milho.

Palavras-chave: Fusão de imagens espaço-temporal de imagens, métricas fenológicas, métricas estatísticas, métricas espectrais.

6.2.1 INTRODUÇÃO

O monitoramento agrícola é essencial para a avaliação do aumento de produtividade e da produção, do suprimento de alimentos, das implicações ambientais que possam ser causados pela atividade, das informações geradas para os formuladores de políticas e das partes interessadas pelo setor agrícola (ATZBERGER, 2013; GRAESSER; RAMANKUTTY, 2017; ZHU; RADELOFF; IVES, 2017), além de serem vitais para a segurança alimentar e para a indústria (VINTROU et al., 2013; HAO et al., 2015; SONG et al., 2017).

No Brasil, as estimativas oficiais de área e produção agropecuária são realizadas pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e pela Companhia Nacional de Abastecimento (CONAB). Estes órgãos oficiais ainda utilizam pesquisas com produtores rurais e em cooperativas, dados de históricos e de financiamento agrícola. Estas informações são importantes, mas a forma de obtenção das informações torna as estimativas de safras sujeitas a subjetividade e imprecisões (GUSSO et al., 2012; JOHANN et al., 2012).

As estimativas de safras no Brasil vêm sofrendo grandes mudanças no intuito de se tornar menos subjetiva. Devido a isso, estão sendo utilizadas ferramentas estatísticas de

amostragem e de acompanhamento de culturas. O sensoriamento remoto é uma destas ferramentas que vem sendo utilizada para o monitoramento de culturas (MERCANTE et al., 2012), gerando informações decisivas nas aplicações agrícolas, pois pode fornecer informações que cobrem grandes áreas e de difícil acesso (ATZBERGER, 2013; BISQUERT et al., 2015; SONG et al., 2017), podendo representar a informação de forma espacial (SANTOS et al., 2014), em tempo real (GAO et al., 2017) e servir para complementar os dados da metodologia adotada em programas oficiais (JOHANN et al., 2012).

O mapeamento de culturas agrícolas é a mais desafiadora classe de uso e cobertura da terra, devido à diversidade de fenologia das culturas e à necessidade de uma alta quantidade de imagens de entrada, variedade de tamanho, forma e práticas de manejo dos talhões (KING et al., 2017). Este tipo de monitoramento para ser realizado em escala regional, necessita de dados de sensoriamento remoto com ampla cobertura geográfica, alta resolução temporal, adequada resolução espacial (condizente com o tamanho dos talhões agrícolas da região monitorada) e mínimo de custo (ATZBERGER, 2013).

Diversos trabalhos utilizaram as imagens do sensor Moderate Resolution Imaging Spectroradiometer (MODIS) para realizar o mapeamento de culturas agrícolas (GUSSO et al., 2012, 2014; JOHANN et al., 2012; FRITZ et al., 2015; SOUZA et al., 2015; GRZEGOZEWSKI et al., 2016; ZHONG et al., 2016a, 2016b; BECKER et al., 2017a), principalmente por sua resolução temporal, com um tempo de revista global quase diária e a sua resolução espacial (250 m) (GUSSO et al., 2012; ATZBERGER, 2013). Alguns autores que utilizaram o sensor MODIS para mapeamento de culturas agrícolas relatam que em áreas mais heterogêneas, com talhões de áreas menores ou próximos a área de um pixel do MODIS (6,25 ha) utilizado, a sua baixa resolução espacial podem ser um fator limitante (YAN; ROY, 2014; FRITZ et al., 2015; ZHONG et al., 2016a).

Uma opção para mapeamento com melhor resolução espacial, de 30 metros por exemplo, são as imagens dos sensores abordo dos satélites Landsat (ZHONG; GONG; BIGING, 2014; ZHONG et al., 2016a). Porém, especialmente em regiões tropicais a baixa resolução temporal (16 dias), a frequente cobertura de nuvens pode comprometer ou inviabilizar a análise dos dados e, somado a isso, algumas imagens Landsat não estão disponíveis em certas datas, dificultando o uso contínuo destas imagens (XU; JIA; PICKERING, 2014, 2015). No Brasil, algumas regiões, tais como o estado do Paraná são altamente afetados por este problema, principalmente durante o período de desenvolvimento das culturas de verão (culturas da soja e milho) (EBERHARDT et al., 2016).

Uma solução para este problema é a combinação de imagens de sensores com alta ou média resolução espacial (como o Landsat) com outros de menor resolução espacial, mas com a alta resolução temporal (como o sensor MODIS) (GAO et al., 2006). Desta forma, a técnica de fusão de dados de diferentes sensores remotos é uma alternativa viável e de

relativo baixo custo para aprimorar a capacidade destas imagens no acompanhamento da dinâmica da superfície da Terra (ZHU et al., 2010).

Intrinsicamente, os métodos de fusão espaço-temporal usam a informação espacial da imagem de entrada de fine-resolution – FR (maior resolução espacial e menor resolução temporal) e a informação temporal da imagem de coarse resolution – CR (menor resolução espacial e maior resolução temporal) (ZHU et al., 2016). Como a refletância da superfície da imagem de FR é desconhecida na data predita, os métodos de fusão espaço-temporal trabalham com uma abordagem não supervisionada (GAO et al., 2006). O resultado é uma imagem sintética com FR na data predita (ZHU et al., 2016).

Vários algoritmos de fusão espaço-temporal foram desenvolvidos na última década, mostrando boa capacidade para melhorar as resoluções espaciais e temporais das imagens para monitorar diversos tipos de uso e cobertura da terra e diversas aplicações (ZHU et al., 2016). Dentre os vários métodos, destaca-se o Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM - GAO et al., 2006), que foi um dos primeiros métodos de fusão espaço-temporal e vem sendo amplamente utilizado e validado (SENF et al., 2015; LU et al., 2016; ZHANG et al., 2016; ZHU et al., 2016; ZHUANG et al., 2016; GAO et al., 2017; WANG et al., 2017; WU et al., 2017), mostrando bom desempenho para áreas homogêneas em que há grande variação temporal, porém não mostra um resultado tão bom para áreas heterogêneas. O Enhanced STARFM ou Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model (ESTARFM) (ZHU et al., 2010) foi desenvolvido com base no STARFM, buscando melhorar a predição em áreas heterogêneas ao utilizar dois pares de imagens. Recentemente foi desenvolvido o Flexible Spatiotemporal Data Fusion (FSDAF) com o objetivo de prever imagens com resolução espacial fina com maior precisão em áreas heterogêneas, capturando mudanças da cobertura da terra gradual e abrupta com o mínimo de dados de entrada, necessitando de apenas uma imagem de resolução espacial fina (ZHU et al., 2016).

Mesmo para sensores com média resolução espacial, diferentes classes de uso e ocupação da terra podem ter características espectrais semelhantes (YAO et al., 2015). Para contornar esse problema, novas metodologias estão sendo testadas com o objetivo de analisar seu potencial de diferenciação espectral (SILVA JUNIOR; FRANK; RODRIGUES, 2014; GRANDE; ALMEIDA; CICERELLI, 2016). Algoritmos baseados em aprendizado de máquina (AM) são uma alternativa, que têm mostrado resultados extremamente eficientes para classificação de alvos agrícolas (VALERO et al., 2016).

Outra abordagem para auxiliar no processo de classificação de imagens multiespectrais é a análise multitemporal de índices de vegetação (IV), amplamente empregado na detecção de alvos agrícolas, pois seus perfis espectro-temporais são fortemente atrelados à dinâmica da agricultura (KUPLICH et al., 2013; BORGES; SANO, 2014; ZHAO et al., 2015). O Enhanced Vegetation Index (EVI) utiliza informações de

refletância das bandas do vermelho, NIR e azul e foi desenvolvido com o objetivo de otimizar o sinal da vegetação com sensibilidade melhorada em regiões de alta biomassa e melhorar o monitoramento da vegetação através de um desacoplamento entre o sinal de fundo do dossel e uma redução nas influências da atmosfera (HUETE et al., 2002). Muitos trabalhos utilizam o índice de vegetação EVI para realizar o mapeamento de áreas semeadas com culturas, o qual tem se mostrado eficiente para o monitoramento agrícola (ARAÚJO et al., 2011; GUSSO et al., 2012; JOHANN et al., 2012; SOUZA et al., 2015; GRZEGOZEWSKI et al., 2016; BECKER et al., 2017a).

A análise multitemporal dos IVs podem ser realizadas extraindo métricas fenológicas. A fenologia é o estudo de eventos biológicos periódicos e seus fatores de controle, e as métricas fenológicas representam os estádios fenológicos e o progresso sazonal da cultura ou de outros tipos de vegetação (ZHONG; GONG; BIGING, 2014). Os dados de sensoriamento remoto vêm sendo utilizados para fornecer informações da fenologia da vegetação, como início do crescimento, máximo desenvolvimento vegetativo e senescência (JOHANN et al., 2016; GAO et al., 2017). Diferentes tipos de vegetação possuem diferentes características fenológicas, mostrando diferentes perfis de crescimento em dados de séries temporais de IV obtidos por sensoriamento remoto, podendo fornecer informações valiosas para a classificação do tipo de cobertura da terra (JIA et al., 2014c). A utilização de parâmetros fenológicos na classificação de culturas tem o potencial de possibilitar a transferência interanual de algoritmos de classificação, podendo alcançar um desempenho estável em relação aos valores das imagens originais (ZHONG; GONG; BIGING, 2014), obtendo bons resultados na classificação de culturas agrícolas (ZHONG et al., 2016a; BECKER et al., 2017a).

Outra forma de análise é a extração de métricas estatísticas (máximo, mínimo, média, desvio padrão, mediana...), que possuem vantagem sobre as variáveis fenológicas por não precisarem de um ano ou ciclo completo de imagens e o tempo entre duas cenas consecutivas não precisam ser o mesmo (VALERO et al., 2016).

Alguns trabalhos avaliaram a utilização de imagens geradas por algoritmos de fusão espaço-temporal para melhoria do resultado de mapeamentos (JIA et al., 2014a, 2014b, 2014c; SENF et al., 2015; LI et al., 2017; ZHU; RADELOFF; IVES, 2017). Para Jia et al. (2014c) as características temporais extraídas de séries temporais, têm abundante informação do crescimento da vegetação e possuem significativo efeito em melhorar o resultado da classificação. Para Senf et al. (2015), quando a quantidade de imagens Landsat disponíveis é limitada a utilização de imagens sintéticas gerados pelo STARFM aumenta a precisão da classificação.

Jia et al. (2014a) comparou métricas espectrais, fenológicas e estatísticas extraídas de imagens geradas pelo STARFM, obtendo melhores resultados semelhantes para vegetação utilizando métricas fenológicas e estatísticas, sendo superior as variáveis

espectrais. Zhu, Radeloff e Ives (2017) relatam que a inclusão de imagens preditas pelo STARFM em datas chaves pode melhorar o resultado da classificação, enquanto a inclusão de todas as imagens preditas pelo STARFM, aumenta o erro de classificação. Segundo eles, isto ocorre por que a informação espectral com alta correlação no tempo causa redundância dos dados, e as imagens preditas pelo STARFM apresentam alguns erros, que podem se acumular, reduzindo a acurácia da classificação. Li et al. (2017) conseguiu altas acurácias para mapear ciclo de culturas utilizando a informação fenológica extraídas de imagens geradas pelo STARFM.

Apesar de vários métodos de fusão espaço-temporal terem sido desenvolvidos nos últimos anos, ainda são poucos utilizados para melhorar a precisão do uso e a cobertura da terra (JIA et al., 2014b). Neste contexto, ainda são necessários estudos para avaliarem se variáveis (espectrais, estatísticas, fenológicas) extraídas de imagens geradas a partir de métodos de fusão espaço-temporais podem aprimorar os resultados dos mapeamentos e diferenciação de culturas agrícolas, como a soja e o milho, em áreas heterogêneas espacialmente, como na região oeste do Paraná.

Desta forma, o objetivo do trabalho foi comparar o desempenho do STARFM, ESTARFM e FSDAF para gerar imagens durante o desenvolvimento de culturas agrícolas, e avaliar se há melhoria no resultado do mapeamento de culturas agrícolas utilizando estas imagens, comparando métricas espectrais, estatísticas e fenológicas.

6.2.2 MATERIAL E MÉTODOS

6.2.2.1 Área de estudo

O estado do Paraná foi o segundo maior produtor de soja e milho na safra 2016/2017, com 19,6 e 17,8 milhões de toneladas, respectivamente (CONAB, 2018). Se considerar a produção de soja para o ano de 2016, o estado possui produção maior que a Índia, quarto maior produtor mundial (14,01 milhões de toneladas) (CONAB, 2018; FAOSTAT, 2018). Já para o milho a produção do Paraná foi maior que da Rússia (15,31 milhões de toneladas), 9º produtor mundial (ONAB, 2018; FAOSTAT, 2018). Assim, as produções de soja e milho no Paraná possuem grande representatividade na produção mundial.

Uma cena do satélite Landsat 8 (órbita 223, ponto 77) foi selecionado para o estudo (Figura 11). Esta é uma região de grande produção agrícola no oeste e centro-oeste Paranaense, principalmente de soja e milho (JOHANN et al., 2012; FRANÇA JUNIOR et al., 2015). O solo é classificado como Latossolo Vermelho Distroférrico (EMBRAPA, 2013). O clima da região é classificado subtropical mesotérmico (Cfa) segundo a classificação de Köppen, com temperatura anual média de 18,5 a 22,9 °C e precipitação anual de 1200 a 1800 mm (APARECIDO et al., 2016).

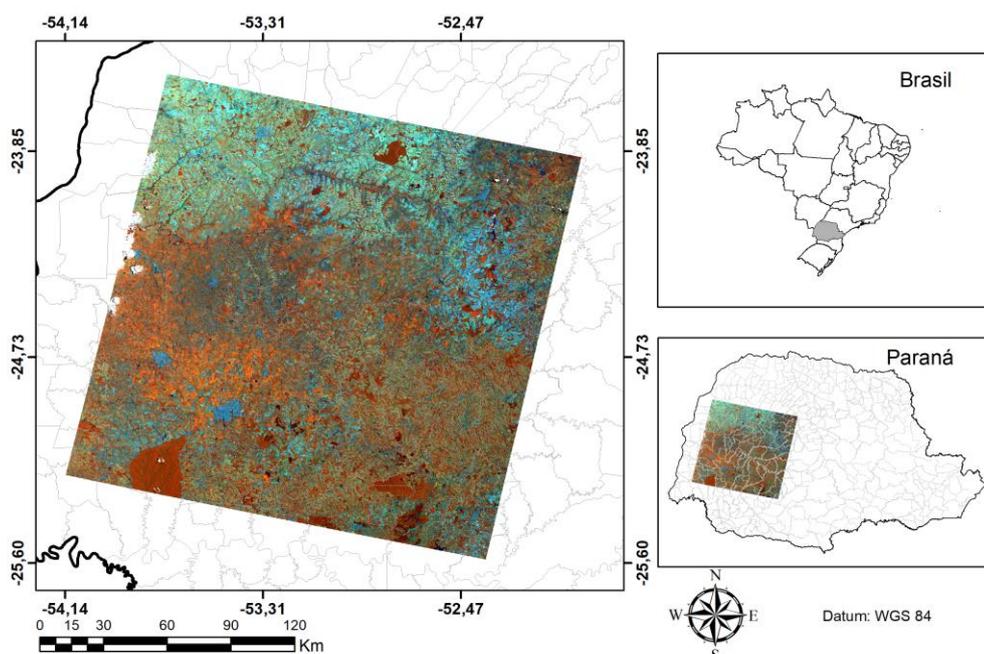


Figura 11 Localização da área de estudo.

6.2.2.2 Dados

Foram utilizadas as imagens de 30 m de resolução espacial do Landsat 8 Operational Land Imager (OLI) e as imagens de 500 m de resolução espacial do Moderate Resolution Imaging Spectroradiometer (MODIS) que compreende o ano/safra de verão 2016/2017. As imagens Landsat 8 de refletância da superfície de alto nível (nível 2) são disponibilizadas por demanda pelo US Geological Survey (USGS) (disponível em: <<https://earthexplorer.usgs.gov/>>). Essas imagens são processadas pelo Landsat Surface Reflectance Code (LaSRC) (VERMOTE et al., 2016). As imagens Landsat 8 foram analisadas visualmente, sendo eliminados os pixels com nuvens e sombra de nuvens, utilizando a banda de qualidade (ZHU; WOODCOCK, 2012; ZHU; WANG; WOODCOCK, 2015), que é distribuída juntamente com as imagens de refletância da superfície.

O produto MODIS MCD43A4 (Terra e Aqua Nadir BRDF – Refletância ajustada (NBAR) diária L3 Global 500 m Versão 6) de setembro de 2016 a março de 2017 foi adquirido pelo Data Pool do National Aeronautics and Space Administration (NASA). Estes dados são distribuídos pelo Land Processes Distributed Active Archive Center (LP DAAC), localizado no USGS Earth Resources Observation and Science (EROS) Center (disponível em: <<https://lpdaac.usgs.gov/>>). O MCD43A4 utiliza as passagens dos satélites Terra e Aqua diárias para comprovar a refletância dentro de cada período de 16 dias, por meio de algoritmo baseado na inversão de modelos de transferência radiativa (SCHAAF et al., 2002). O algoritmo ajusta a refletância no meio-dia solar local e reduz os efeitos do ângulo de visão e da dispersão anisotrópica. A refletância MCD43A4 é calculada para as bandas espectrais MODIS 1-7 a 500m de resolução diariamente na versão 6, utilizando uma janela temporal móvel (Guia do usuário MCD43, 2017).

Foram utilizadas as faixas do azul, verde, vermelho, Near Infrared (NIR), Shortwave Infrared 1 (SWIR 1) e Shortwave Infrared 2 (SWIR 2), que correspondem, respectivamente, às bandas 2, 3, 4, 5, 6 e 7 do Landsat 8 – OLI e às bandas 3, 4, 1, 2, 6 e 7 do sensor MODIS.

As imagens MODIS foram reprojetaadas para o mesmo sistema de referência do Landsat 8 – OLI (WGS 84 – UTM 22 S) e recortada para o tamanho do tile Landsat. Então, foi aplicado o filtro Savitzky-Golay (SAVITZKY; GOLAY, 1964) nos pixels faltantes ou com baixa qualidade. Em seguida as imagens foram reamostradas por Interpolação Bilinear para os algoritmos STARFM e ESTARFM, e pelo método do vizinho mais próximo para o algoritmo FSDAF. A etapa final foi recortar as imagens MODIS com o mesmo tamanho que as imagens Landsat 8 – OLI.

Para o STARFM e FSDAF utilizou-se o par de imagens Landsat/MODIS no qual a imagem MODIS obteve maior correlação com a imagem MODIS do dia predito. Para o ESTARFM, utilizou-se o critério das imagens entre os dois pares ou imagens mais próximas. Assim, para gerar a imagem do dia 289/2016, por exemplo, com o FSDAF e o STARFM foi utilizado o par de imagens do dia 281/2016 (Figura 12). Já para o ESTARFM, foram utilizados os pares de imagens do dia 281/2016 e 329/2016. Ao todo foram utilizadas 6 imagens Landsat 8, que estavam livres ou parcialmente livres de nuvens e 25 imagens MODIS, adotando, assim, um intervalo de 8 dias entre imagens.

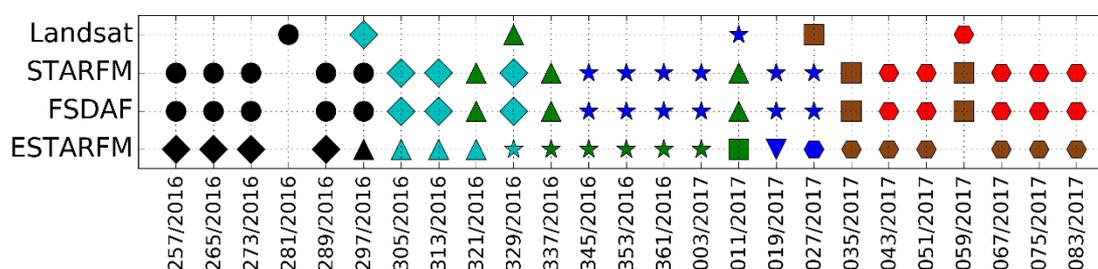


Figura 12 Datas dos pares de imagens utilizadas para gerar as imagens sintéticas. Mesmas cores e mesma forma para o FSDAF e STARFM indicam os pares de entrada. Para o ESTARFM, mesma cor ou mesma forma indicam os pares de entrada.

6.2.2.3 Algoritmos de fusão

Foram utilizados três algoritmos de fusão espaço-temporal: (i) STARFM (GAO et al., 2006); (ii) ESTARFM (ZHU et al., 2010), (iii) FSDAF (ZHU et al., 2016). O STARFM prediz uma imagem sintéticas no dia t_k com resolução Landsat (30 m) utilizando um ou dois pares Landsat/MODIS adquiridos no mesmo dia (t_0) e uma imagem MODIS para o dia predito (t_k) (GAO et al., 2006). Neste trabalho foi utilizado apenas um par de imagens Landsat/MODIS, pois alguns trabalhos sugerem um resultado melhor com apenas um par, e que a utilização de dois pares pode aumentar os erros de predição (SENF et al., 2015; ZHU; RADELOFF; IVES, 2017). Uma janela móvel é utilizada para reduzir os efeitos da heterogeneidade do pixel MODIS, mudanças na cobertura da terra e mudanças temporais. Então, são atribuídos pesos

espaciais, temporais e espectrais para determinar o quanto cada pixel similar encontrado dentro da janela móvel irá contribuir para estimar o pixel central (GAO et al., 2006).

