



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA  
LABORATÓRIO DE SISTEMAS DE INFORMAÇÕES ESPACIAIS

**USO DE SÉRIES TEMPORAIS SENTINEL 1 NA IDENTIFICAÇÃO DE  
CULTURAS AGRÍCOLAS UTILIZANDO MODELOS DE MACHINE  
LEARNING**

**DIANDRA HOFFMANN COSTA**

**DISSERTAÇÃO DE MESTRADO**

Brasília - DF  
Março de 2020

UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA  
LABORATÓRIO DE SISTEMAS DE INFORMAÇÕES ESPACIAIS

**USO DE SÉRIES TEMPORAIS SENTINEL 1 NA IDENTIFICAÇÃO DE  
CULTURAS AGRÍCOLAS UTILIZANDO MODELOS DE MACHINE  
LEARNING**

**DIANDRA HOFFMANN COSTA**

Orientador:

Prof. Dr. Roberto Arnaldo Trancoso Gomes

Coorientador:

Prof. Dr. Osmar Abílio de Carvalho Junior

**DISSERTAÇÃO DE MESTRADO**

Brasília - DF  
Março de 2020

UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA  
LABORATÓRIO DE SISTEMAS DE INFORMAÇÕES ESPACIAIS

## **USO DE SÉRIES TEMPORAIS SENTINEL 1 NA IDENTIFICAÇÃO DE CULTURAS AGRÍCOLAS UTILIZANDO MODELOS DE MACHINE LEARNING**

**DIANDRA HOFFMANN COSTA**

Dissertação de Mestrado apresentada ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários à obtenção do Grau de Mestre em Geografia. Área de concentração Gestão Ambiental e Territorial. Linha de Pesquisa em Geoprocessamento.

**Aprovado por:**

---

Prof. Dr. Roberto Arnaldo Trancoso Gomes (PÓS-GEA/UNB)  
(Orientador)

---

Osmar Abílio de Carvalho Junior (PÓS-GEA/UNB)  
(Coorientador)

---

Prof. Dr. Potira Meirelles Hermuche (CDS/UNB)  
(Examinadora Externa)

---

Prof. Dr. José Yure Gomes dos Santos (UFRN)  
(Examinador Externo)

Brasília - DF, 03 de março de 2020.

COSTA, DIANDRA HOFFMANN COSTA

Uso de Séries Temporais Sentinel 1 na identificação de Culturas Agrícolas Utilizando Modelos de Machine Learning, 51 p., (UnB-CDS, Mestre, Gestão Ambiental e Territorial, 2020).

Dissertação de Mestrado – Universidade de Brasília. Instituto de Humanas, Departamento de Geografia.

1. Sentinel -1

2. SAR

3. Tipos de Cultura

4. Machine Learning

I. UnB-CDS

II. Título (série)

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

---

Nome do Autor

Aos meus pais, João e Claudete e ao meu mestre, Flávio.

## AGRADECIMENTOS

Ao autor da vida, grande responsável por esta busca incessante de saberes, meus singelos agradecimentos. A Ele toda a glória.

Aos meus pais João e Claudete por permitirem que eu fosse em busca dos meus ideais, por todo amor, confiança, paciência, concebido a mim, sempre me apoiando e me encorajando nas decisões e por se manterem firmes em suas orações.

Aos meus avós e avôs, *in memóriam* aos meus eternos anjos, vó Leonilda, vô Carlos e vô Crescêncio, por terem me ensinado o significado do amor verdadeiro e a compreender que sou capaz de tudo aquilo que Deus planejou para mim e ao grande e majestoso “Mestre”, tio Flavio, que a pouco nos deixou, muito obrigada por cada ensinamento, seguirei fielmente vossas orientações aqui na terra.

De modo especial agradeço a minha amiga Jomary, peça fundamental nesta caminhada, cuidando de mim, segurando minha mão nos momentos de dor, angústias, tristezas, inseguranças, saudades de casa e alegrias. Obrigada por ter aberto teu coração para me receber quando eu ainda era uma estranha.

Agradeço ao meu noivo Rennê, por toda paciência e confiança, por sempre me motivar e acreditar em mim. Obrigada por tanto em tão pouco tempo.

Ao GJRC, meus meninos, em especial aos meus afilhados Thyssa e Xandy, obrigada por cada dia de bênçãos compartilhadas e por me suportar nos dias difíceis.

A amiga Maria ponte fundamental nessa caminhada, obrigada por todas as orientações, apoio e motivação. Agradeço a Karen pela companhia nos dias de sol e chuva, pelas longas esperas na parada de ônibus, pelas parcerias e pouso. Agradeço ao grande mestre Hugo, talvez a pessoa mais sábia que eu já tenha tido a chance de conhecer, de um coração imensurável, valeu por todas as palavras e assistência (técnica). Agradeço a toda equipe do LSIE, de modo especial ao Felipe, Dany e principalmente, ao incomparável Professor Dr. Osmar Abílio, sempre dispostos a sanar dúvidas e auxiliar na construção de minha pesquisa.

Agradeço ao meu orientador, professor Dr. Roberto Gomes, muito obrigada pela paciência, orientações e preocupação durante a execução desta pesquisa, o senhor demonstrou ser, além de orientador, um grande amigo e para mim, um exemplo ímpar de humildade na comunidade científica da qual fazemos parte.

Agradeço a todos que contribuíram de forma direta e indireta para que mais essa etapa acontecesse, a Casa Menino Deus, que muito bem me acolheu, de modo especial, Irmã Dita, a grande parceira Luana, aos primos, tios, colegas, professores, a galera do LAGIM, a turma de mestrado 2018, a Universidade de Brasília e a CAPES por viabilizar o desenvolvimento desta pesquisa.

Obrigada por juntos, me proporcionarem a força e o conhecimento necessário para vencer mais um dos meus objetivos. Estar longe de casa não foi fácil, mas os anjos que encontrei pelo caminho, tornaram tudo muito mais agradável. A vocês, fica toda a minha gratidão. Muito obrigada!

*“Nunca houve noite que pudesse impedir o nascer do sol e a esperança!”*

*Ícaro Dias*

## LISTA DE FIGURAS

<b>Figura 1:</b> Localização da área de estudo .....	21
<b>Figura 2:</b> Fluxograma metodológico de pesquisa.....	22
<b>Figura 3:</b> Cubo Temporal 3D .....	24
<b>Figura 4:</b> Bandas de 1 a 6, polarização VH, apenas com a fração sinal após o processamento do MNF. ....	25
<b>Figura 5:</b> Bandas de 1 a 6, polarização VV, apenas com a fração sinal após o processamento do MNF .....	26
<b>Figura 6:</b> Buffer utilizados na etapa de treinamento dos dados para classificação .....	28
<b>Figura 7:</b> Pontos utilizados na etapa de validação da classificação. ....	30
<b>Figura 8:</b> Bandas de 1 a 6, polarização VH reconstruída de acordo as suas componentes originais e suavizadas, após o MNF Invertido. ....	31
<b>Figura 9:</b> Bandas de 1 a 6, polarização VV reconstruída de acordo as suas componentes originais e suavizadas, após o MNF Invertido. ....	31
<b>Figura 10:</b> Classificação KNN com K sendo igual a 10. ....	33
<b>Figura 11:</b> Classificação KNN com K sendo igual a 05. ....	34
<b>Figura 12:</b> Classificação Rondon Forest para as safras 2016/2017, 2017/2018 nas polarizações VV e VH.....	34
<b>Figura 13:</b> Classificação SVM utilizando a função Radial Basis.....	35
<b>Figura 14:</b> Classificação SVM utilizando a função polinomial de quarta ordem....	36
<b>Figura 15:</b> Matriz de Confusão, RF, SVM - Radial Basis e KNN - K igual a 10.....	38
<b>Figura 16:</b> Matriz de Confusão, SVM - Polinômio de quarto grau e KNN - K igual a 05 .....	38

## LISTA DE TABELAS

<b>Tabela 1:</b> Quantidade de amostras de treinamento e distribuição .....	28
<b>Tabela 2:</b> Valores de Concordância do Índice Kappa.....	29
<b>Tabela 3:</b> Valores de Exatidão Global e Kappa por classificadores, safra e polarizações. ....	32