O ESTARFM foi desenvolvido com base no STARFM, mas necessita de dois pares Landsat/MODIS nos dias (t_0) (ZHU et al., 2010). Da mesma forma que o STARFM, o ESTARFM também utiliza uma janela móvel. Porém, enquanto o STARFM assume que as mudanças que ocorrem no pixel do Landsat são equivalentes às mudanças no pixel MODIS, o ESTARFM considera elas proporcionais (GAO et al., 2015). Também são considerados pesos espaciais, temporais e espectrais para calcular o pixel predito. Para pixels MODIS com mistura espectral, um modelo linear de mistura espectral é aplicado para estimar o coeficiente de conversão efetivo para cada pixel de FR, com base na mistura de classes no pixel de CR (ZHU et al., 2010; GAO et al., 2015).

O FSDAF utiliza um par de imagens Landsat/MODIS para o dia (t_0) e uma imagem MODIS para o dia predito (t_k) (ZHU et al., 2016). O FSDAF utiliza uma classificação prévia ou utiliza uma classificação não supervisionada ISODATA. Neste trabalho foi utilizada a classificação de culturas agrícolas anuais/não cultura utilizando métricas temporais de NDVI e o classificador Random Forest do ARTIGO 1. O FSDAF também procura por pixels semelhantes dentro de uma janela móvel, mas que sejam da mesma classe do pixel a ser predito. Então utiliza um modelo de mistura espectral e um interpolador Thin Plate Spline (TPS) para prever o pixel central (ZHU et al., 2016).

6.2.2.4 Avaliação das imagens geradas

Para avaliar o resultado das imagens geradas pelos algoritmos de fusão foram geradas imagens também para as datas que existiam imagens Landsat 8, e comparando-se então às imagens geradas com a imagem existente, banda por banda. Por exemplo, a banda do vermelho do dia 329/2016 foi gerada utilizando as imagens da banda do vermelho do dia 297/2016 para o STARFM e FSDAF e utilizando as imagens do dia 297/2016 e 011/2017 para o ESTARFM.

Inicialmente avaliou-se a correlação por postos de Spearman (r_s). O desempenho dos algoritmos foi analisado pelo método do erro quadrático médio (RMSE) (Equação 1) e o índice refinado de Wilmott (d_r) (WILLMOTT; ROBESON; MATSUURA, 2012 – Equação 2).

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (O - E)^2} \quad \text{Eq.(1)}$$

$$d_r = 1 - \frac{\sum_{i=1}^n |E - O|}{2 \sum_{i=1}^n (|O - \bar{O}|)} \quad \text{Eq.(2)}$$

em que:

n - número de pixels;

O - valores de refletância da superfície da imagem Landsat 8;

E - valores de refletância da superfície da imagem gerada;

\bar{O} - valores médios de refletância da superfície da imagem Landsat 8.

O índice d_r é variável de -1 a 1. Valores próximos a 1 indicam uma boa concordância entre valores observados e preditos; d_r próximo ou menor a 0 representam discordância entre os valores (WILLMOTT; ROBESON; MATSUURA, 2012).

6.2.2.5 Classificação

a) Cenários de classificação

Foram considerados 5 cenários, que utilizaram diferentes métricas nas classificações. Nos 1º e 2º foram considerados apenas as bandas espectrais das imagens Landsat 8 livres de nuvens. As 3º, 4º e 5º foram realizadas utilizando as imagens geradas pelo STARFM, ESTARFM e FSDAF. No 3º cenário foram utilizadas as métricas espectrais das imagens Landsat 8 e as imagens espectrais geradas pelos algoritmos de fusão, no 4º foram considerados as métricas estatísticas e no 5º as métricas fenológicas. Cada cenário será detalhado a seguir.

b) Cenário 1: Imagens espectrais Landsat 8 classificadas separadamente

No primeiro cenário foram utilizadas as bandas 2, 3, 4, 5, 6 e 7 (azul, verde, vermelho, NIR, SWIR 1 e SWIR 2) do Landsat 8, das datas em que as imagens estavam livres de nuvens durante o período de desenvolvimento das culturas, ou seja, de setembro a fevereiro. Assim, as imagens 329/2016, 011/2017 e 027/2017 foram utilizadas. O processo de classificação seguiu a metodologia de Mercante et al. (2012), na qual cada imagem é classificada separadamente, e depois são unidas. Devido às diferenças nas datas de semeadura de algumas regiões dentro da área de estudo, apenas as amostras de treinamento em que haviam as características de cultura na composição falsa-cor do Landsat (564 NIR-SWIR1-vermelho) e pela análise do perfil temporal de EVI do MODIS (SATVeg, 2017) foram utilizadas para cada imagem. Assim, evita-se que amostras em que a cultura não estivesse semeada ou que já fora colhida fossem usadas para treinamento, pois quando há solo exposto pode haver confusão com outros alvos como áreas urbanas.

c) Cenário 2: Imagens espectrais Landsat 8 classificadas juntas

O segundo cenário utilizou as mesmas bandas e imagens que o cenário 1. Aqui, porém, todas as imagens foram classificadas juntamente em uma única vez.

d) Cenário 3: Imagens espectrais Landsat 8 e imagens espectrais de imagens sintéticas

Foram utilizadas as mesmas imagens do cenário 2, juntamente com as imagens geradas por cada algoritmo de fusão espectro temporal, com objetivo de avaliar se apenas as

bandas espectrais das imagens sintéticas eram capazes de melhorar o resultado das classificações.

e) Cenário 4: Métricas fenológicas

Para extração das métricas fenológicas foi calculado o Enhanced Vegetation Index (EVI) (Equação 3). O EVI tem melhor sensibilidade de capturar a dinâmica da vegetação em comparação com o NDVI (LI et al., 2017), mostrando diferenças de amplitude entre o perfil espectro-temporal da soja e do milho (BECKER et al., 2017b), mostrando-se adequado para classificação utilizando métricas fenológicas (ZHONG; GONG; BIGING, 2014; ZHONG et al., 2016a).

$$EVI = \frac{\rho_{NIR} - \rho_{VER}}{\rho_{NIR} + C_1 \times \rho_{VER} + C_2 \times \rho_{AZUL} + L} \quad \text{Eq.(3)}$$

em que: ρ_{NIR} é a refletância do NIR; ρ_{VER} é a refletância do vermelho; ρ_{AZUL} é a refletância do azul; L é o ajuste de fundo do dossel; C_1 e C_2 são os coeficientes do termo de resistência ao aerossol; G é o fator de ganho. Valores empíricos de 1, 6, 7,5 e 2,5 serão utilizados para L, C_1 , C_2 e G, respectivamente (HUETE et al., 1997; ZHONG; GONG; BIGING, 2014).

Então, o perfil espectro-temporal de EVI foi filtrado utilizando Savitzky-Golay (SAVITZKY; GOLAY, 1964), eliminando ruídos em imagens individuais geradas pelos algoritmos de fusão espaço-temporal (LI et al., 2017). As datas de transição fenológicas foram derivadas a partir do ajuste de uma curva predefinida (ZHONG et al., 2016a). Foi utilizada uma função assimétrica dupla sigmoideal para ajuste (SOUDANI et al., 2008) (Equação 4), e as variáveis fenológicas foram extraídas diretamente ou indiretamente (ZHONG et al., 2016a).

$$V(t) = V_b + \frac{1}{2} V_a [\tanh(p(t - D_i)) - \tanh(q(t - D_d))] \quad \text{Eq.(4)}$$

em que: $V(t)$ é o valor da série espectro-temporal de EVI, V_b é o valor de mínimo em que as culturas estão sendo semeadas, V_a é o amplitude de variação de EVI durante o ciclo da cultura, p e q são as taxas de variação média de crescimento e decrescimento do perfil de EVI, e D_i e D_d são as datas de máximo variação positiva e negativa do período de crescimento e decrescimento do perfil espectro-temporal de EVI (ZHONG et al., 2016a). Além destas métricas, foram utilizadas as métricas denominadas D_1 , D_2 , D_3 e D_4 que são os pontos de máximo e mínimo da segunda derivada (ZHONG; GONG; BIGING, 2012). D_1 e D_2 representam o início e final do ciclo. Também foi calculada a diferença dos dois, representando a duração do ciclo (D_c). D_3 e D_4 ocorre quando o EVI para de crescer e quando começa a decrescer, respectivamente (ZHONG et al., 2016b). Estas 11 variáveis formaram as métricas fenológicas.

f) Cenário 5: Métricas estatísticas

Foram calculadas também métricas estatísticas a partir do perfil espectro-temporal de EVI das imagens Landsat 8 e sintéticas. Além de média, mínimo, máximo, desvio padrão, coeficiente de variação, amplitude, mediana e soma, também foi calculado o somatório das diferenças (EVI_{SD}) das imagens de EVI (Equação 5), para criar uma nova variável que pudesse ser utilizada para diferenciar as culturas agrícolas anuais.

$$EVI_{SD} = \sum_{i=1}^n |EVI_i - EVI_{i+1}| \quad \text{Eq.(5)}$$

em que:

n é a quantidade de imagens da série temporal;

EVI_i é a imagem i da série temporal;

EVI_{i+1} é a imagem $i+1$ da série temporal.

6.2.2.6 Amostras de treinamento, validação e Random Forest e Acurácia das classificações

Foram formadas três classes: soja, milho e outros. Dados de campo foram utilizados como base para identificar as características da soja e do milho (Figura 13). Além de amostras de campo, foram coletadas mais amostras com base em composição falsa cor do Landsat (564 NIR-SWIR1-vermelho) e pela análise do perfil temporal de EVI do MODIS (SATVeg, 2017).

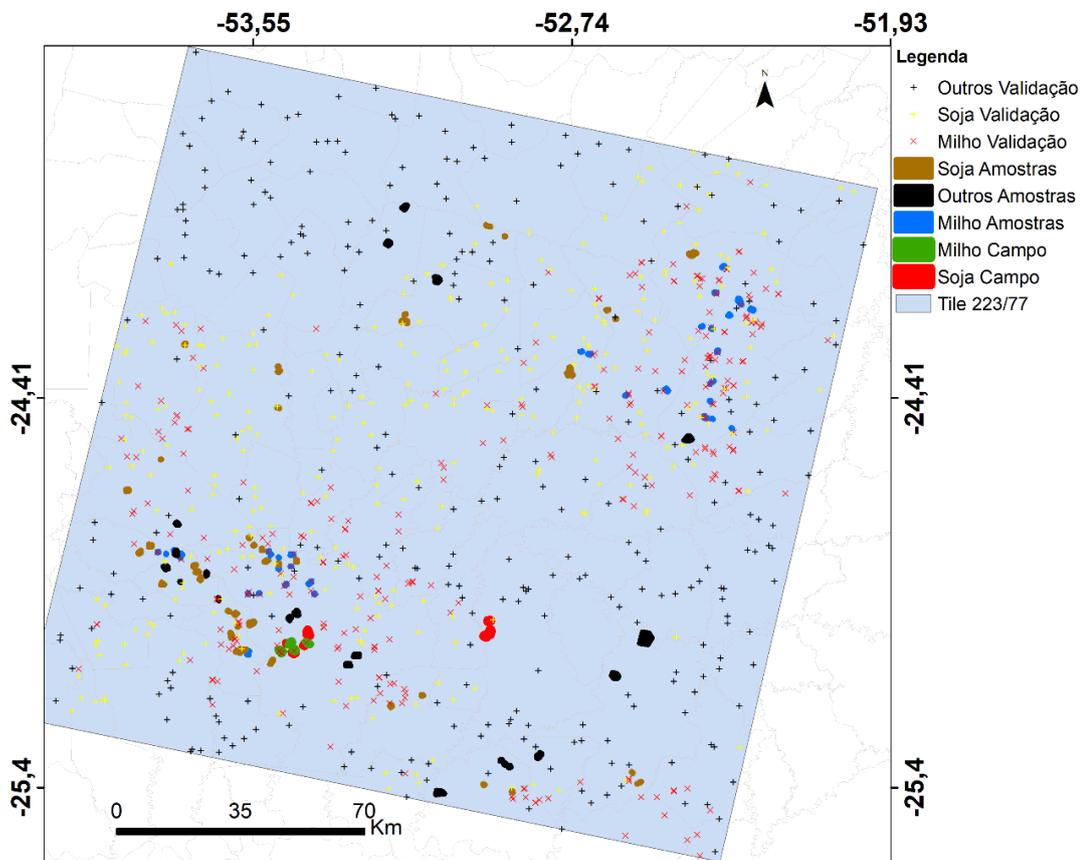


Figura 13 Amostras de campo, treinamento e validação.

Utilizou-se o algoritmo de classificação Random Forest (BREIMAN, 2001), da biblioteca Scikit-Learn (PEDREGOSA et al., 2011) de Machine Learn para Python. O Random Forest é adequado para classificar culturas agrícolas usando grande volume de dados (HAO et al., 2015). A única alteração de configuração foi alterar o critério para entropy. Após a utilização do classificador Random Forest, foi aplicado um filtro de mediana com janela de 3x3, para eliminar pixels isolados, conforme Mercante et al. (2012).

As avaliações da acurácia espacial dos mapeamentos foram realizadas por meio das matrizes de erros. Distribuíram-se aleatoriamente pontos em toda a cena; após isso, verificou-se a qual classe cada ponto pertencia, analisando a composição falsa-cor do Landsat (564 NIR-SWIR1-vermelho), pela análise do perfil temporal de EVI do MODIS (SATVeg, 2017) e pelas imagens de alta resolução do Google Earth. Então, 300 pontos por classe foram utilizados para calcular a matriz de erros para todos os cenários. A partir da matriz de erros, calculou-se a Exatidão Global (EG), no intuito de avaliar as acurácias do mapeamento.

Também foram determinadas as métricas de Acurácia de Produtor (AP), que se refere à probabilidade de um determinado pixel ter sido corretamente classificado, e a Acurácia de Usuário (AU), que indica a probabilidade que um pixel classificado na imagem de fato representa aquela categoria no campo (CONGALTON, 1991). Para avaliar diferenças significativas das medidas de precisão entre diferentes resultados de classificação foi utilizado o teste Z para comparação de duas proporções (Equação 6) (FOODY, 2009b).

$$Z = \frac{P_1 - P_2}{\sqrt{\bar{p}(1-\bar{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \quad \text{Eq.(6)}$$

em que:

$\bar{p} = \frac{x_1 + x_2}{n_1 + n_2}$, com x_1 e x_2 representando o número de casos alocados corretamente nas classificações de dados com tamanho n_1 e n_2 , respectivamente. Para este teste, assume-se que se o valor de $|Z| > 1,96$ indicará que as duas classificações comparadas são significativamente diferentes ao nível de significância de 5% (FOODY, 2009a).

6.2.3 RESULTADOS E DISCUSSÃO

6.2.3.1 Avaliação dos algoritmos de fusão espaço-temporal

Para avaliar o resultado da classificação foram geradas as imagens com os três algoritmos de fusão para o mesmo dia em que existia imagem do Landsat 8. Visualmente, todos os três algoritmos conseguiram gerar imagens que capturaram as mudanças temporais ocorridas pelo desenvolvimento das culturas agrícolas, ao mesmo tempo que preservaram a resolução espacial do Landsat 8 (Figura 14). O ESTARFM, por utilizar dois pares de imagens, foi mais afetado pela presença de nuvens em partes da imagem, gerando uma menor área utilizável.

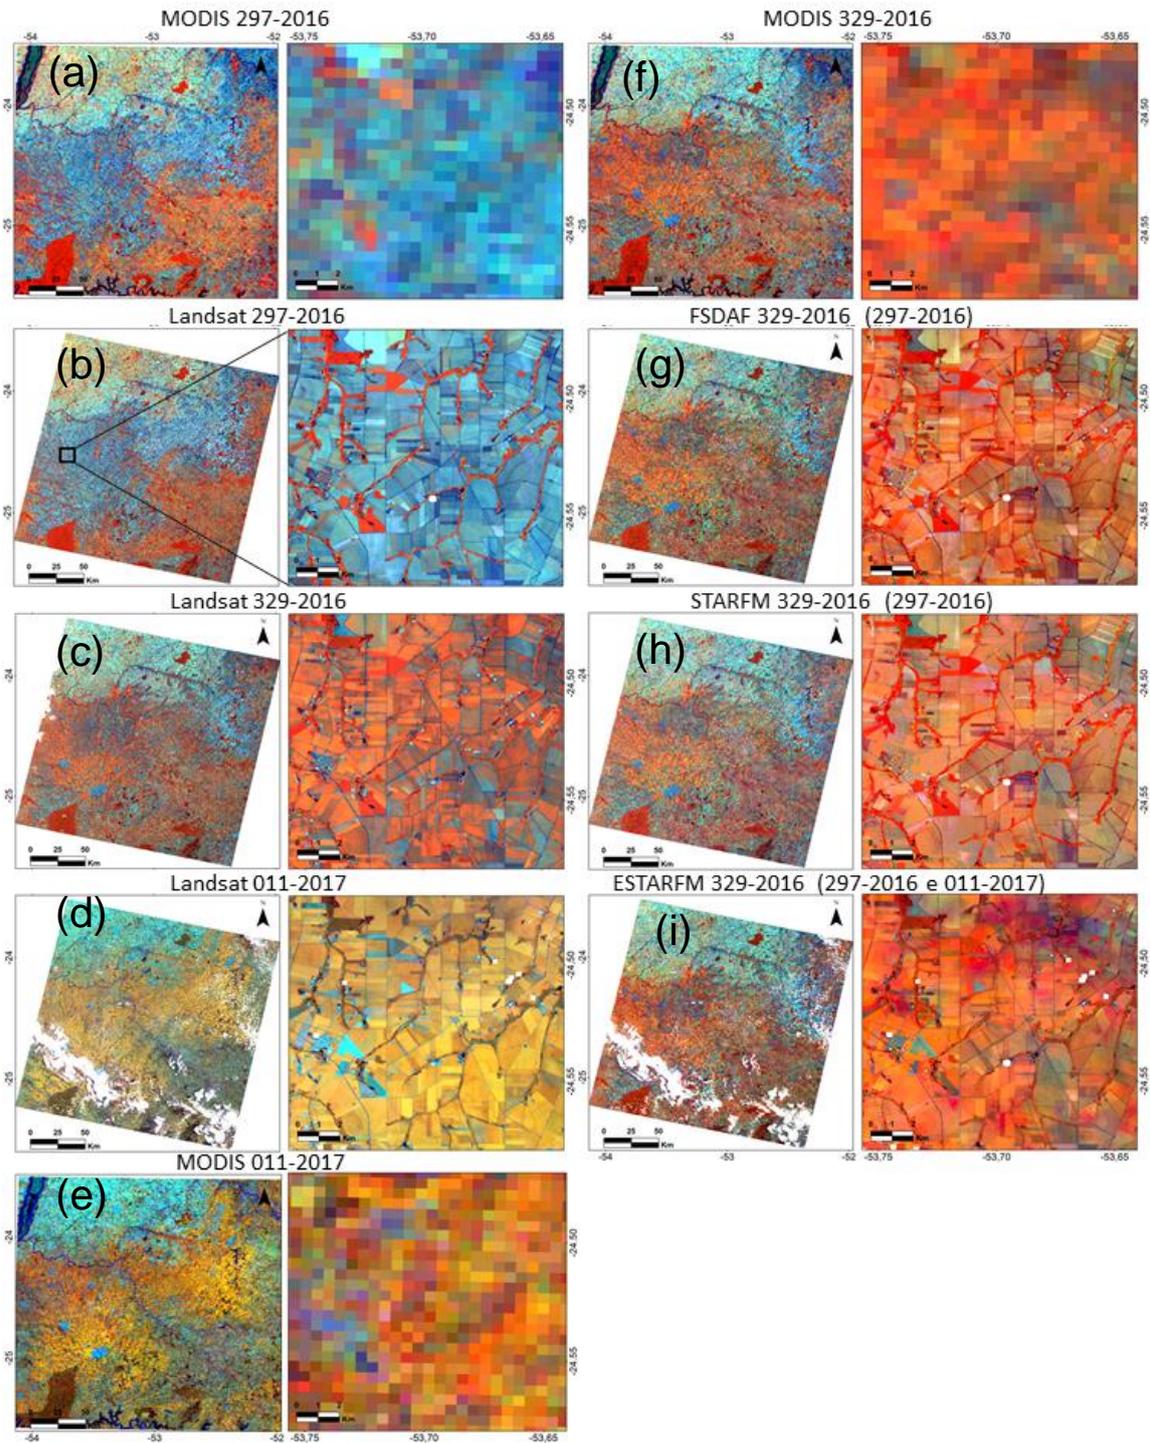


Figura 14 Imagem Landsat 8 do DOY (day of year) 329/2016 (c) e as imagens sintéticas geradas para o mesmo dia pelos algoritmos FSDAF (g), STARFM (h) e ESTARFM (i). Nos dois primeiros foram utilizados os pares MODIS-Landsat 8 (respectivamente, a e b) do DOY 297/2016 e a imagem MODIS do DOY 329/2016 (f). Para o ESTARFM utilizou-se também o par do dia 011/2017 (d, e). Todas as imagens estão na composição colorida falsa cor (R: NIR, G: SWIR1 e B: vermelho) com contraste linear de 2%.

Quando a variação temporal é menor entre os pares de imagens de entrada e a imagem predita, todos os algoritmos tiveram melhores resultados, com r_s acima de 0,85 e d_r acima de 0,7 para todas as bandas, como é o caso da imagem 297/2016 (Figura 15), que foi

gerada usando como base o par do dia 281/2016 para o STARFM e FSDAF e os pares 281/2016 e 329/2016 para o ESTARFM.

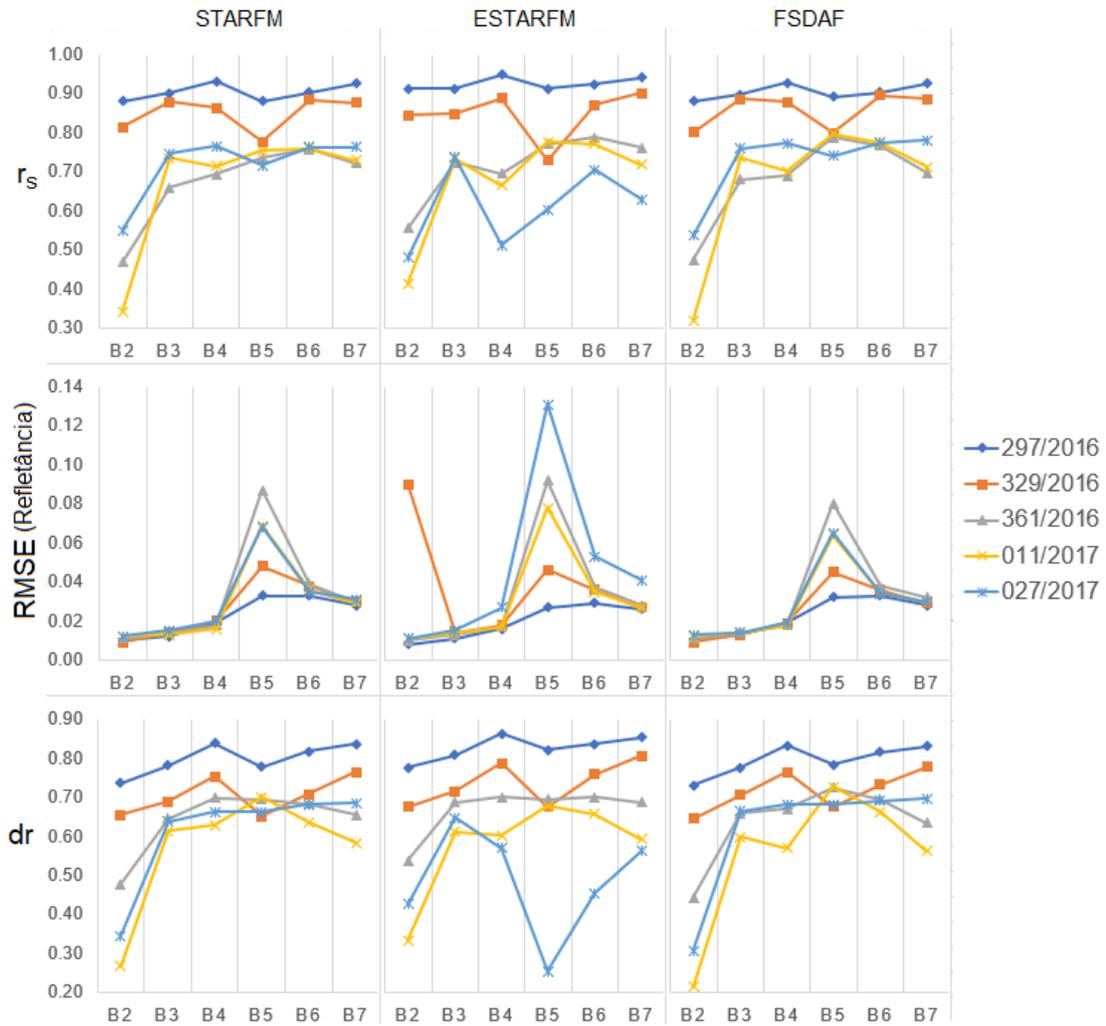


Figura 15 Gráficos de correlação de Spearman (r_s), erro quadrático médio (RMSE) e índice refinado de Wilmott (d_r) entre as imagens geradas pelo STARFM, ESTARFM e FSDAF e as imagens Landsat 8. As bandas espectrais são: B2:azul; B3: verde; B4: vermelho; B5: NIR; B6: SWIR 1; B7: SWIR 2. Para mais detalhes, consultar gráficos de dispersão no apêndice A.

Para todos os métodos de fusão a banda do azul teve menor r_s e d_r nas datas em que havia maior presença de nuvem nas imagens Landsat 8 (361/2016, 011/2017 e 027/2017). Possivelmente isso ocorreu por esta faixa ser mais influenciada por nuvens. No geral, as bandas do vermelho, SWIR 1 e SWIR 2, obtiveram maiores correlações e valores de d_r .

O STARFM e FSDAF obtiveram valores de RMSE semelhantes, com o FSDAF sendo ligeiramente menor. Já o ESTARFM obteve RMSE um pouco maior, principalmente para a banda do NIR. As bandas do visível (azul, verde e vermelho) obtiveram os menores RMSE, possivelmente pela menor amplitude de variação da refletância da superfície (Apêndice A), enquanto que o NIR possui o maior RMSE, chegando a 0,09 para o FSDAF e STARFM e a 0,13 para o ESTARFM. Os valores mais altos de RMSE ocorreram quando houve mais variação entre a data do par de imagens e a data predita. Gao et al. (2017) também encontraram maior RMSE para a banda do NIR em comparação com a banda do vermelho,

com o STARFM, assim como Zhu et al. (2016), que obtiveram piores valores de RMSE para o NIR e melhores para o azul, tanto para o STARFM como para o FSDAF, com melhores resultados para o FSDAF. Segundo esses autores, isso ocorre quando há grandes variações temporais (como o desenvolvimento de culturas) porque há mais mudanças de refletância no NIR do que em outras bandas.

6.2.3.2 Avaliação das classificações

O cenário 1 obteve exatidão global (EG) de 86,44%, sendo superior ao cenário 2 (72,44%) (Figura 16). Isso se deve à utilização de amostras independentes para cada imagem, pois ao utilizar as mesmas amostras e classificar todas as imagens juntas, criou-se confusão no classificador, pela variação das datas de semeadura dentro da área de estudo. Assim, algumas partes estão sendo semeadas em alguma das imagens e outras já estão em desenvolvimento vegetativo (JOHANN et al. 2016), e quando as primeiras já estão sendo colhidas, as outras ainda estão em desenvolvimento. O cenário 1 obteve resultado superior a trabalhos anteriores (MERCANTE et al., 2012, EG = 79.05%), que utilizaram classificação por máxima verossimilhança em imagens Landsat 5/TM para mapear soja em partes da mesma área de estudo.

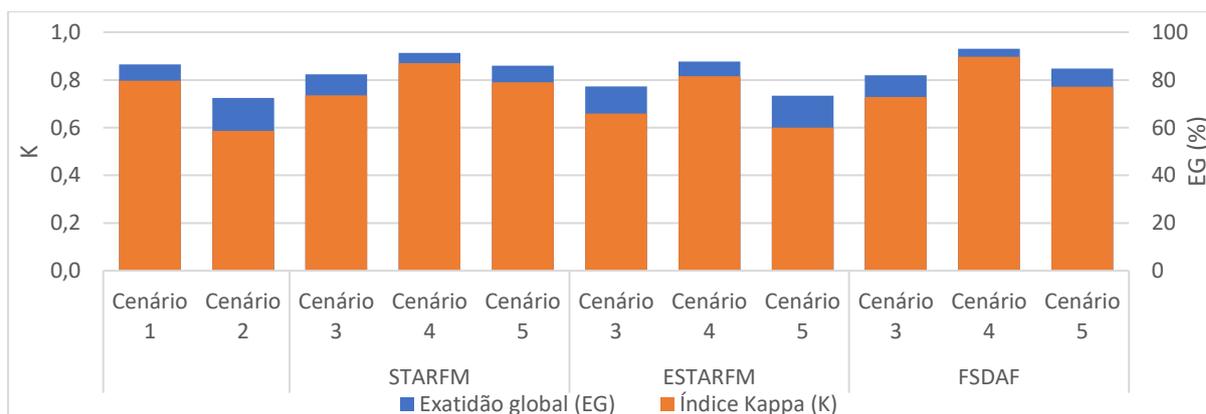


Figura 16 Gráfico de exatidão global para todos os cenários de classificação.

A adição das imagens sintéticas com as imagens Landsat 8 existentes (cenário 3), melhorou a exatidão da classificação em relação ao cenário 2, porém ainda foram inferiores ao cenário 1, sendo o cenário 3 utilizando as imagens geradas pelo STARFM o que obteve a melhor exatidão (82,33%). A utilização de métricas estatísticas extraídas do perfil de EVI do FSDAF e STARFM (cenário 5) foram superiores às métricas espectrais (cenário 3). Apenas a utilização de métricas fenológicas do perfil espectral de EVI (cenário 4) foram superiores ao cenário 1, com as imagens dos três algoritmos de fusão (STARFM, ESTARFM e FSDAF). Contudo, as métricas extraídas a partir das imagens do FSDAF obtiveram a melhor acurácia de todas as classificações (93,11%). Jia et al. (2014a) encontraram melhores resultados utilizando métricas estatísticas em comparação com métricas fenológicas para culturas,

porém eles separaram culturas de outros alvos e não diferenciaram o tipo de cultura. Além disso, eles utilizaram apenas 5 métricas fenológicas e 4 métricas estatísticas.

Estatisticamente, apenas o cenário 4 utilizando o FSDAF ou o STARFM foram superiores ao cenário 1 (Tabela 12), ou seja, os resultados utilizando as métricas fenológicas derivadas dos dois algoritmos de fusão foram superiores às métricas espectrais classificadas com cada imagem do Landsat 8 separadamente. Porém, se considerar as imagens espectrais do Landsat 8 classificadas juntas (cenário 2), apenas o cenário 5 (métricas estatísticas) não obteve resultado superior. Considerando o melhor cenário (cenário 4 – FSDAF), ele não foi superior apenas ao cenário 4 com o STARFM.

Tabela 12 Teste Z a 5% de significância entre todos os cenários de classificação

	Cenário	1	2	STARFM			ESTARFM			FSDAF	
				3	4	5	3	4	5	3	4
STARFM	2	7.3*									
	3	2.4*	-5.0*								
	4	-3.3*	-10.4*	-5.6*							
	5	0.3 ^{ns}	-7.1*	-2.1*	3.6*						
ESTARFM	3	5.1*	-2.3*	2.7*	8.2*	4.8*					
	4	-0.8 ^{ns}	-8.1*	-3.2*	2.5*	-1.0 ^{ns}	-5.8*				
	5	6.9*	-0.4 ^{ns}	4.6*	10.0*	6.7*	1.9 ^{ns}	7.7*			
FSDAF	3	2.6*	-4.8*	0.2 ^{ns}	5.9*	2.4*	-2.5*	3.4*	-4.4*		
	4	-4.7*	-11.6*	-7.0*	-1.4 ^{ns}	-4.9*	-9.5*	-3.9*	-11.2*	-7.2*	
	5	1.0 ^{ns}	-6.4*	-1.4 ^{ns}	4.3*	0.7 ^{ns}	-4.1*	1.8 ^{ns}	-6.0*	-1.6 ^{ns}	5.6*

Nota: * significativo a 5% de probabilidade; ^{ns} - não significativo.

O cenário 1 obteve alta acurácia de usuário (AU) para a soja (97%), indicando que do total das áreas classificadas com soja, apenas 3% não é soja. Porém, deixou de classificar 13% desta classe (acurácia de produtor – AP: 87%). Já para as classes milho e outros, apenas 82% das áreas classificadas eram realmente está classe. Assim, houve maior confusão de culturas sendo classificadas como outros e de outros sendo classificadas como milho (Apêndice B – Matriz de erros de todos os cenários de classificação). Já o cenário 2 obteve uma alta AP (93%) para a soja; assim, apenas 7% das áreas de soja foram omitidas na classificação, tendo baixa AP para a classe milho e baixa AU para a classe outros, pela grande quantidade de pixel de milho classificado como outros.

Já o cenário 3, que inclui além das imagens espectrais do Landsat 8, também as imagens espectrais sintéticas, obteve melhor AU para a classe milho para todos os algoritmos de fusão espaço-temporal, chegando a AU de 95% para o STARFM. O cenário 5 com as imagens geradas pelo ESTARFM obteve altas acurácias para a classe outros (AU: 92% e AP: 98%). O cenário 5 com o STARFM e FSDAF obtiveram melhores acurácias para a soja (AU: 93%, AP: 98% e AU: 92%, AP: 96%, respectivamente).

A utilização de métricas fenológicas (cenário 4) mostrou melhores resultados gerais de AP e AU para os três métodos de fusão espaço-temporal. Com melhor resultado para o

FSDAF, em que as AU e AP foram superiores a 87 e 86%, respectivamente, chegando a AU de 96 e 98% para milho e outros, respectivamente, e AP de 96 e 97% para soja e outros, respectivamente. Neste cenário, os maiores erros ocorreram com a inclusão de pixels de milho classificados como soja. Esses erros ocorreram principalmente em áreas de sojas semeadas mais precocemente, coincidindo com a semeadura do milho.

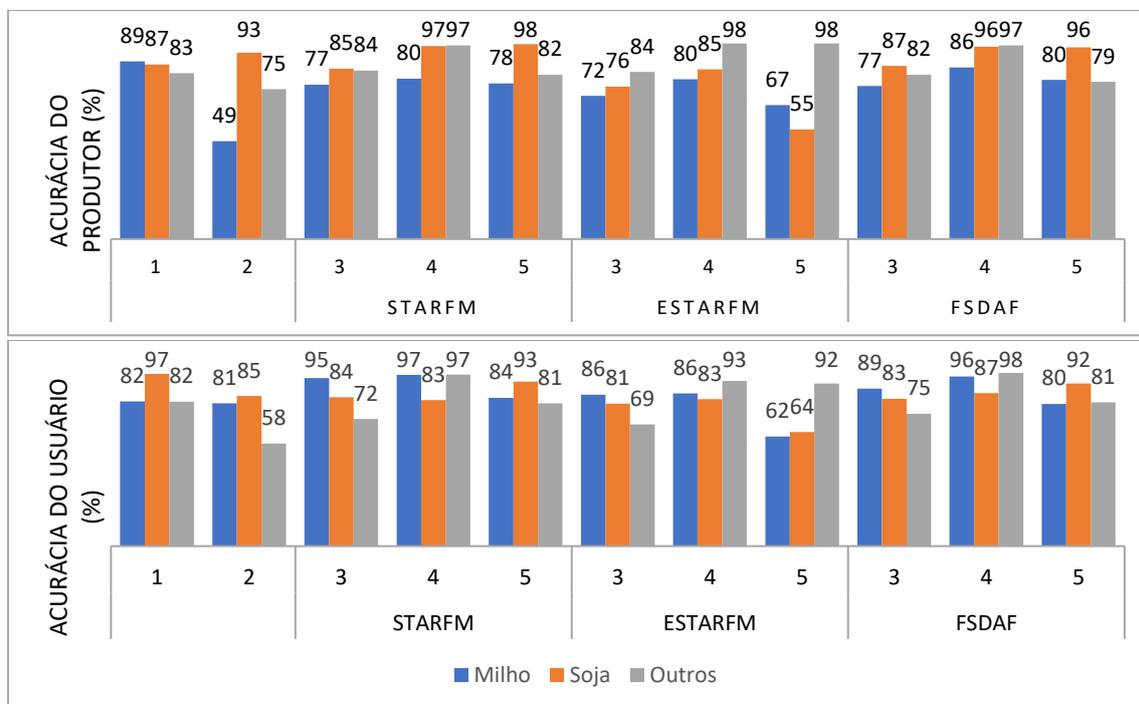


Figura 17 Acurácia de produtor e usuário para as classes soja, milho e outros com todos os cenários de classificação.

A classificação utilizando as métricas fenológicas de EVI (cenário 4) extraídas das imagens sintéticas (30 m) conseguiram bons resultados para áreas grandes (Figura 18b e d) e para áreas pequenas (Figura 18 a e c), principalmente as extraídas das imagens geradas pelo FSDAF – assim, superando limitações encontradas por trabalhos anteriores nesta região de estudo que classificaram soja e milho, em que áreas menores sofriam mais confusões, como Zhong et al. (2016a), que utilizaram métricas fenológicas de EVI do sensor MODIS com 500 m de resolução espacial e Souza et al. (2015), que utilizaram métricas do perfil espectro-temporal de IVs do sensor MODIS com 250 m de resolução espacial.

Assim, a utilização de algoritmos de fusão espaço-temporal mostra-se uma importante ferramenta para o mapeamento de culturas agrícolas com baixa disponibilidade de nuvens. Com o lançamento dos Sentinel 2a e 2b aumenta a disponibilidade de imagens com média resolução (GÓMEZ; WHITE; WULDER, 2016) e também a possibilidade de gerar fusão espaço-temporal de imagens (WANG; ATKINSON, 2018). Desta forma, estes dados podem ser utilizados em conjunto para aumentar a informação temporal, contribuindo para melhorar o monitoramento de culturas agrícolas.

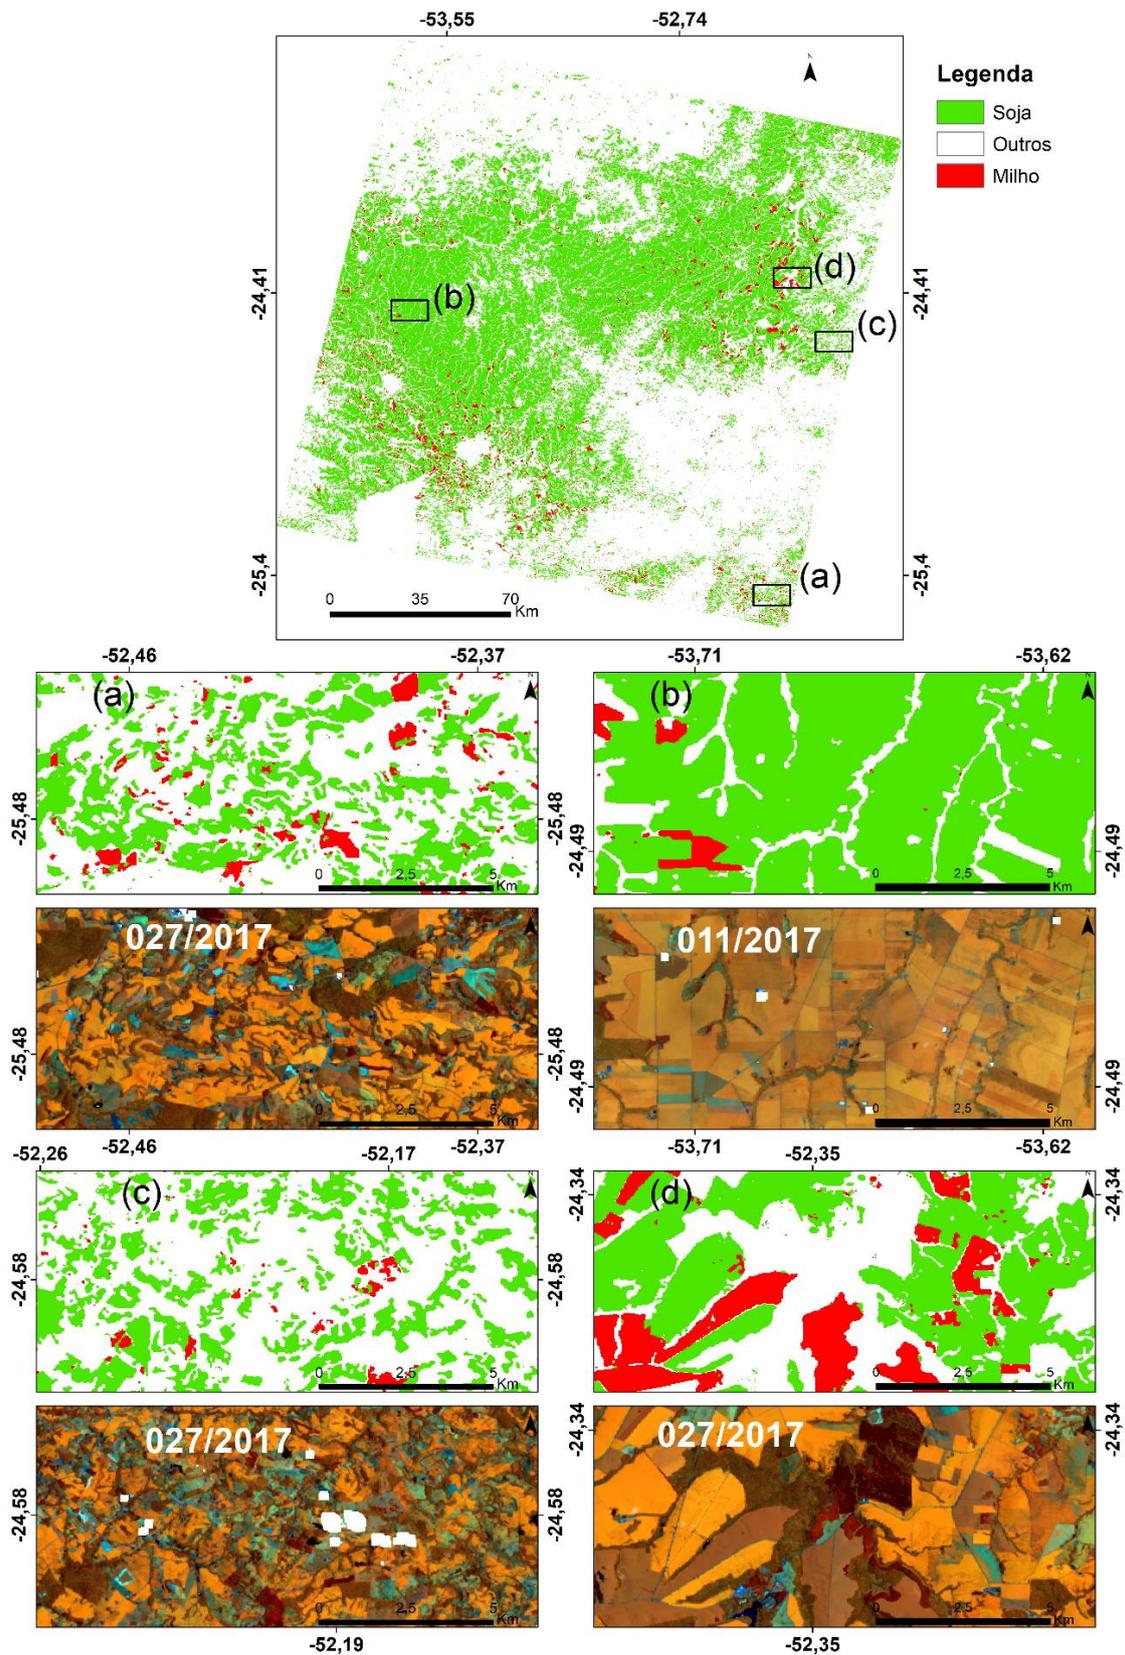


Figura 18 Resultado da classificação com métricas fenológicas extraídas da série temporal de EVI das imagens geradas pelo FSDAF com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

6.2.4 CONCLUSÕES

O algoritmo FSDAF obteve melhores resultados para gerar imagens sintéticas em comparação ao STARFM e ao ESTARFM, necessitando de apenas um par de entrada. O ESTARFM e o STARFM também conseguiram prever a refletância da superfície mesmo quando houve mudança temporal. Porém, o ESTARFM, por necessitar de dois pares de imagens de entrada, pode ser mais prejudicado quando há menor disponibilidade de imagens livres de nuvens, além de ser computacionalmente mais oneroso.