## LISTA DE SIGLAS

AI – Inteligência Artificial

ACDP - Análise de Componentes de Densidade de Probabilidade

CDS – Centro de Desenvolvimento Sustentável

ESA - European Space Agency

GRD - Ground Range Detected

IW - Interferometric Wide Wath

KNN - K-Nearest Neighbor

LSIE - Laboratório de Sistemas de Informações Espaciais

MATOPIBA – Maranhão, Tocantins, Piauí e Bahia

MDE – Modelo Digital de Elevação

MNF - Transformação Minimum Noise Fraction

PÓS-GEA – Programa de Pós Graduação em Geografia

RF - Randon Forest

SAR - Synthetic Aperture Radar

SVM - Support Vector Machine

SNAP - Sentinel's Application Platform

UFRN – Universidade Federal do Rio Grande do Norte

UNB - Universidade de Brasília

VANT'S - Veículos Aéreos Não Tripulados

## RESUMO

Na área agrícola o Sensoriamento Remoto vem sendo uma opção de baixo custo, no entanto o aumento da disponibilidade de imagens com alta resolução espacial e temporal gratuitas, veio para contribuir de modo significativo para com esses estudos. Mais especificamente as imagens do RADAR/SAR Sentinel-1A e 1B, o qual é capaz de alcançar uma resolução temporal de até 6 dias. As imagens de RADAR são de fundamental importância para compreensão do comportamento de culturas agrícolas e sua identificação, uma vez que independem das condições atmosféricas, favorecendo a aquisição de imagens em quaisquer situações, resultando em séries temporais mais completas e refinadas. Neste estudo buscou-se avaliar o desempenho de três modelos de classificadores de Machine Learning, *Random Forest* (RF), *Support Vector Machine* (SVM) e *K-Nearest Neighbor* (KNN), utilizando séries temporais Sentinel-1/SAR, com a finalidade de identificar os tipos de culturas presentes na região do Panambi, Bahia, no período de safras que compreendem a 2016/2017, 2017/2018. Os procedimentos metodológicos consistiram no pré-processamento das imagens no *Software Sentinel's Application Platform* (SNAP); empilhamento de imagens para construção do cubo temporal; filtragem espacial utilizando o método de Análise de Componentes de Densidade de Probabilidade (ACDP); técnicas de *Transformação Minimum Noise Fraction* (MNF) e MNF Invertido para extração do ruído na frequência das imagens e reconstrução da mesma; e classificação do cubo temporal. Os melhores resultados foram obtidos na filtragem para a polarização VH, com capacidade de melhor separar os alvos agrícolas e para o classificador KNN, alcançando um Kappa de 0,85 e um índice de Exatidão Global de 0,88, seguido do RF com 0,78 e 0,83 e então o SVM com o menor Kappa, 0,59 e 0,67 respectivamente, com melhores respostas na polarização VV. As imagens SAR possuem um alto potencial para identificação de culturas utilizando os modelos propostos em ambas as polarizações, com destaque para o KNN, alcançando uma acurácia geral neste estudo de 96,7%. Entretanto, mais estudos devem ser direcionados para estes fins utilizando imagens Sentinel-1/SAR, fazendo ainda, uso da junção de ambas as polarizações, VV e VH, para alcançar uma maior precisão nas classificações.

**Palavras Chave:** Sentinel-1; SAR; Tipos de Cultura; Machine Learning.

## ABSTRACT

In agricultural field, Remote Sensing has been a low-cost option, however the increase in the availability of free and temporal high-resolution imagery has contributed significantly to these studies. For instance, the images from Sentinel-1A and 1B Synthetic-aperture radar (SAR) are capable of achieving a temporal resolution of up to 6 days. SAR images are pivotal for understanding the behavior of agricultural crops and their identification, since they are independent of atmospheric conditions, favoring the acquisition of images in any situation, resulting in more complete and refined time series. In this study, we evaluate the performance of three models of Machine Learning classifiers, Random Forest (RF), Support Vector Machine (SVM) and K-Nearest Neighbor (KNN), using Sentinel-1 time series, aiming to identify the types of crops present in the region of Panambi, Bahia, during the harvesting (2016/2017 and 2017/2018). We adopted the following methodological procedures: pre-processing the images in the Sentinel's Application Platform (SNAP) Software; stacking images for the construction of the temporal cube; spatial filtering using the Probability Density Component Analysis (ACDP) method; Minimum Noise Fraction (MNF) and Inverted MNF Transformation techniques for extracting noises in the image frequency and reconstructing them; and classification of the temporal cube. Our best result was obtained in the filtering for the VH polarization, with the ability to better separate the agricultural targets and for the KNN classifier, reaching a Kappa coefficient of 0.85 and a Global Accuracy index of 0.88, followed by the RF with 0.78 and 0.83 and then the SVM with the lowest Kappa coefficient, 0.59 and 0.67 respectively, with better responses in the VV polarization. SAR images have a high potential for identifying cultures using the models proposed in both polarizations, with emphasis on KNN, reaching a general accuracy in this study of 96.7%. However, further studies should focus on these purposes, using Sentinel-1/SAR images and combining both polarizations (VV and VH) as a means to achieve greater accuracy in the classifications.