As classificações utilizando métricas fenológicas extraídas do perfil de EVI obtidas das imagens geradas pelo FSDAF obtiveram a melhor exatidão global (93,11%) e índice Kappa (0,9), com valor de, respectivamente, 6,67% e 0,1, melhor que a classificação utilizando apenas as bandas espectrais das imagens existentes. O FSDAF obteve melhores resultados, porém, neste trabalho, foi utilizada uma pré-classificação. O STARFM também alcançou bons resultados, sem necessitar de nenhuma informação inicial e utilizando apenas um par de entrada.

Assim, os resultados sugerem que a utilização de informações fenológicas é melhor do que informações espectrais e estatísticas para mapear soja e milho. Para extrair informações fenológicas das culturas agrícolas com média resolução espacial os algoritmos de fusão espaço-temporal são uma boa opção.

6.2.5 REFERÊNCIAS

ARAÚJO, G. K. D.; ROCHA, J. V.; LAMPARELLI, R. A. C.; ROCHA, A. M. Mapeamento de culturas de verão no estado do Paraná por meio de composições decendiais de NDVI do sensor Spot Vegetation. **Engenharia Agrícola**, v. 31, n. 4, p. 760-770, 2011.

ATZBERGER, C. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013.

BECKER, W. R.; JOHANN, J. A.; RICETTI, J.; SILVA, L. C. de A. Data mining techniques for separation of summer crop based on satellite images. **Engenharia Agrícola**, v. 37, n. 4, p. 750-759, 2017. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162017000400750&lng=en&tlng=en>. Acesso em: 10 nov. 2017.

BISQUERT, M.; BORDOGNA, G.; BÉGUÉ, A.; CANDIANI, G.; TEISSEIRE, M.; PONCELET, P. A simple fusion method for image time series based on the estimation of image temporal validity. **Remote Sensing**, v. 7, n. 1, p. 704-724, 2015.

BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p. 526-547, 2014.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

CONAB. **Levantamento de Safras – Séries Históricas (1976-2018)**. Disponível em: <http://www.conab.gov.br/conteudos.php?a=1252&&Pagina_objcmsconteudos=2#A_objcms>

conteudos>. Acesso em: 19 jan. 2018.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, 1991.

EBERHARDT, I. D. R.; SCHULTZ, B.; RIZZI, R.; SANCHES, I. D. A.; FORMAGGIO, A. R.; ATZBERGER, C.; MELLO, M. P.; IMMITZER, M.; TRABAQUINI, K.; FOSCHIERA, W.; LUIZ, A. J. B. Cloud cover assessment for operational crop monitoring systems in tropical areas. **Remote Sensing**, v. 8, n. 3, p. 1-14, 2016.

FAOSTAT. **Production quantities by country - Average 1993-2016**. Disponível em: <<http://faostat3.fao.org>>. Acesso em: 19 jan. 2018.

FOODY, G. M. Classification accuracy comparison: Hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority. **Remote Sensing of Environment**, v. 113, n. 8, p. 1658-1663, 2009a. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2009.03.014>>. Acesso em: 10 jan. 2017.

FOODY, G. M. Sample size determination for image classification accuracy assessment and comparison. **International Journal of Remote Sensing**, v. 30, n. 20, p. 5273-5291, 2009b. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01431160903130937>>. Acesso em: 10 jan. 2017.

FRANÇA JUNIOR, P.; VILLA, M. E. C. D.; VILLA, J. F. D. Características Geomorfológicas e a Produção de Culturas Temporárias no estado do Paraná-Brasil. **Revista Formação**, v. 1, n. 22, p. 71-86, 2015.

FRITZ, S.; SEE, L.; MCCALLUM, I.; YOU, L.; BUN, A.; MOLTCHANOVA, E.; DUERAUER, M.; ALBRECHT, F.; SCHILL, C.; PERGER, C.; HAVLIK, P.; MOSNIER, A.; THORNTON, P.; WOOD-SICHTA, U.; HERRERO, M.; BECKER-RESHEF, I.; JUSTICE, C.; HANSEN, M.; GONG, P.; ABDEL AZIZ, S.; CIPRIANI, A.; CUMANI, R.; CECCHI, G.; CONCHEDDA, G.; FERREIRA, S.; GOMEZ, A.; HAFFANI, M.; KAYITAKIRE, F.; MALANDING, J.; MUELLER, R.; NEWBY, T.; NONGUIERMA, A.; OLUSEGUN, A.; ORTNER, S.; RAJAK, D. R.; ROCHA, J.; SCHEPASCHENKO, D.; SCHEPASCHENKO, M.; TEREKHOV, A.; TIANGWA, A.; VANCUTSEM, C.; VINTROU, E.; WENBIN, W.; VAN DER VELDE, M.; DUNWOODY, A.; KRAXNER, F.; OBERSTEINER, M. Mapping global cropland and field size. **Global Change Biology**, v. 21, n. 5, p. 1980-1992, 2015.

GAO, F.; ANDERSON, M. C.; ZHANG, X.; YANG, Z.; ALFIERI, J. G.; KUSTAS, W. P.; MUELLER, R.; JOHNSON, D. M.; PRUEGER, J. H. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. **Remote Sensing of Environment**, v. 188, p. 9-25, 2017.

GAO, F.; HILKER, T.; ZHU, X.; ANDERSON, M.; MASEK, J.; WANG, P.; YANG, Y. Fusing Landsat and MODIS Data for Vegetation Monitoring. **IEEE Geoscience and Remote Sensing Magazine**, v. 3, n. 3, p. 47-60, 2015.

GAO, F.; MASEK, J.; SCHWALLER, M.; HALL, F. On the blending of the landsat and MODIS surface reflectance: predicting daily landsat surface reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 8, p. 2207-2218, 2006.

GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55-72, 2016.

GRAESSER, J.; RAMANKUTTY, N. Semi-automatic detection of crop field parcels with Landsat imagery. **Remote Sensing of Environment**, v. 201, p. 165-180, 2017. Disponível

em: <<http://dx.doi.org/10.1016/j.rse.2017.08.027>>. Acesso em: 05 jan. 2018.

GRANDE, T. O. de; ALMEIDA, T. de; CICERELLI, R. E. Classificação orientada a objeto em associação às ferramentas reflectância acumulada e mineração de dados. **Pesquisa Agropecuária Brasileira**, v. 51, n. 12, p. 1983-1991, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2016001201983&lng=pt&nrm=iso&tlng=en>. Acesso em: 10 jan. 2017.

GRZEGOZEWSKI, D. M.; JOHANN, J. A.; URIBE-OPAZO, M. A.; MERCANTE, E.; COUTINHO, A. C. Mapping soya bean and corn crops in the State of Paraná, Brazil, using EVI images from the MODIS sensor. **International Journal of Remote Sensing**, v. 37, n. 6, p. 1257-1275, 2016.

GUSSO, A.; ARVOR, D.; DUCATI, J. R.; VERONEZ, M. R.; SILVEIRA, L. G. da. Assessing the modis crop detection algorithm for soybean crop area mapping and expansion in the Mato Grosso state, Brazil. **The Scientific World Journal**, v. 2014, n. 1, 2014.

GUSSO, A.; FORMAGGIO, A. R.; RIZZI, R.; ADAMI, M.; RUDORFF, B. F. T. Soybean crop area estimation by Modis/Evi data. **Pesquisa Agropecuaria Brasileira**, v. 47, n. 3, p. 425-435, 2012.

HAO, P.; ZHAN, Y.; WANG, L.; NIU, Z.; SHAKIR, M. Feature selection of time series MODIS data for early crop classification using random forest: A case study in Kansas, USA. **Remote Sensing**, v. 7, n. 5, p. 5347-5369, 2015.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.; GAO, X.; FERREIRA, L.. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195-213, 2002. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425702000962>>. Acesso em: 10 jan. 2017.

JIA, K.; LIANG, S.; WEI, X.; YAO, Y.; SU, Y.; JIANG, B.; WANG, X. Land cover classification of landsat data with phenological features extracted from time series MODIS NDVI data. **Remote Sensing**, v. 6, n. 11, p. 11518-11532, 2014a.

JIA, K.; LIANG, S.; ZHANG, L.; WEI, X.; YAO, Y.; XIE, X. Forest cover classification using Landsat ETM+ data and time series MODIS NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, n. 1, p. 32-38, 2014b. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.04.015>>. Acesso em: 10 jan. 2017.

JIA, K.; LIANG, S.; ZHANG, N.; WEI, X.; GU, X.; ZHAO, X.; YAO, Y.; XIE, X. Land cover classification of finer resolution remote sensing data integrating temporal features from time series coarser resolution data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 93, p. 49-55, 2014c. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2014.04.004>>. Acesso em: 10 jan. 2017.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná - Brasil. **Engenharia Agrícola**, v. 36, n. 1, p. 126-142, 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162016000100126&lng=pt&nrm=iso&tlng=en>. Acesso em: 10 jan. 2017.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa Agropecuaria Brasileira**, v. 47, n. 9, p. 1295-1306, 2012.

KING, L.; ADUSEI, B.; STEHMAN, S. V.; POTAPOV, P. V.; SONG, X.-P.; KRYLOV, A.; DI BELLA, C.; LOVELAND, T. R.; JOHNSON, D. M.; HANSEN, M. C. A multi-resolution approach

to national-scale cultivated area estimation of soybean. **Remote Sensing of Environment**, v. 195, p. 13-29, 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425717301505>>. Acesso em: 10 dez. 2017.

KUPLICH, T. M.; MOREIRA, A.; FONTANA, D. C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 55, p. 1116-1123, 2013.

LI, L.; ZHAO, Y.; FU, Y.; PAN, Y.; YU, L.; XIN, Q. High Resolution Mapping of Cropping Cycles by Fusion of Landsat and MODIS Data. **Remote Sensing**, v. 9, n. 12, p. 12-32, 2017. Disponível em: <<http://www.mdpi.com/2072-4292/9/12/1232>>. Acesso em: 15 dez. 2017.

LU, M.; CHEN, J.; TANG, H.; RAO, Y.; YANG, P.; WU, W. Land cover change detection by integrating object-based data blending model of Landsat and MODIS. **Remote Sensing of Environment**, v. 184, p. 374-386, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.07.028>>. Acesso em: 10 jan. 2017.

MERCANTE, E.; LIMA, L. E. P. de; JUSTINA, D. D.; URIBE-OPAZO, M. A.; LAMPARELLI, R. A. C. Detection of soybean planted areas through orbital images based on culture spectral dynamics. **Engenharia Agrícola**, v. 32, n. 5, p. 920-931, 2012.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, É. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825-2830, 2011. Disponível em: <<http://dl.acm.org/citation.cfm?id=2078195%5Cnhttp://arxiv.org/abs/1201.0490>>. Acesso em: 10 jan. 2017.

SANTOS, J. S.; FONTANA, D. C.; SILVA, T. S. F.; RUDORFF, B. F. T. Identificação da dinâmica espaço-temporal para estimar área cultivada de soja a partir de imagens MODIS no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 54-63, 2014.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SCHAAF, C. B.; GAO, F.; STRAHLER, A. H.; LUCHT, W.; LI, X.; TSANG, T.; STRUGNELL, N. C.; ZHANG, X.; JIN, Y.; MULLER, J.-P.; LEWIS, P.; BARNESLEY, M.; HOBSON, P.; DISNEY, M.; ROBERTS, G.; DUNDERDALE, M.; DOLL, C.; D'ENTREMONT, R. P.; HU, B.; LIANG, S.; PRIVETTE, J. L.; ROY, D. First operational BRDF, albedo nadir reflectance products from MODIS. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 135-148, 2002. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0034425702000913>>. Acesso em: 10 jan. 2017.

SENF, C.; LEITÃO, P. J.; PFLUGMACHER, D.; VAN DER LINDEN, S.; HOSTERT, P. Mapping land cover in complex Mediterranean landscapes using Landsat: Improved classification accuracies from integrating multi-seasonal and synthetic imagery. **Remote Sensing of Environment**, v. 156, p. 527-536, 2015.

SILVA JUNIOR, C. a.; FRANK, T.; RODRIGUES, T. C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 44-53, 2014. Disponível em: <<http://www.agriambi.com.br/revista/v18n01/v18n01a07.pdf>>. Acesso em: 10 jan. 2017.

SONG, X.; POTAPOV, P. V.; KRYLOV, A.; KING, L.; DI BELLA, C. M.; HUDSON, A.; KHAN, A.; ADUSEI, B.; STEHMAN, S. V.; HANSEN, M. C. National-scale soybean mapping and area estimation in the United States using medium resolution satellite imagery and field survey.

Remote Sensing of Environment, v. 190, p. 383-395, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2017.01.008>>. Acesso em: 10 jan. 2018.

SOUDANI, K.; LE MAIRE, G.; DUFRÊNE, E.; FRANÇOIS, C.; DELPIERRE, N.; ULRICH, E.; CECCHINI, S. Evaluation of the onset of green-up in temperate deciduous broadleaf forests derived from Moderate Resolution Imaging Spectroradiometer (MODIS) data. **Remote Sensing of Environment**, v. 112, n. 5, p. 2643-2655, 2008.

SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809-1824, 2015. Disponível em: <<http://www.tandfonline.com/doi/full/10.1080/01431161.2015.1026956>>. Acesso em: 10 jan. 2017.

VALERO, S.; MORIN, D.; INGLADA, J.; SEPULCRE, G.; ARIAS, M.; HAGOLLE, O.; DEDIEU, G.; BONTEMPS, S.; DEFOURNY, P.; KOETZ, B. Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions. **Remote Sensing**, v. 8, n. 1, p. 1-21, 2016.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46-56, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2016.04.008>>. Acesso em: 10 jan. 2017.

VINTROU, E.; IENCO, D.; BEGUE, A.; TEISSEIRE, M. Data mining, a promising tool for large-area cropland mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 5, p. 2132-2138, 2013.

WANG, Q.; ATKINSON, P. M. Spatio-temporal fusion for daily Sentinel-2 images. **Remote Sensing of Environment**, v. 204, 2017, p. 31-42, 2018. Disponível em: <<https://doi.org/10.1016/j.rse.2017.10.046>>. Acesso em: 20 jan. 2018.

WANG, Z.; SCHAAF, C. B.; SUN, Q.; KIM, J.; ERB, A. M.; GAO, F.; ROMÁN, M. O.; YANG, Y.; PETROY, S.; TAYLOR, J. R.; MASEK, J. G.; MORISETTE, J. T.; ZHANG, X.; PAPUGA, S. A. Monitoring land surface albedo and vegetation dynamics using high spatial and temporal resolution synthetic time series from Landsat and the MODIS BRDF/NBAR/albedo product. **International Journal of Applied Earth Observation and Geoinformation**, v. 59, p. 104-117, 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0303243417300715>>. Acesso em: 10 dez. 2017.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, v. 32, n. 13, p. 2088-2094, 2012. Disponível em: <<http://doi.wiley.com/10.1002/joc.2419>>. Acesso em: 10 jan. 2017.

WU, K.; DU, Q.; WANG, Y.; YANG, Y. Supervised Sub-Pixel Mapping for Change Detection from Remotely Sensed Images with Different Resolutions. **Remote Sensing**, v. 9, n. 3, p. 284, 2017. Disponível em: <<http://www.mdpi.com/2072-4292/9/3/284>>. Acesso em: 10 jan. 2018.

XU, M.; JIA, X.; PICKERING, M. Automatic cloud removal for landsat 8 oli images using cirrus band. **IEEE International Geoscience and Remote Sensing Symposium**, p. 2511-2514, 2014.

XU, M.; JIA, X.; PICKERING, M. Cloud effects removal via sparse representation. In: 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2, **Anais...IEEE**, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7325836/>>. Acesso em: 10 jan. 2017.

YAN, L.; ROY, D. P. Automated crop field extraction from multi-temporal Web Enabled Landsat Data. **Remote Sensing of Environment**, v. 144, p. 42-64, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2014.01.006>>. Acesso em: 10 jan. 2017.

YAO, F.; TANG, Y.; WANG, P.; ZHANG, J. Estimation of maize yield by using a process-based model and remote sensing data in the Northeast China Plain. **Physics and Chemistry of the Earth**, v. 87-88, p. 142-152, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.pce.2015.08.010>>. Acesso em: 10 jan. 2017.

ZHANG, B.; ZHANG, L.; XIE, D.; YIN, X.; LIU, C.; LIU, G. Application of synthetic NDVI time series blended from landsat and MODIS data for grassland biomass estimation. **Remote Sensing**, v. 8, n. 1, p. 1-21, 2016.

ZHAO, J.; LI, J.; LIU, Q.; FAN, W.; ZHONG, B.; WU, S.; YANG, L.; ZENG, Y.; XU, B.; YIN, G. Leaf area index retrieval combining HJ1/CCD and Landsat8/OLI data in the Heihe River Basin, China. **Remote Sensing**, v. 7, n. 6, p. 6862-6885, 2015.

ZHONG, L.; GONG, P.; BIGING, G. S. Phenology-based Crop Classification Algorithm and its Implications on Agricultural Water Use Assessments in California's Central Valley. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 8, p. 799-813, 2012. Disponível em: <<http://cat.inist.fr/?aModele=afficheN&cpsidt=26196709>>. Acesso em: 10 jan. 2017.

ZHONG, L.; GONG, P.; BIGING, G. S. Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery. **Remote Sensing of Environment**, v. 140, p. 1-13, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.08.023>>. Acesso em: 10 jan. 2017.

ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. S. Automated mapping of soybean and corn using phenology. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151-164, 2016a.

ZHONG, L.; YU, L.; LI, X.; HU, L.; GONG, P. Rapid corn and soybean mapping in US Corn Belt and neighboring areas. **Scientific Reports**, v. 6, p. 36240, 2016b. Disponível em: <<http://www.nature.com/articles/srep36240>>. Acesso em: 10 jan. 2017.

ZHU, L.; RADELOFF, V. C.; IVES, A. R. Improving the mapping of crop types in the Midwestern U.S. by fusing Landsat and MODIS satellite data. **International Journal of Applied Earth Observation and Geoinformation**, v. 58, n. February, p. 1-11, 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0303243417300120>>. Acesso em: 10 jan. 2017.

ZHU, X.; CHEN, J.; GAO, F.; CHEN, X.; MASEK, J. G. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. **Remote Sensing of Environment**, v. 114, n. 11, p. 2610-2623, 2010.

ZHU, X.; HELMER, E. H.; GAO, F.; LIU, D.; CHEN, J.; LEFSKY, M. A. A flexible spatiotemporal method for fusing satellite images with different resolutions. **Remote Sensing of Environment**, v. 172, p. 165-177, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2015.11.016>>. Acesso em: 10 jan. 2017.

ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v. 159, p. 269-277, 2015.

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, p. 83-94, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2011.10.028>>. Acesso em: 10 jan. 2017.

ZHUANG, X.; ZHAO, S.; LI, X.; CONG, D. Landsat and MODIS Data Fusion products based phenology analysis of dryland in Shan Dong province. In: 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), **Anais...IEEE**, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7729669/>>. Acesso em: 10 jan. 2017.

7 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

A utilização do sensoriamento remoto mostrou-se uma forma mais rápida e menos subjetiva de se obter informações das culturas agrícolas, tornando as estimativas e previsões de safras mais objetivas e com menor custo.

A utilização de métricas estatísticas extraídas da série temporal de NDVI demonstrou bons resultados para mapear culturas agrícolas anuais, separando-as de outros alvos. Outros índices, como o EVI, podem ser testados, assim como a utilização de série temporal derivadas de imagens sintéticas, o que pode melhorar a classificação/separação até mesmo de outros alvos, com o aumento de informação.

Os métodos de fusão espaço-temporal testados foram capazes de prever imagens condizentes com as mudanças temporais causados pelo desenvolvimento das culturas agrícolas em uma resolução espacial igual ao Landsat 8/OLI, a partir de imagens MODIS de 500 m (produto MCD43A4). Outros produtos, como o MOD13Q1/MYD13Q1, que possuem resolução espacial de 250m podem melhorar o resultado da predição. Porém, há necessidade de estudo de metodologias para melhorar o pré-processamento, pois estes produtos possuem maior variação no tempo do que o MCD43A4. Os resultados também mostram menores qualidade das imagens na banda do azul. Assim, também é interessante avaliar se índices de vegetação que não utilizam a banda do azul, com o EVI2 ou o WDRVI, e que não possuem problemas de saturação (como o NDVI) podem melhorar a qualidade do mapeamento de soja e milho.

Com o lançamento do Sentinel 2, há novas possibilidades de gerar séries temporais a média resolução espacial (10 a 30 m), integrando Landsat com Sentinel (QUINTANO; FERNÁNDEZ-MANSO; FERNÁNDEZ-MANSO, 2018), ou mesmo realizando fusão entre Sentinel 2 e Sentinel 3 (WANG; ATKINSON, 2018), podendo gerar séries temporais mais densas, melhorando o mapeamento de culturas agrícolas.

As métricas fenológicas também podem ser utilizadas a média resolução espacial para a segunda safra e inverno. Ainda é necessário melhorar o desempenho dos processamentos e a automatização, para realizar os mapeamentos a nível estadual ou nacional.

APÉNDICE A

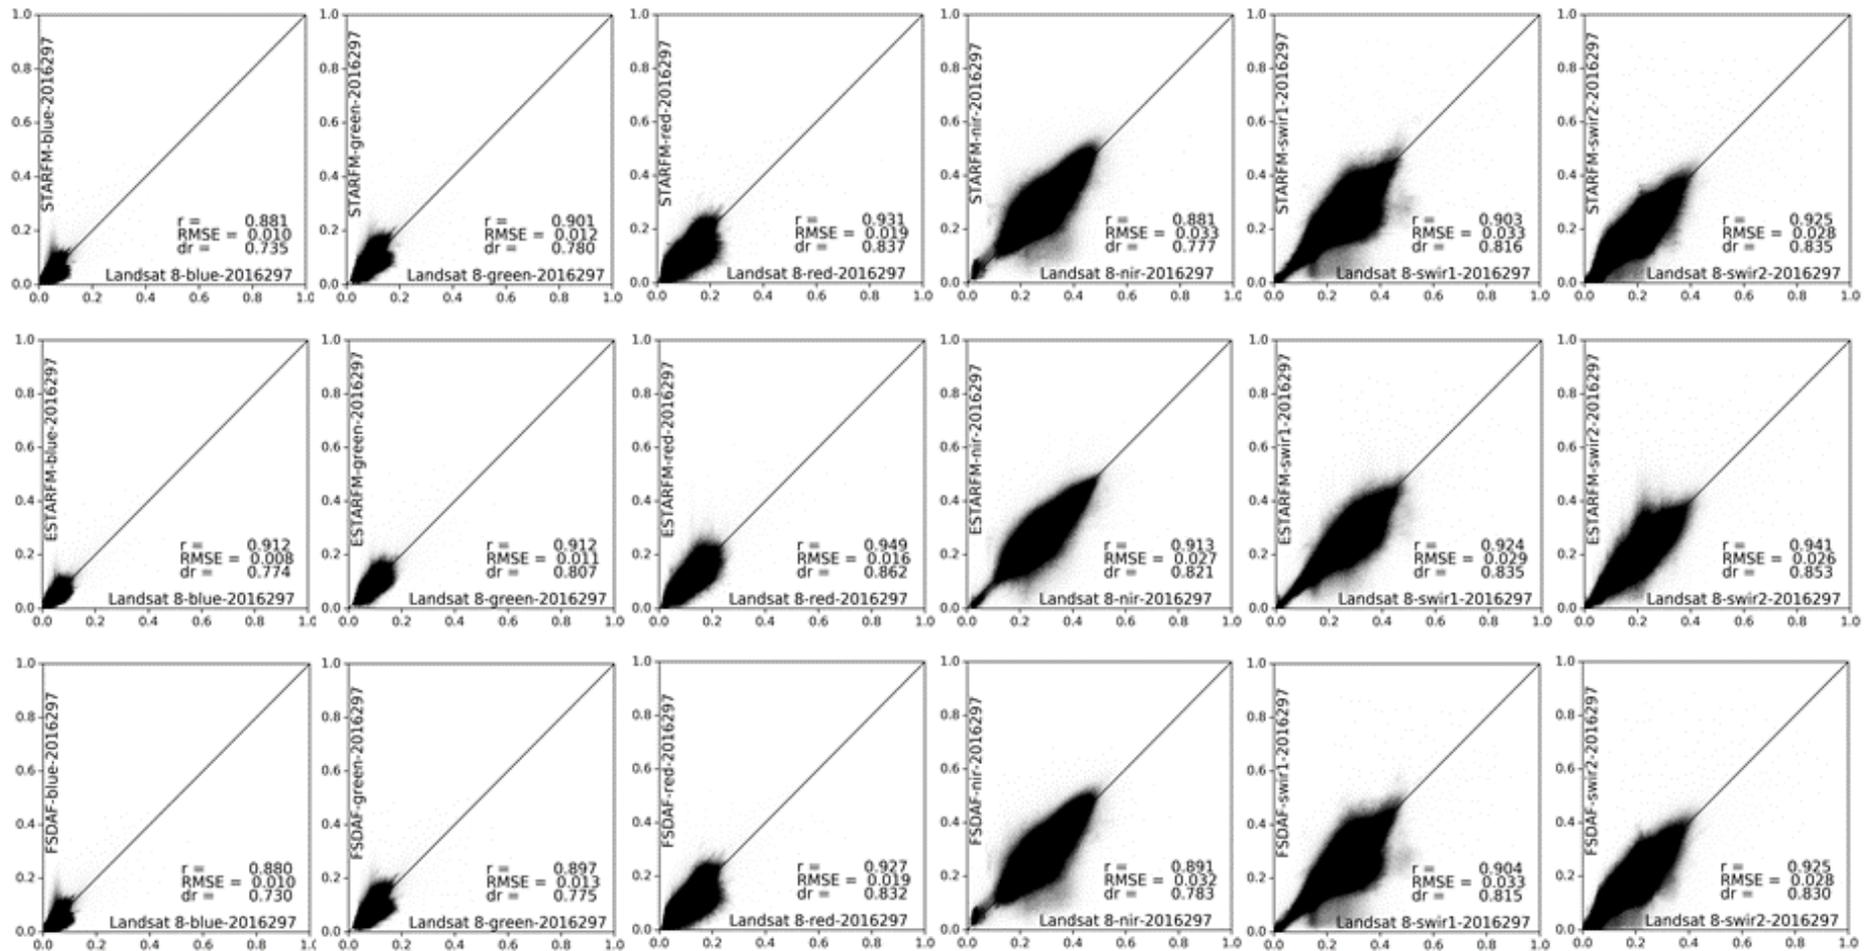


Figura 19 Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 297/2016 com a Imagem Landsat 8.

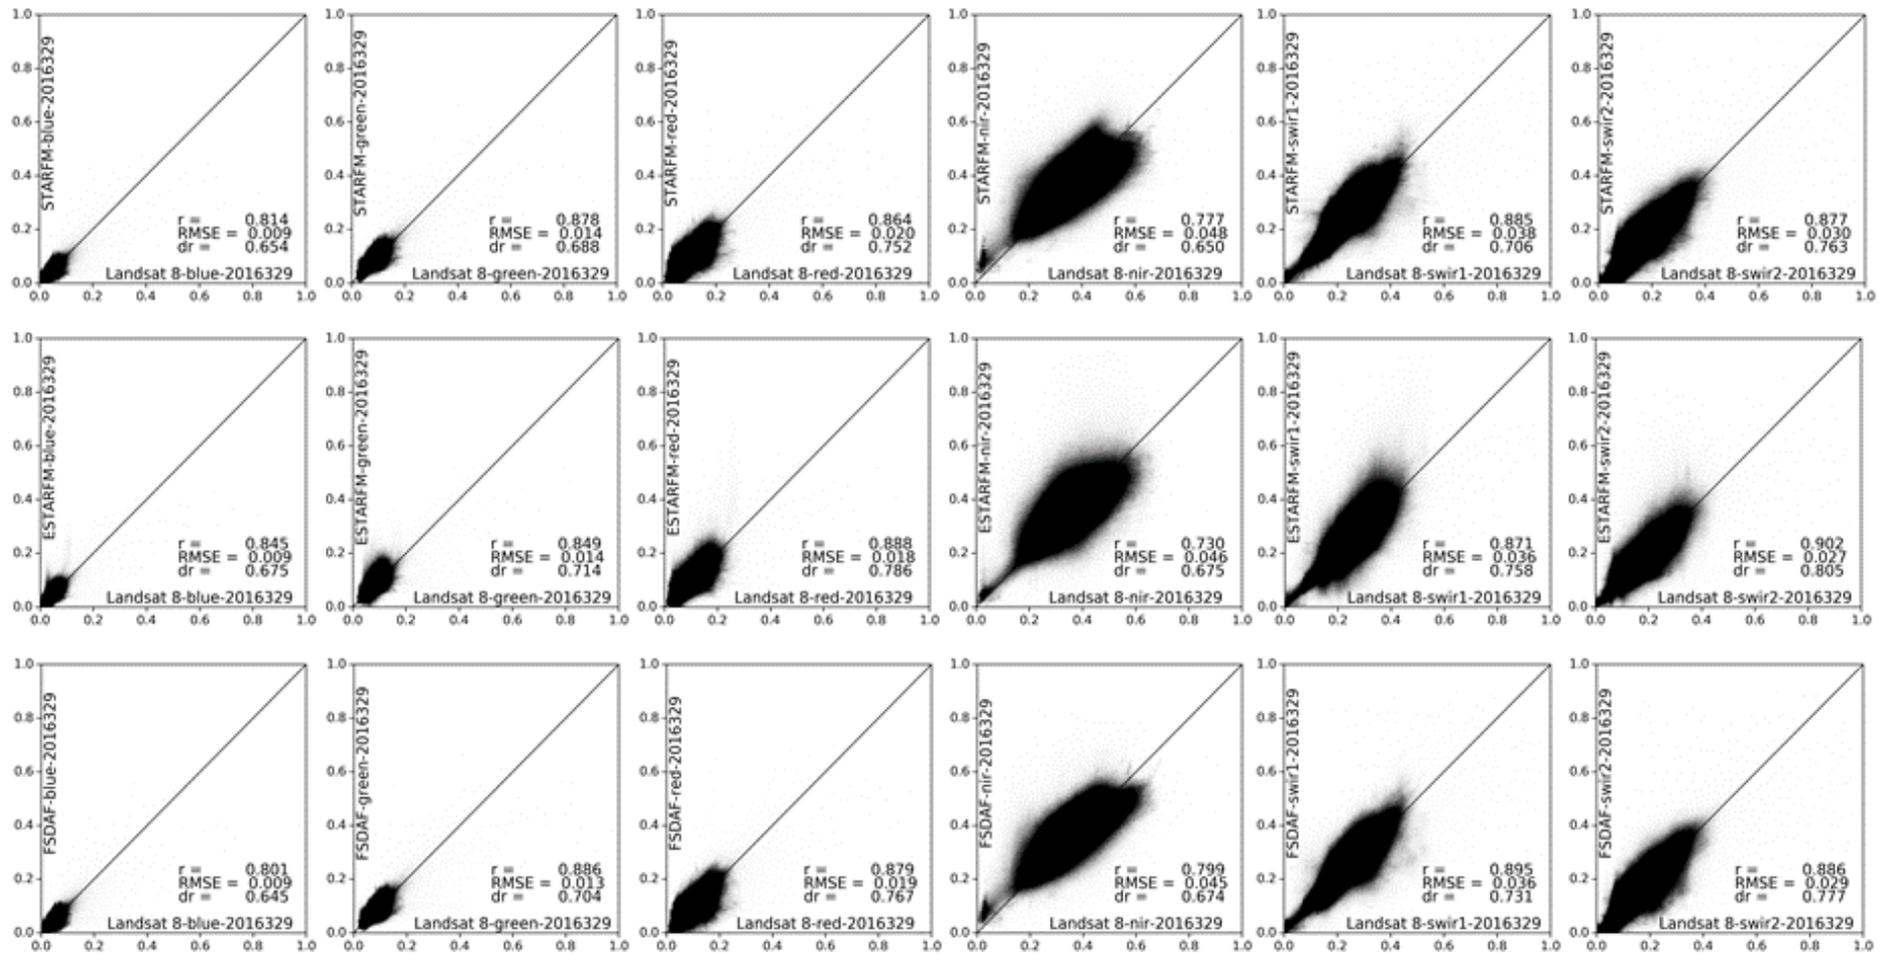


Figura 20 Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 329/2016 com a Imagem Landsat 8.

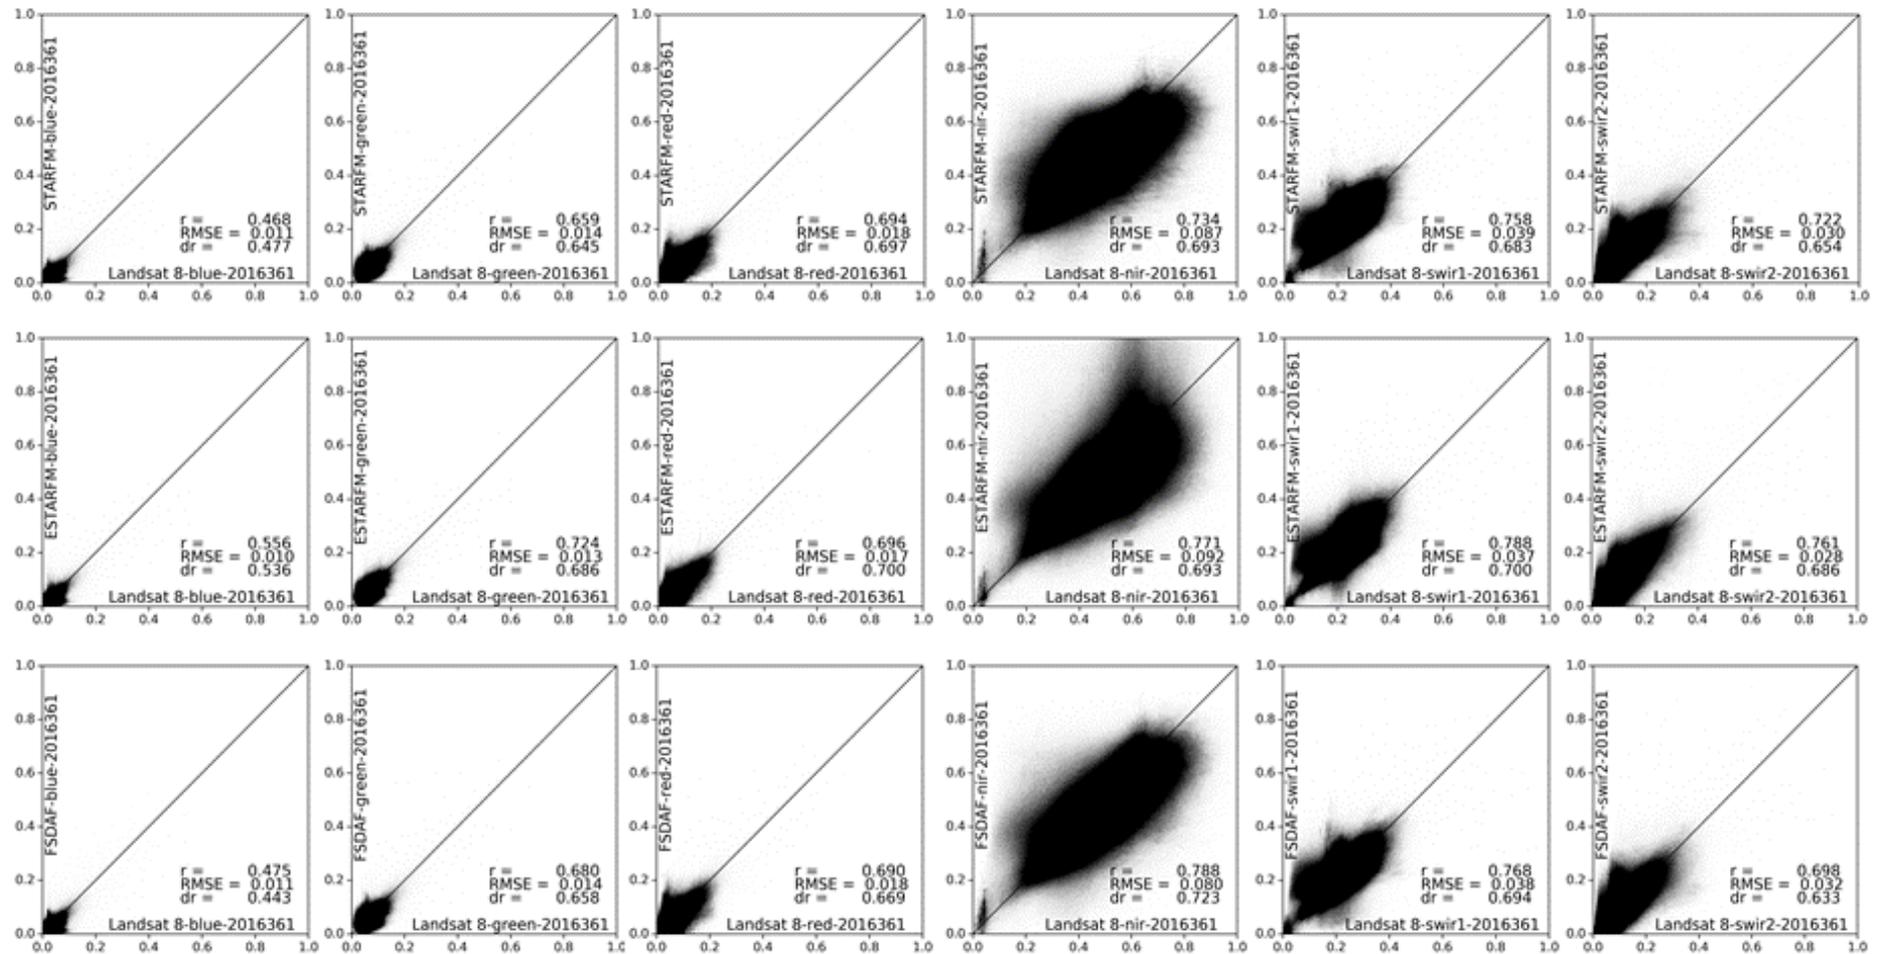


Figura 21 Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 361/2016 com a Imagem Landsat 8.

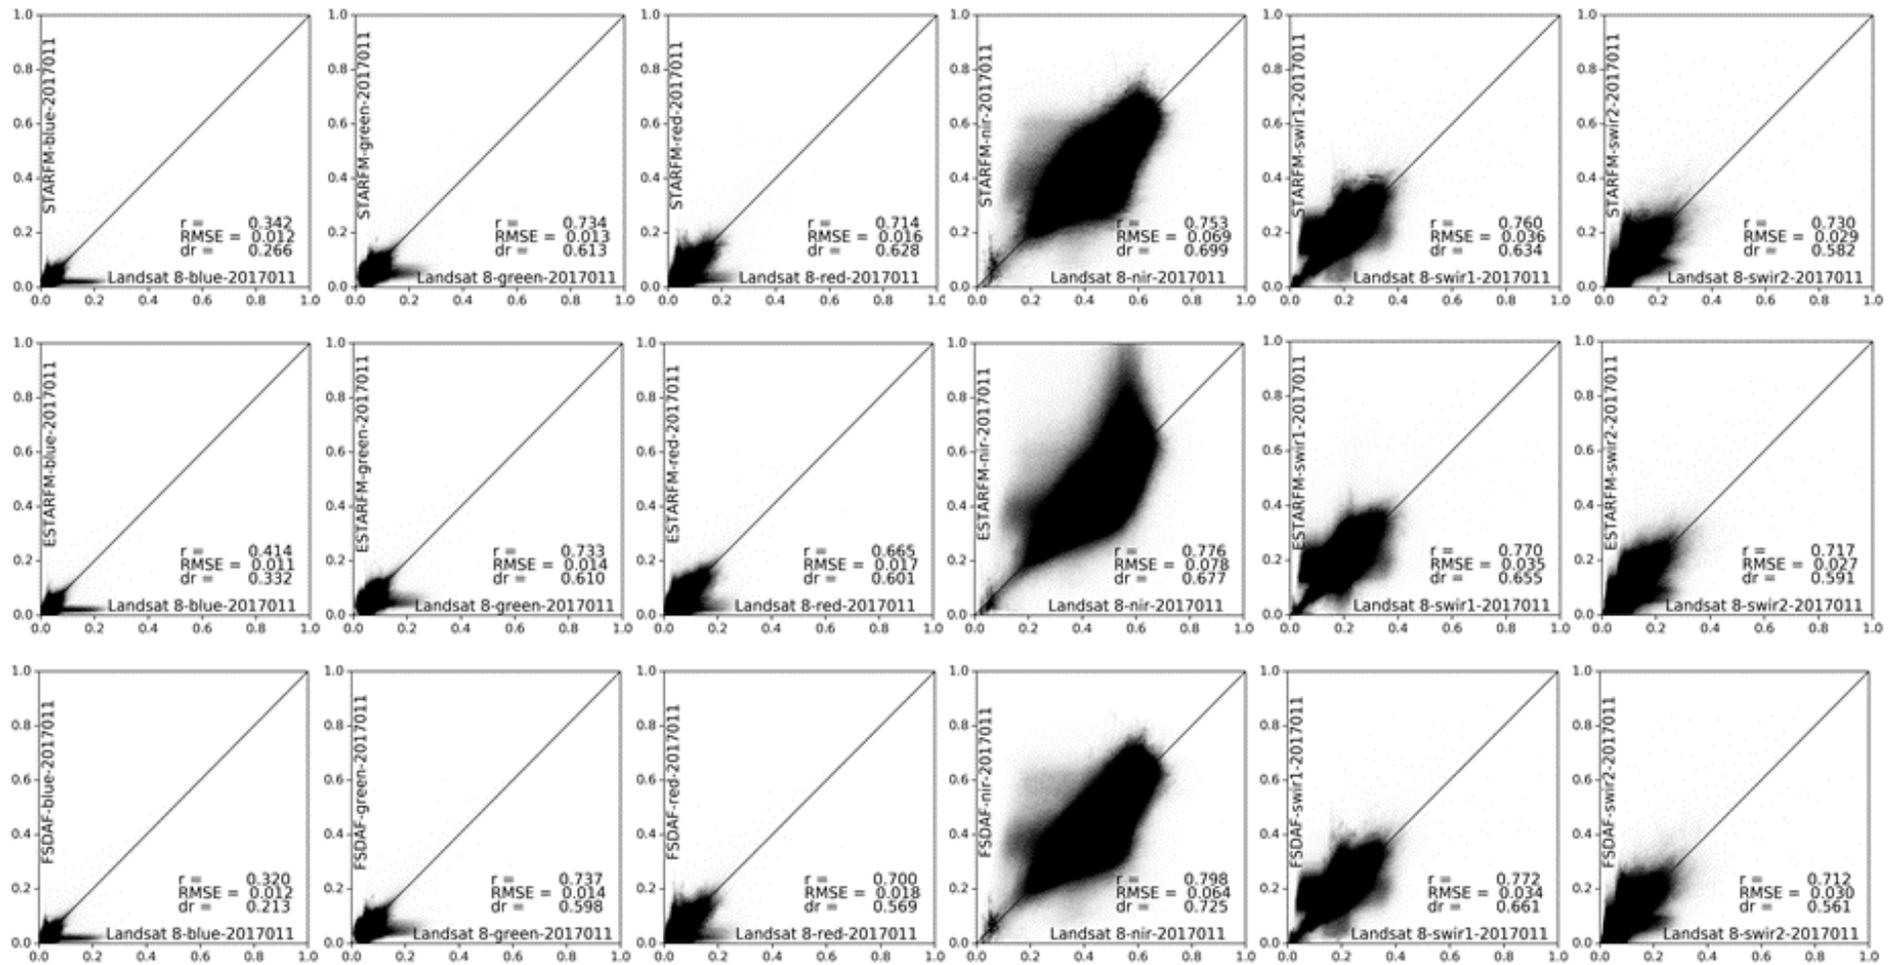


Figura 22 Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 01/2017 com a Imagem Landsat 8.