**Keywords:** Sentinel-1; SAR; Types of Culture; Machine Learning.

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	12
<b>2. REVISÃO TEÓRICA</b> .....	15
<b>3. MATERIAL E MÉTODOS</b> .....	21
2.1 ÁREA DE ESTUDO.....	21
2.2 PROCEDIMENTOS METODOLÓGICOS .....	22
2.2.1 <i>Aquisição dos Dados</i> .....	23
2.2.2 <i>Pré-Processamento dos Dados</i> .....	23
2.2.3.2 <i>Filtragem Espacial</i> .....	25
2.2.3.3 <i>Classificação</i> .....	26
2.2.3.4 <i>Separação das Amostras</i> .....	27
2.2.3.5 <i>Análise de Acurácia</i> .....	29
<b>3. RESULTADOS E DISCUSSÕES</b> .....	31
3.1 <i>Filtragem</i> .....	31
3.2 <i>Classificação e Acurácia</i> .....	32
3.3 <i>Matriz de Confusão</i> .....	36
<b>4. CONSIDERAÇÕES FINAIS</b> .....	39
<b>5. REFERÊNCIAS</b> .....	40

## 1. INTRODUÇÃO

Os Cerrados baianos desde a década de 1970 tornaram-se alvo de expansão agrícola, se configurando atualmente, como um dos mais importantes polígonos agrícolas a compor a região do MATOPIBA, que compreende a uma vasta área de produção de grãos e pecuária, envolvendo os estados de Maranhão, Tocantins, Piauí e Bahia. A implementação de políticas e programas de modernização da agricultura advindos do governo do estado, acarretou em uma nova configuração econômica para estas regiões assim como, as extensas áreas planas e a disponibilidade de terras a baixo custo e em abundância (MONDARDO, 2012; SANTOS et al., 2010). Deste modo a demanda da produção para esta região tem exigido da comunidade científica estudos constantes, a fim de torná-la mais eficiente, com baixo custo e amenizar os impactos ao ambiente e seu entorno.

As culturas agrícolas têm seu desenvolvimento acompanhado a partir de avaliações de campo, que apresentam alto custo, demandam tempo considerável e não fornecem informações detalhadas de sua distribuição espacial (OZDOGAN, 2010), porém estes monitoramentos eram dificultados pela falta de disponibilidade a baixo custo de altas resoluções temporais e espaciais de sensores orbitais, trazendo como possível solução, satélites comerciais para preencher tais lacunas, (RUSSWURM; K RNER, 2018; LEE et al., 2010). Assim, ainda com a limitação de aquisição, as imagens de alta resolução temporal e espacial têm contribuído de maneira eficiente com os estudos agrícolas, de modo geral com os monitoramentos regulares (DEL'ARCO SANCHES et al., 2018).

Os avanços nas resoluções temporais de sensores RADAR, juntamente com a grande área recoberta, permitem novas possibilidades no monitoramento de culturas (VAGLIO LAURIN et al., 2018). Os estudos de Sensoriamento Remoto voltados à agricultura têm se beneficiado, recentemente de modo progressivo das imagens de satélites disponíveis gratuitamente, as quais têm sido usadas para estimar a produtividade em grandes áreas e auxiliar na identificação de possíveis doenças. Com estes dados é possível compreender o estágio inicial de crescimento do ciclo fenológico da planta, identificar os seus diversos tipos e ainda viabilizar a prospecção de cenários de

rendimento de preço e mercado (PALCHOWDHURI et al., 2018; FORKUOR et al., 2014; XU et al., 2019).