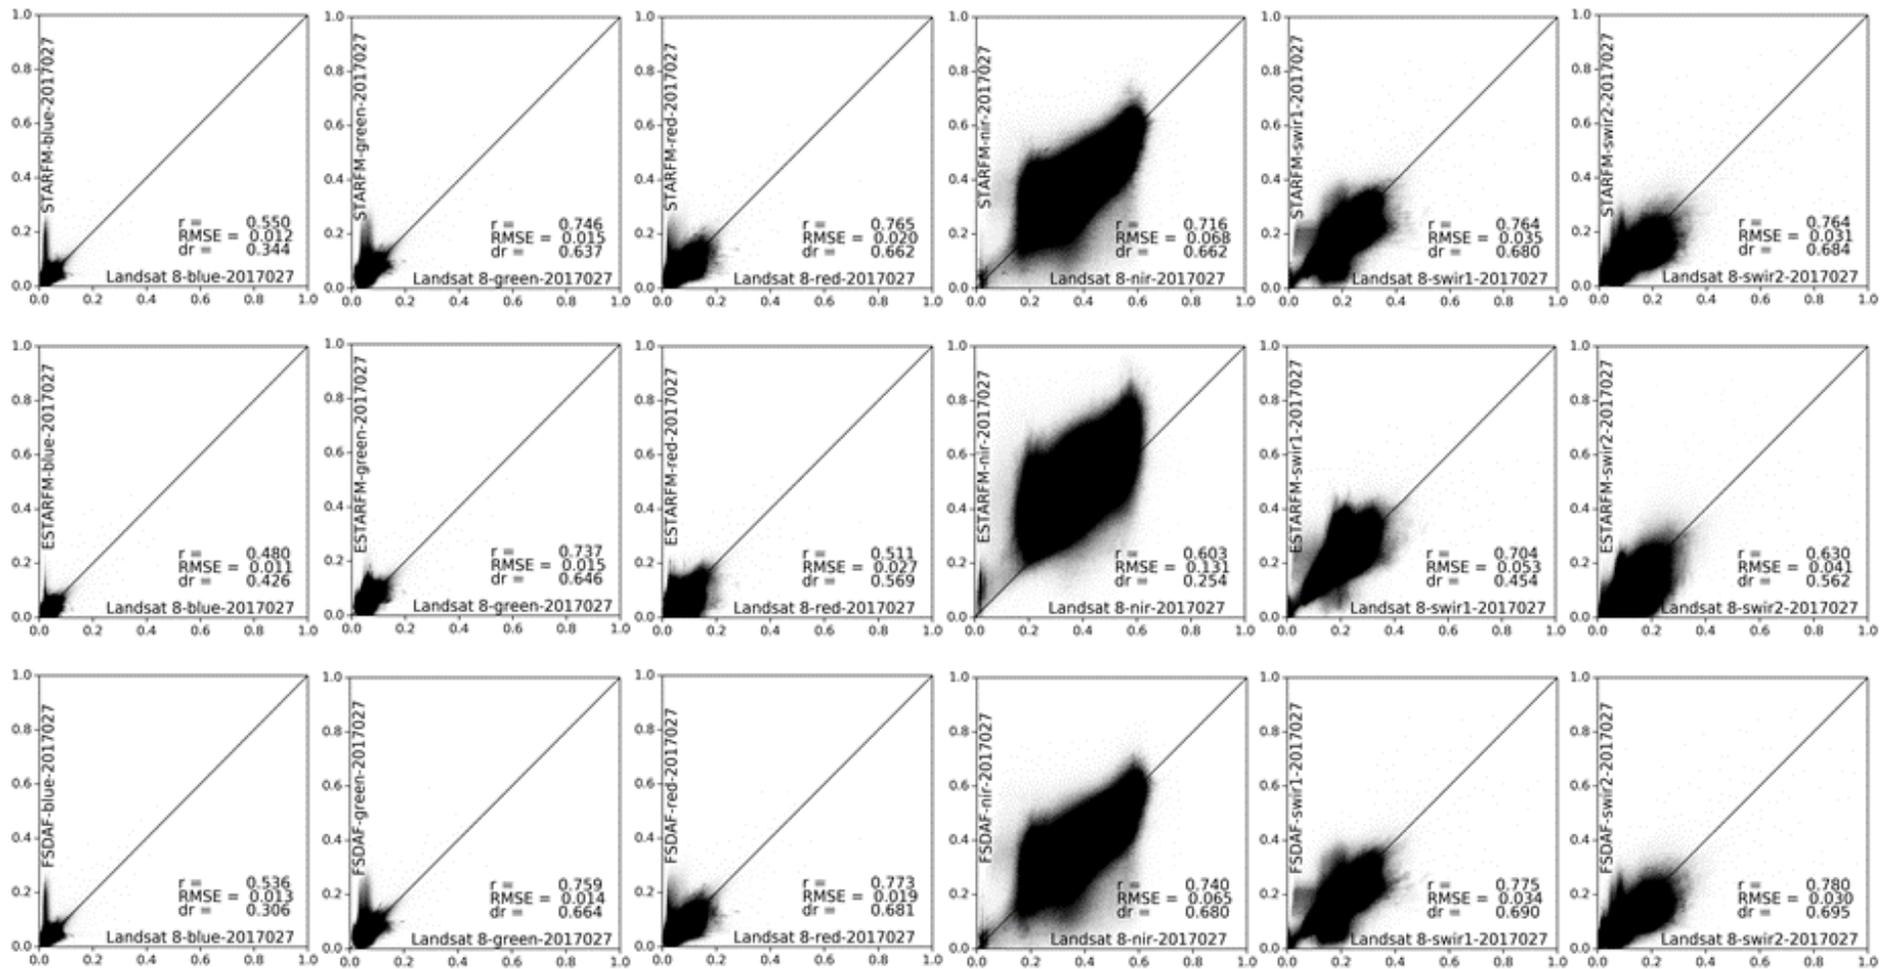


Figura 23 Gráficos de dispersão das imagens sintéticas geradas pelo STARFM, ESTARFM e FSDAF do dia 027/2017 com a Imagem Landsat 8.

APÉNDICE B

Tabela 13 Matriz de erros para todos os cenários de classificação

		Referência	Classificação			
			Milho	Outros	Soja	Total
	Cenário 1	Milho	267	27	6	300
		Outros	50	249	1	300
		Soja	9	29	262	300
		Total	326	305	269	778
	Cenário 2	Milho	147	150	3	300
		Outros	28	225	47	300
		Soja	7	13	280	300
		Total	182	388	330	652
	Cenário 3	Milho	232	65	3	300
		Outros	2	253	45	300
		Soja	10	34	256	300
		Total	244	352	304	741
STARFM	Cenário 4	Milho	241	5	54	300
		Outros	2	291	7	300
		Soja	6	4	290	300
		Total	249	300	351	822
	Cenário 5	Milho	234	9	57	300
		Outros	5	293	2	300
		Soja	40	13	247	300
		Total	279	315	306	774
	Cenário 3	Milho	215	78	7	300
		Outros	1	251	48	300
		Soja	35	36	229	300
		Total	251	365	284	695
ESTARFM	Cenário 4	Milho	240	12	48	300
		Outros	2	294	4	300
		Soja	36	9	255	300
		Total	278	315	307	789
	Cenário 5	Milho	201	10	89	300
		Outros	4	294	2	300
		Soja	119	16	165	300
		Total	324	320	256	660
	Cenário 3	Milho	230	66	4	300
		Outros	5	247	48	300
		Soja	23	17	260	300
		Total	258	330	312	737
FSDAF	Cenário 4	Milho	258	3	39	300
		Outros	3	291	6	300
		Soja	8	3	289	300
		Total	269	297	334	838
	Cenário 5	Milho	239	11	50	300
		Outros	8	288	4	300
		Soja	50	14	236	300
		Total	297	313	290	763

APÉNDICE C

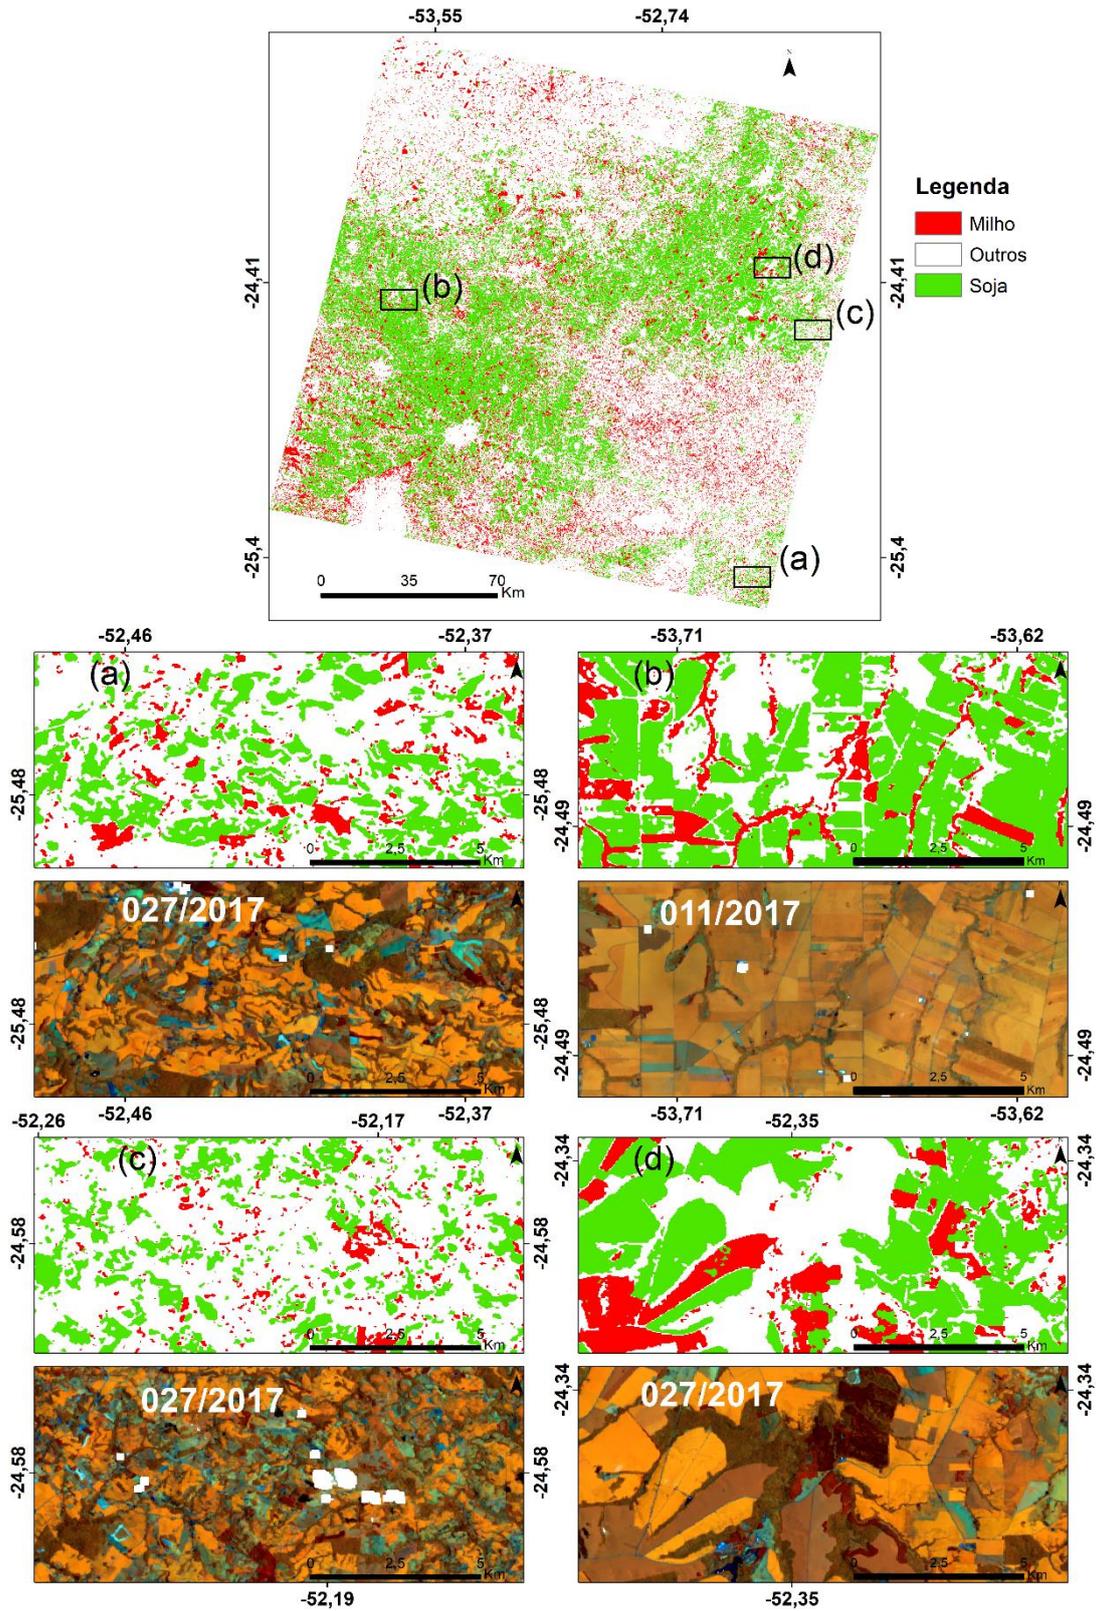


Figura 24 Resultado da classificação para o cenário 1 com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

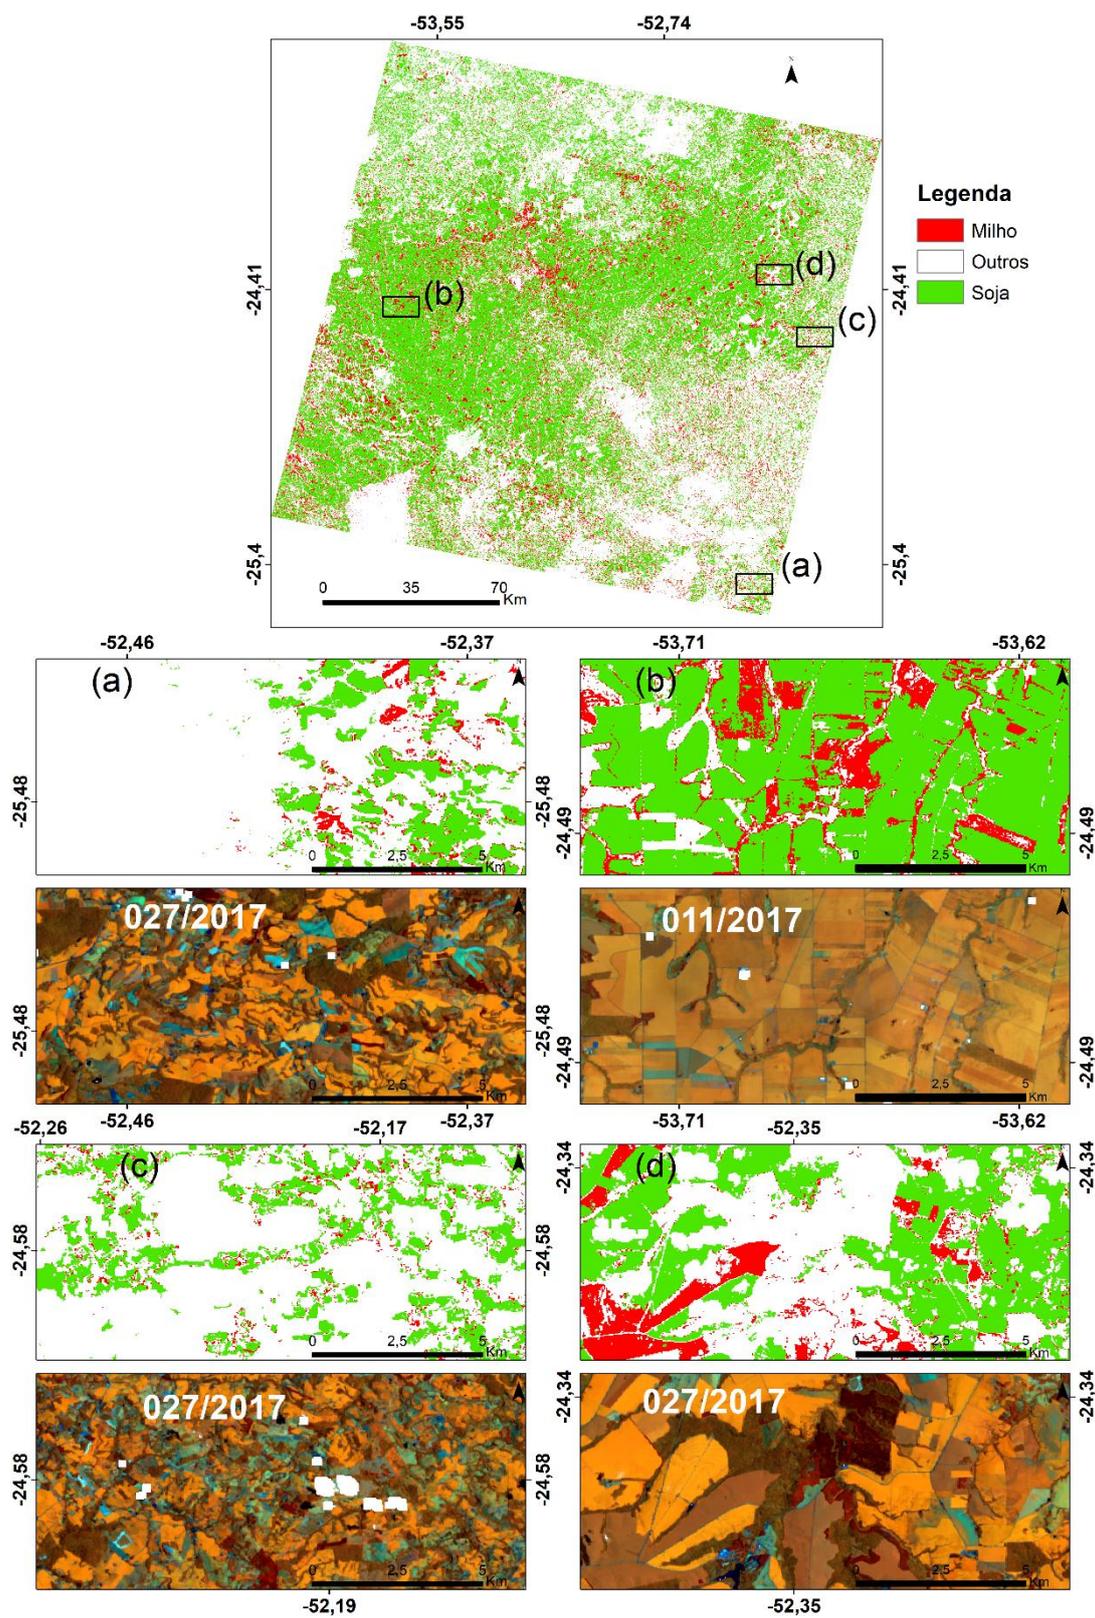


Figura 25 Resultado para o cenário 2 com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

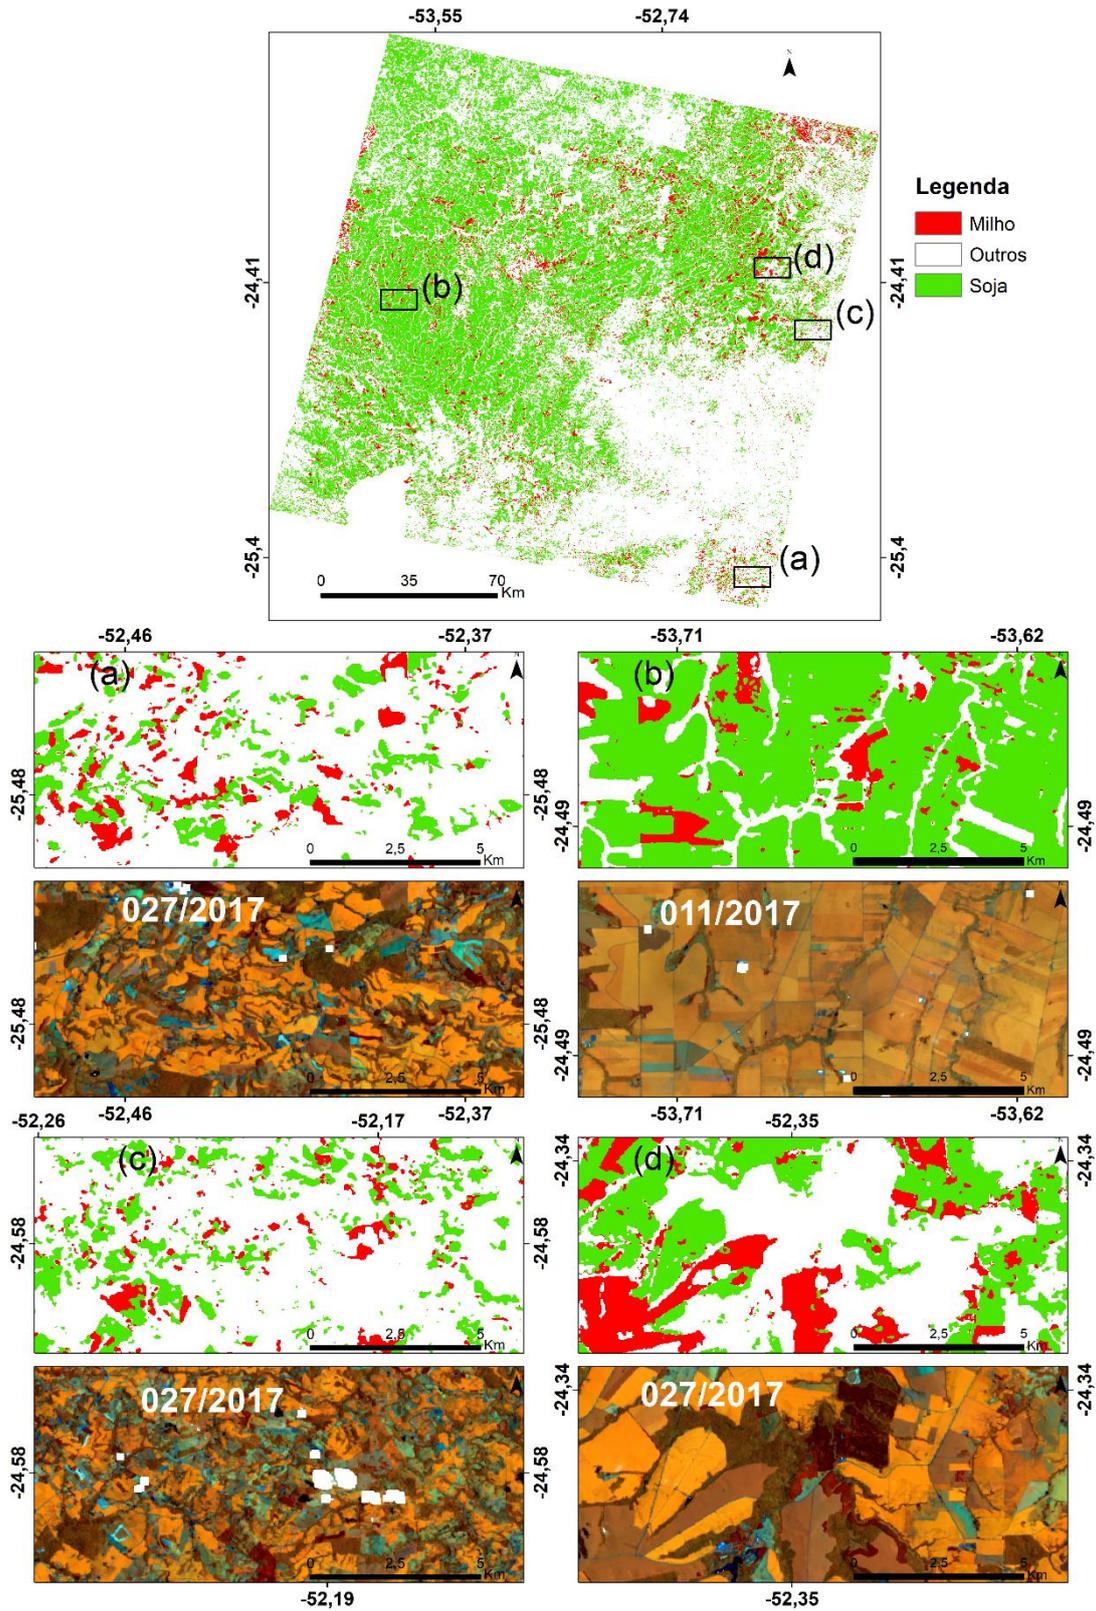


Figura 26 Resultado da classificação para o cenário 3 utilizando o STARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

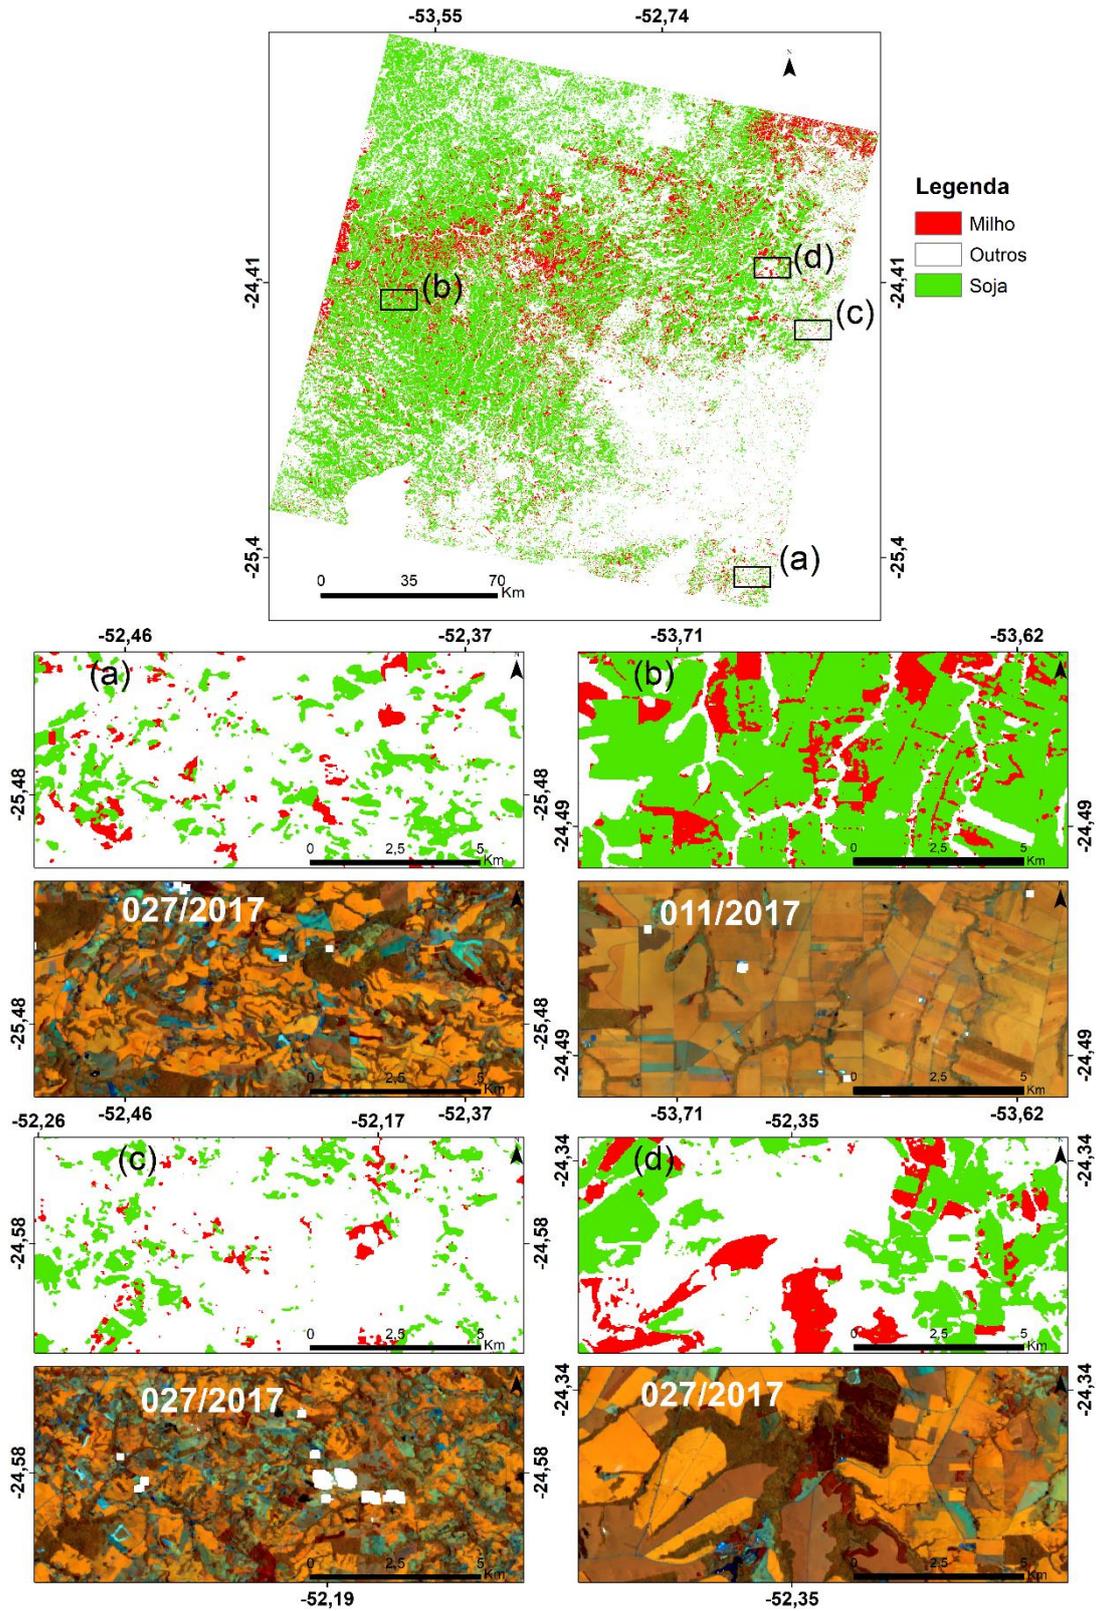


Figura 27 Resultado da classificação para o cenário 3 utilizando o ESTARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

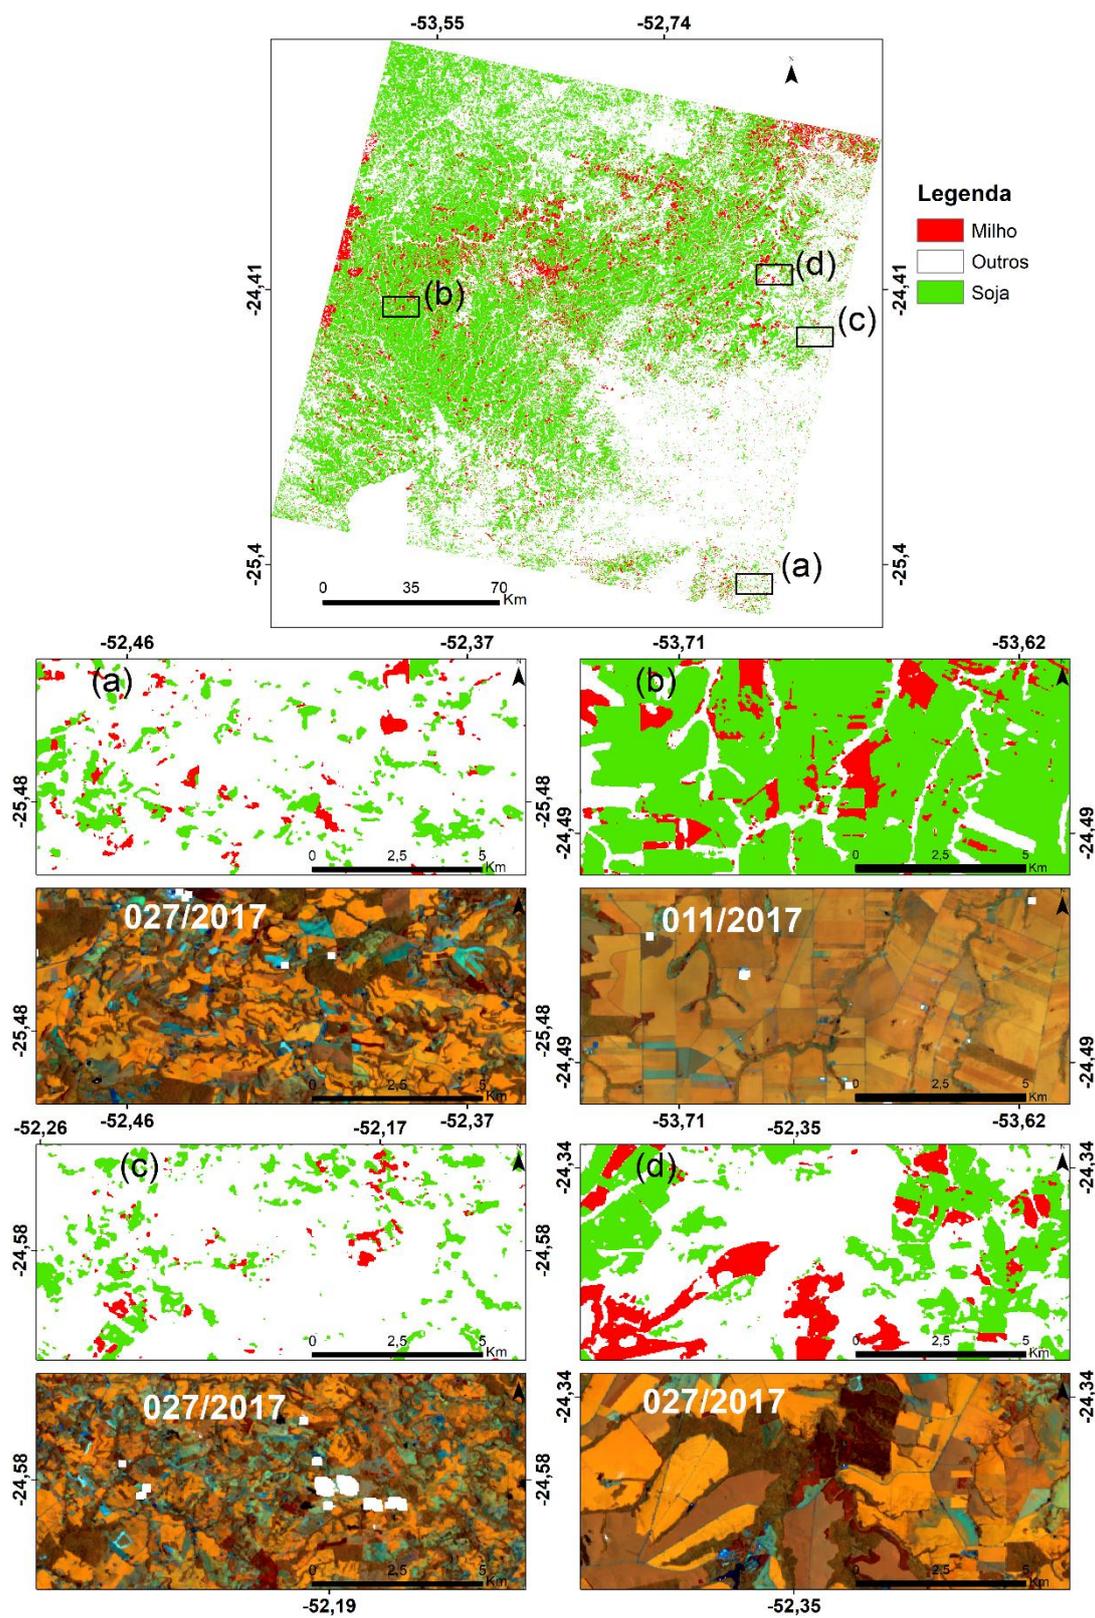


Figura 28 Resultado da classificação para o cenário 3 utilizando o FSDAF com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

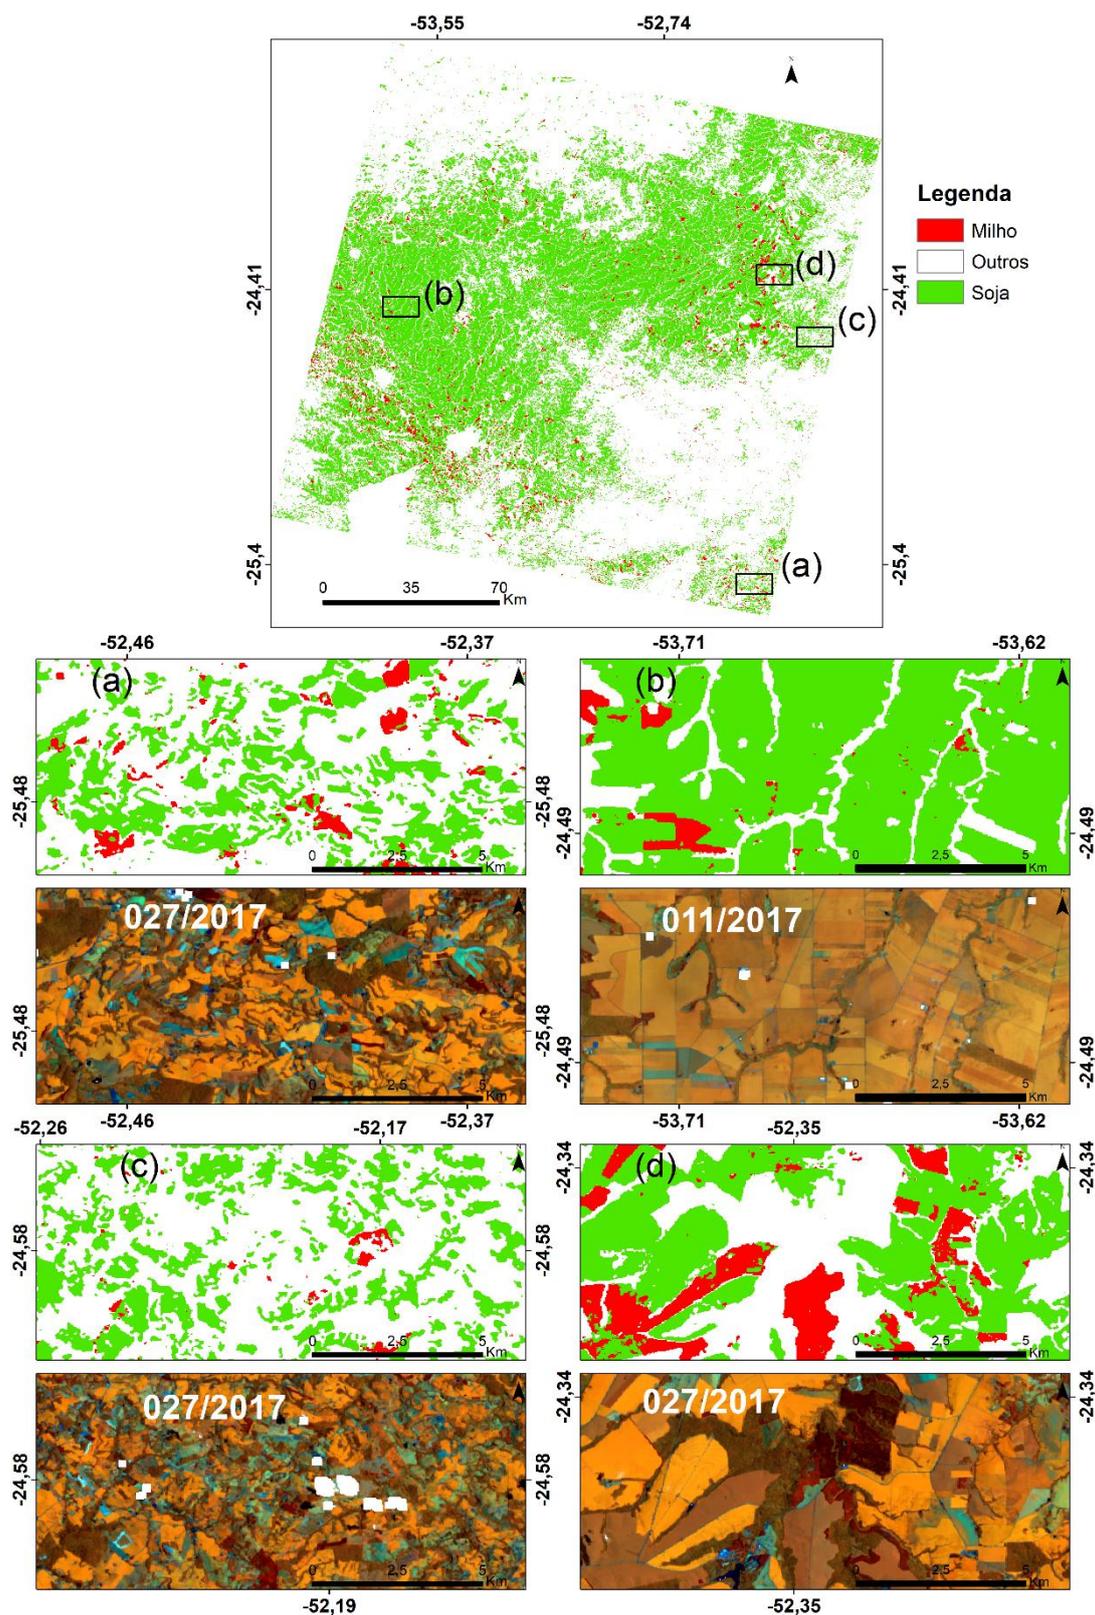


Figura 29 Resultado da classificação para o cenário 4 utilizando o STARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

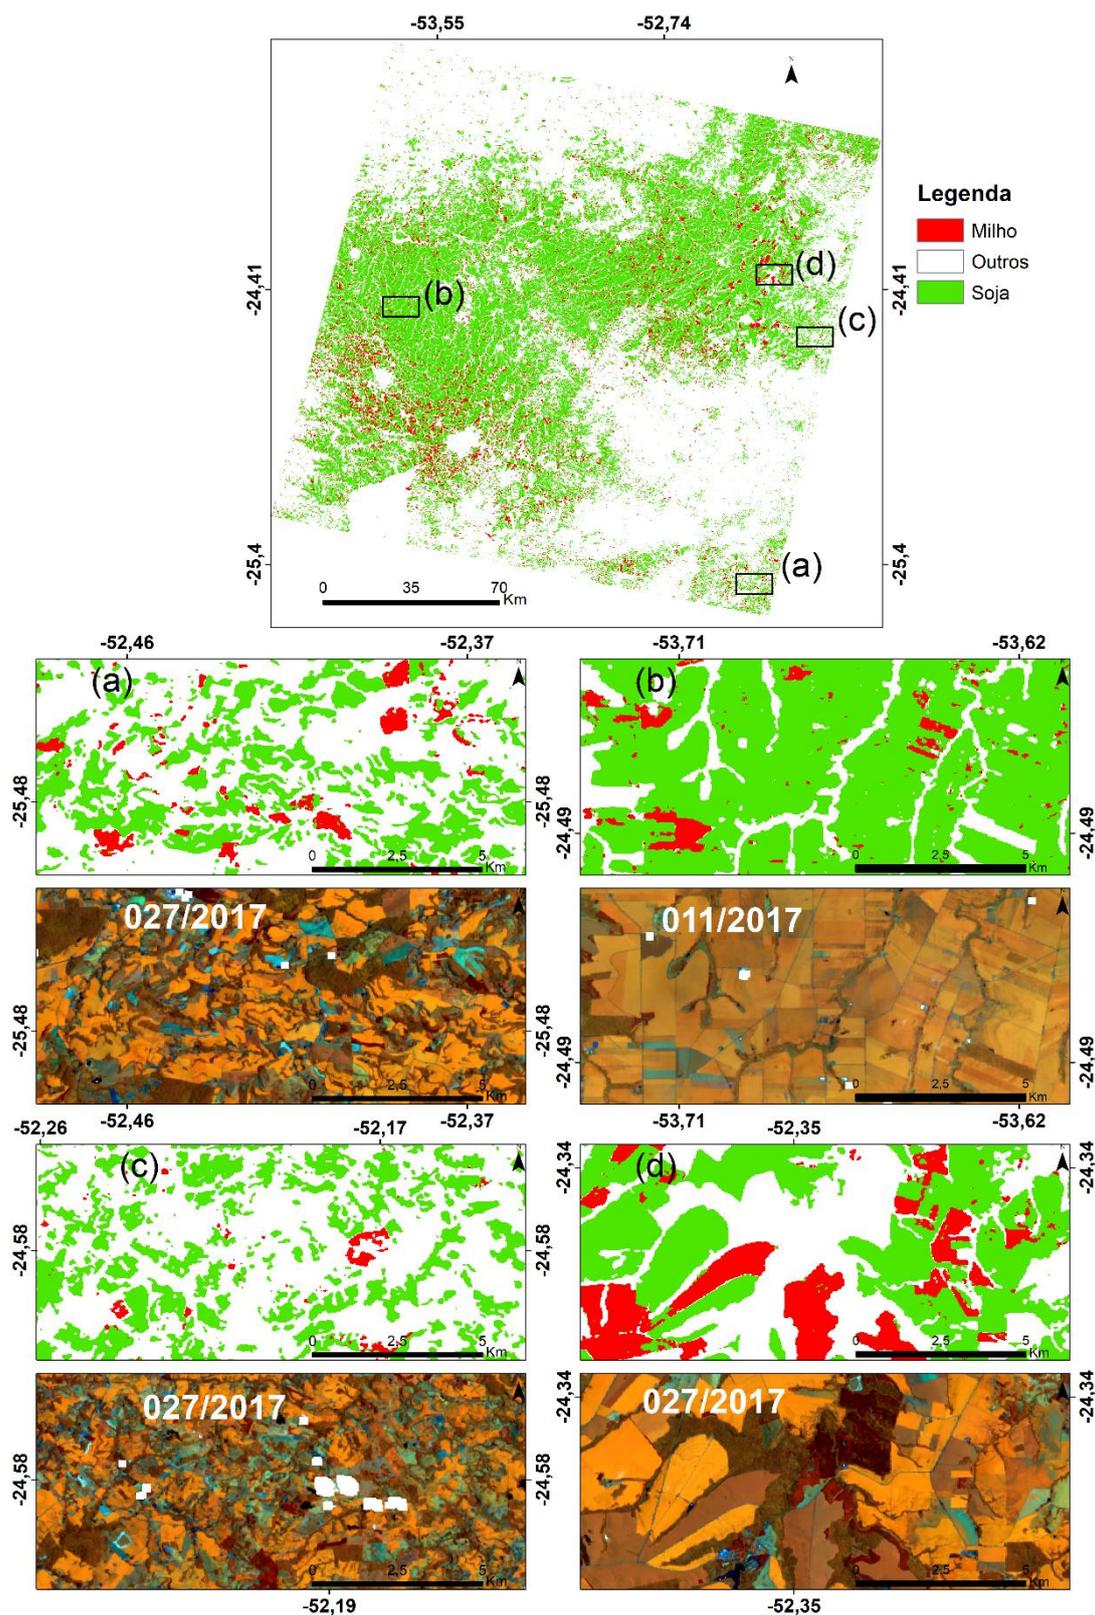


Figura 30 Resultado da classificação para o cenário 4 utilizando o ESTARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

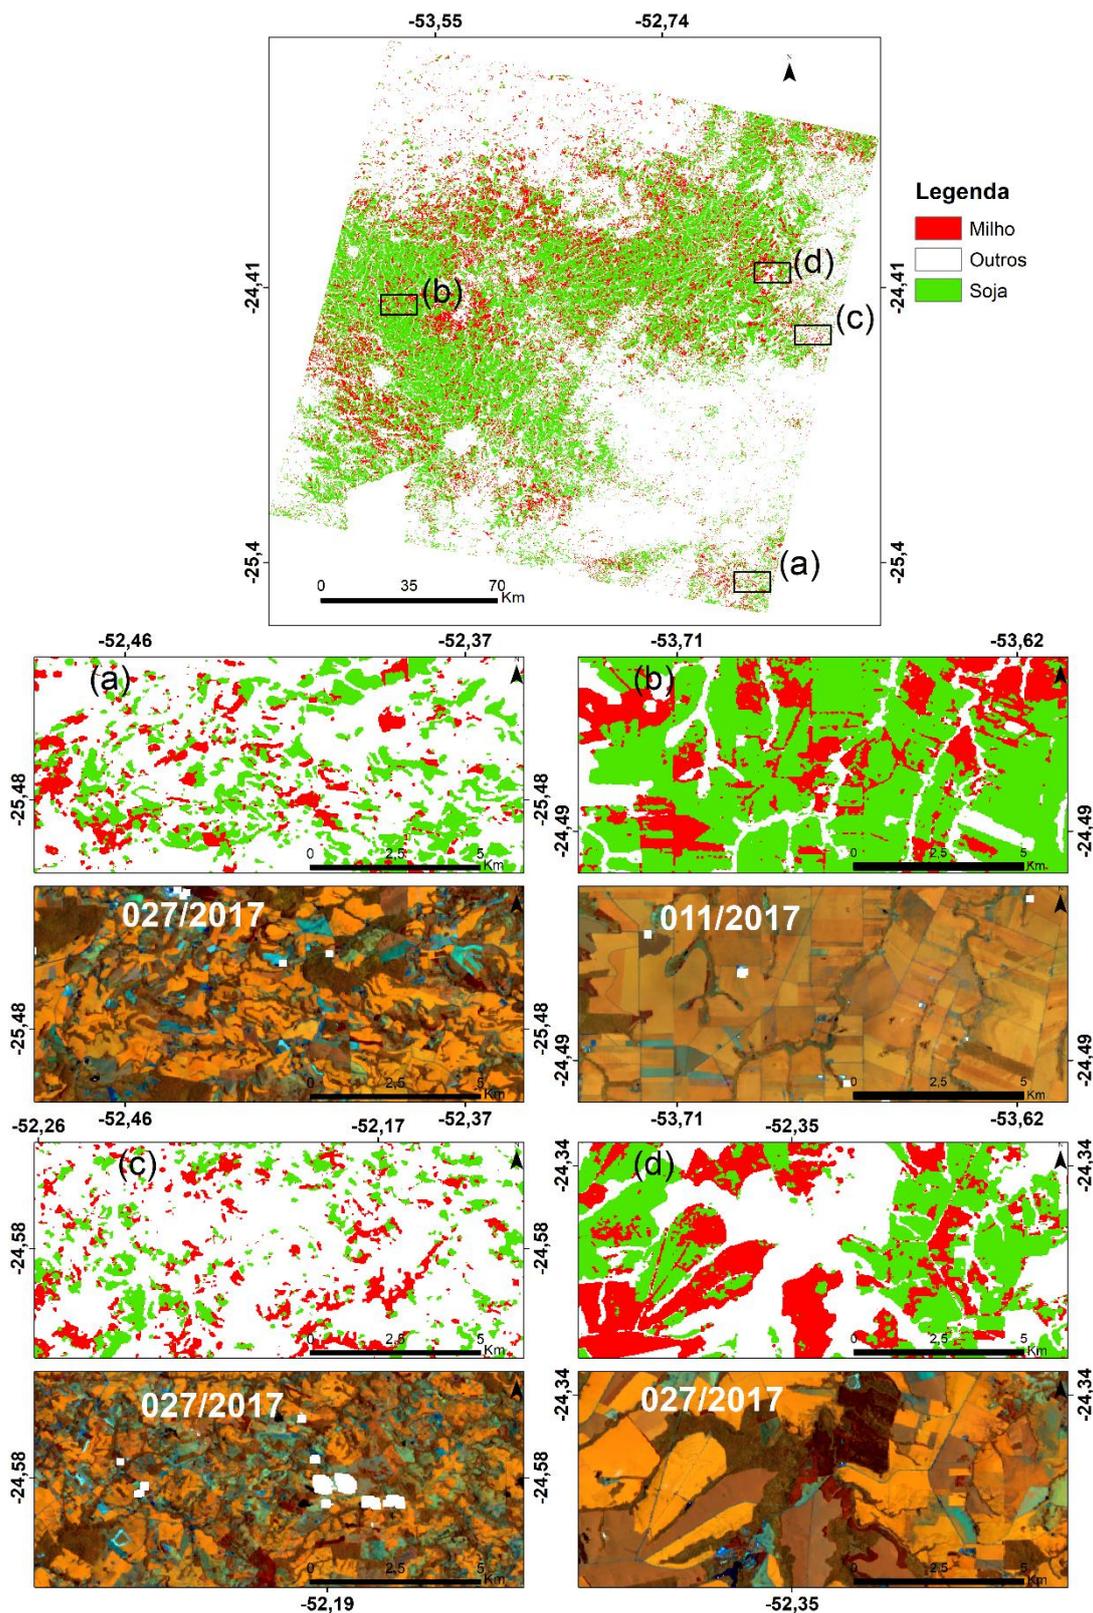


Figura 31 Resultado da classificação para o cenário 5 utilizando o STARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

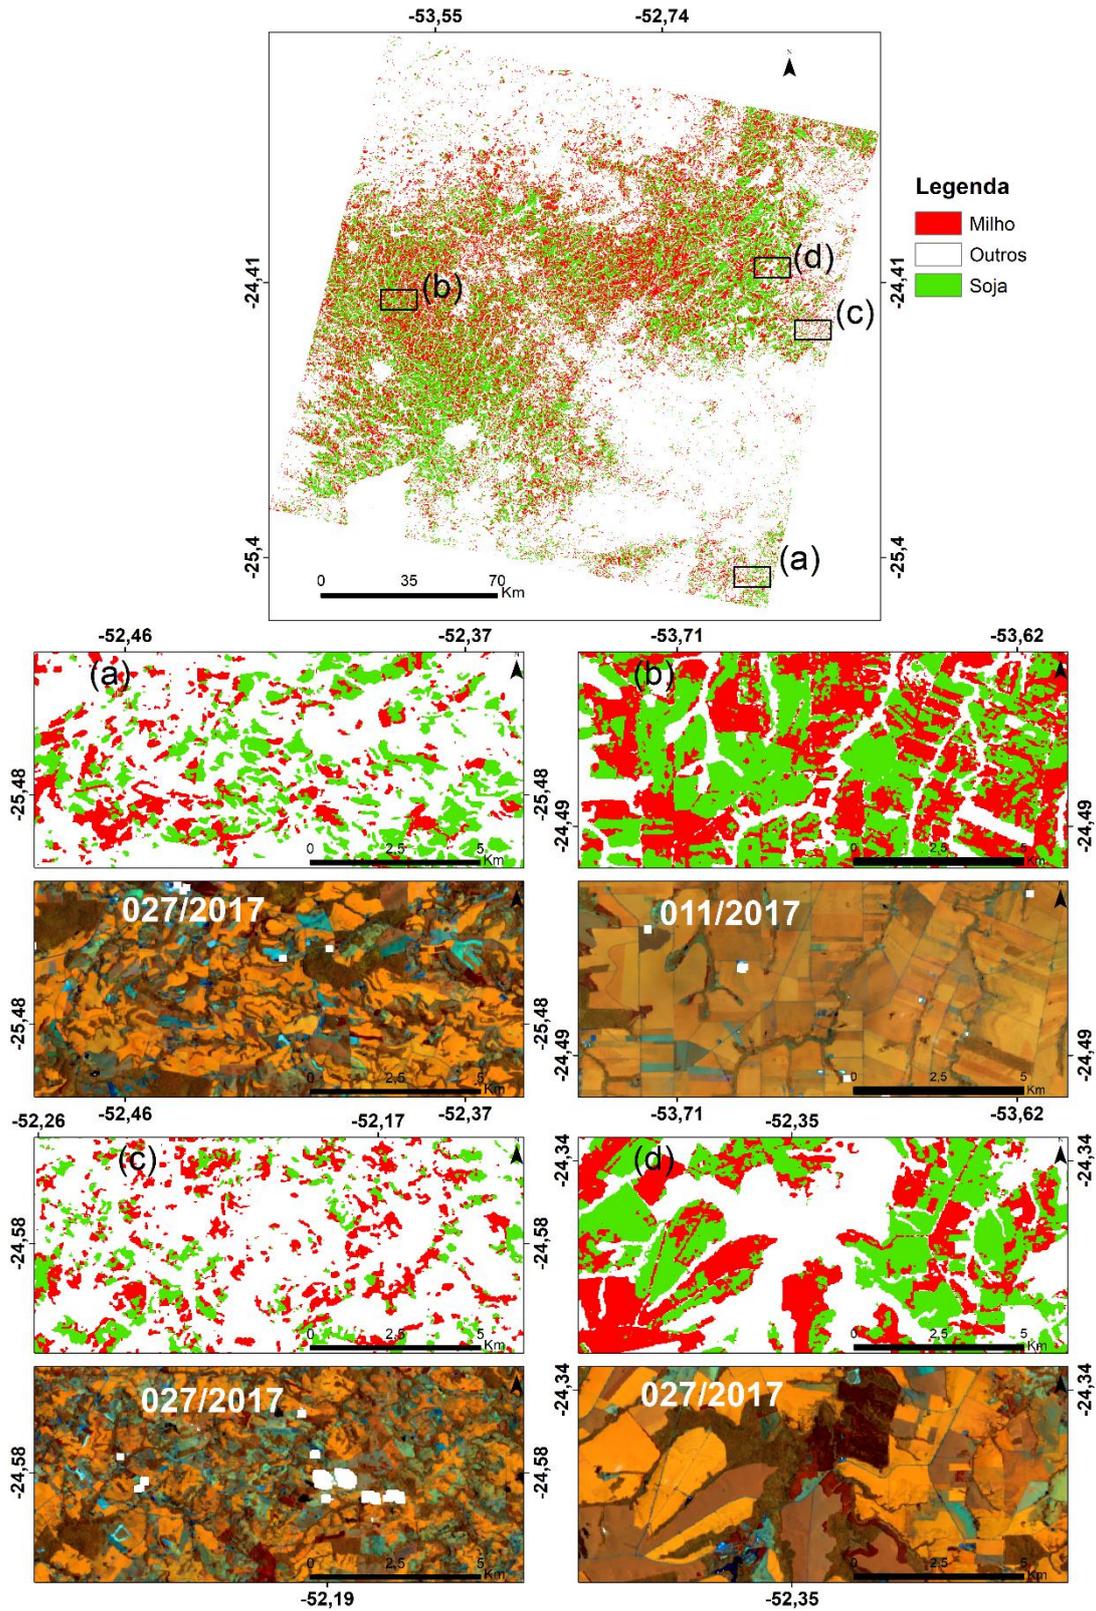


Figura 32 Resultado da classificação para o cenário 5 utilizando o ESTARFM com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).

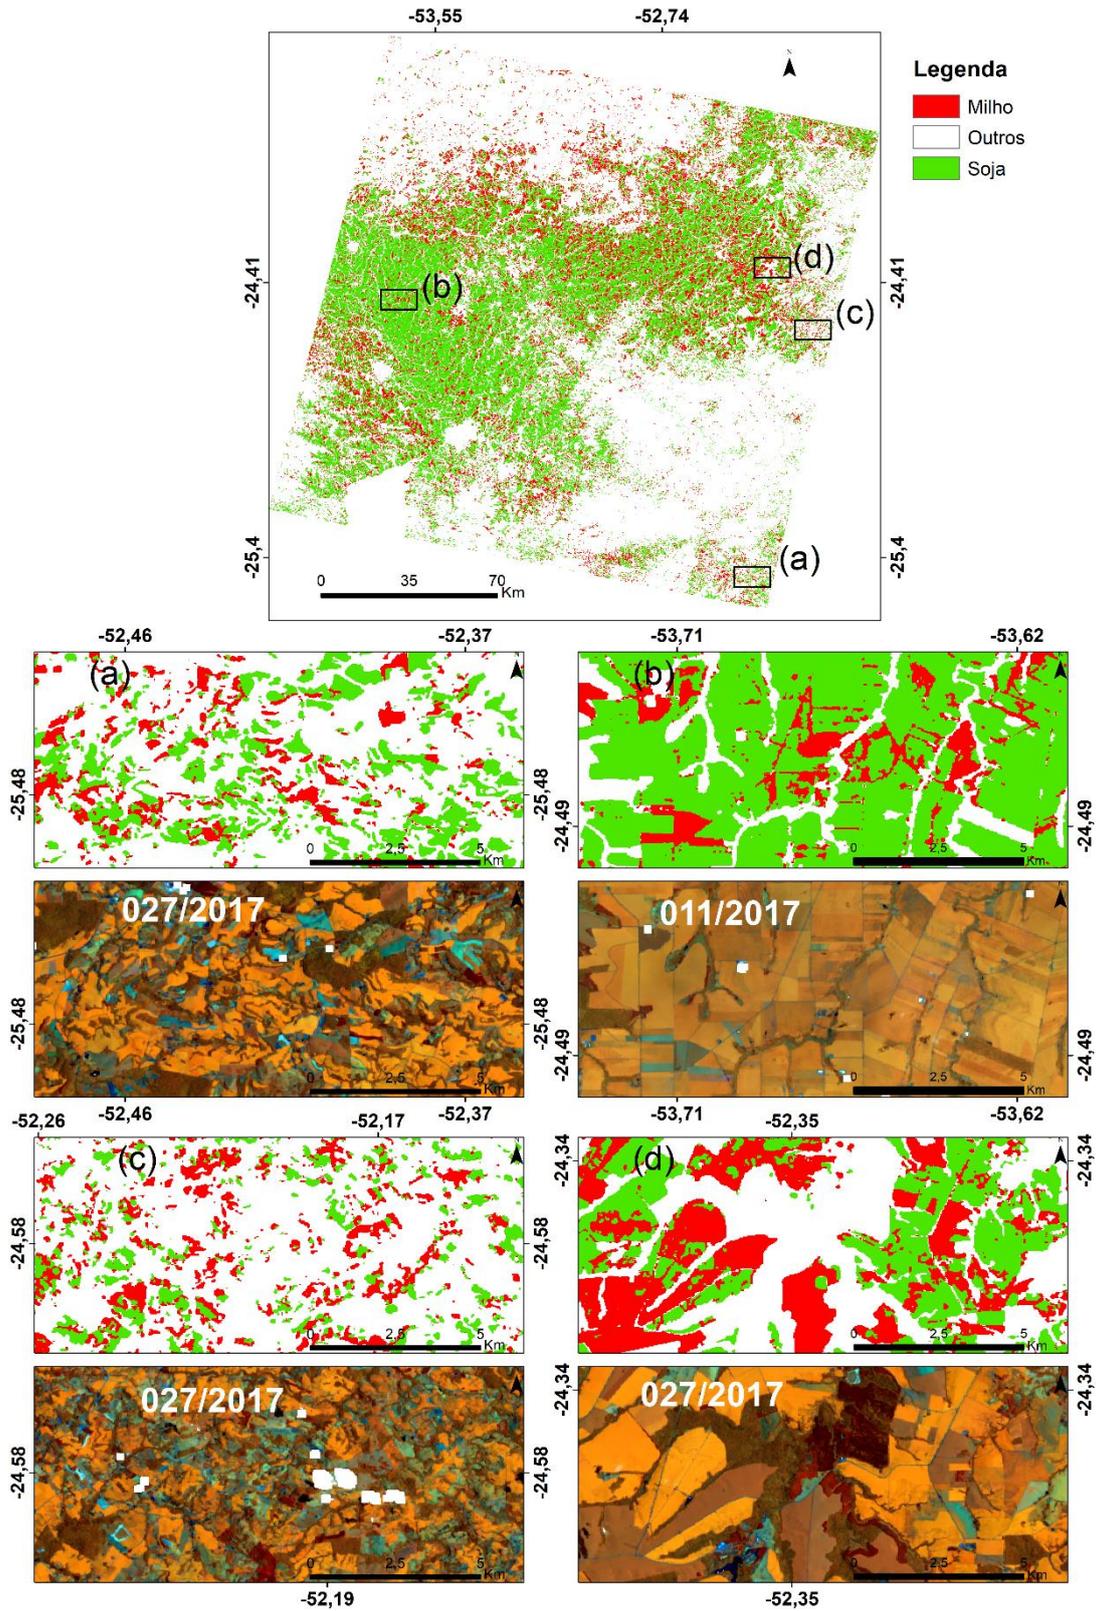


Figura 33 Resultado da classificação para o cenário 5 utilizando o FSDAF com detalhes de algumas regiões com talhões pequenos (a e c) e grandes (b e d).