Uma nova fase para trabalhos voltados a agricultura, se iniciou com o lançamento do programa Copernicus da *European Space Agency* (ESA), dentre as alternativas gratuitas, o sensor RADAR Sentinel-1, parte desta missão, possui excelência no que se refere a disponibilidade de dados com alta resolução espacial e temporal (CSORBA et al., 2019; MOKHTARI et al., 2019; RIBEIRO et al., 2017a; HE; MOSTOVOY, 2019). O tempo curto de revisita torna capaz o monitoramento conciso das áreas agrícolas (SITOKONSTANTINO et al., 2018) visto que são as variações em determinados intervalos curtos de tempo que caracterizam a cobertura destas áreas (BARGIEL, 2017). Deste modo, os dados SAR (*Synthetic Aperture Radar*) podem ser considerados um elemento importante neste tipo de análise (DUSSEUX et al., 2014), independente das condições de cobertura de nuvens presente na área, buscando dessa forma, sanar a lacuna da análise multitemporal de sensores óticos (BARET et al, 2013; HE et al., 2019).

Qualquer cultura agrícola possui uma assinatura específica (espectral e temporal), que a diferencia. Estas assinaturas são utilizadas para distingui-las na classificação, mas diferenciá-las espectralmente com a análise de uma única data pode ser uma tarefa difícil devido às grandes variações sazonais que as plantas têm ao longo do tempo. Isso se deve pelo fato do comportamento fenológico da planta variar ao longo do tempo, o que faz com que se obtenha uma melhoria significativa usando informações multitemporais que descrevem estes diferentes estágios (ABADE et al., 2015). Logo, analisar o contexto temporal é imprescindível, principalmente em regiões caracterizadas por dinâmicas complexas e diversas, como em áreas tropicais (CUÉ LA ROSA et al., 2019), melhorando desta forma a precisão de classificações e validações, bem como a consistência dos dados trabalhados (GÓMEZ; WHITE; WULDER, 2016; CLERICI; VALBUENA ALDERÓN; POSADA, 2017).

Além da qualidade dos dados de Sensoriamento Remoto, os algoritmos de classificação são importantes para melhorar a precisão dos mapas de culturas (SONOBE et al., 2018). Nesta perspectiva, diversos classificadores têm sido utilizados e desenvolvidos nas pesquisas mais recentes utilizando de técnicas de Inteligência Artificial (IA), como os *Machines Learning* e *Deep Learning*, os

quais já não se enquadram como classificadores convencionais de origem paramétrica e supervisionados.

O uso de imagens de SAR do programa Sentinel-1 tem mostrado bons resultados para cartografia de uso da terra a baixo custo (CHATZIANTONIOU; PETROPOULOS; PSOMIADIS, 2017). Com isso, o objetivo deste estudo consiste em avaliar o desempenho de três modelos de Machine Learning, *Random Forest* (RF), *Support Vector Machine* (SVM) e *K-Nearest Neighbor* (KNN), utilizando séries temporais Sentinel - 1/SAR, com a finalidade de identificar os tipos de culturas presentes na região do Panambi, Bahia, no período de safras que compreendem a 2016/2017 e 2017/2018.

Realizamos a classificação dos tipos de culturas através dos métodos de *Machine Learning*: SVM, RF e KNN e, desta forma buscamos: 1) Explorar o uso de imagens SAR para diferentes períodos de safra e tipos de culturas e; 2) Detectar as precisões de diferentes métodos de *Machine Learning*. Para estes fins, essa Dissertação de Mestrado está dividida em: I) Introdução (já apresentada); II) Referencial Teórico acerca do tema proposto, III) Materiais e Métodos, apresentando ainda a descrição da área de estudo, IV) Resultados e Discussões e, V) Considerações Finais.

## 2. REVISÃO TEÓRICA

Diante da evolução de estudos destinados a agricultura, o Sensoriamento Remoto atua como ferramenta essencial, sendo capaz de oferecer um meio não destrutivo de fornecer informações recorrentes da escala local para a escala global de forma sistematizada, caracterizando a variabilidade espaço-temporal dentro de uma determinada área de plantio (WEISS; JACOB; DUVEILLER, 2020). O acesso rápido e gratuito a dados de Sensoriamento Remoto de resolução moderada oferecem alto potencial para monitorar as tendências longas interanuais ou anuais (RENGARAJAN; SCHOTT, 2018).

O desenvolvimento do Sensoriamento Remoto passou e vem passando por significativas transformações, tendo sua origem conectada às fotografias utilizadas de forma estratégica, iniciando uma segunda fase somente em 1960, com a primeira imagem de sensor orbital. Após este feito, diversos sensores óticos, multiespectrais, hiperespectrais e de microondas, foram postos em órbita para as mais diversas aplicações (NOVO, 2010). Recentemente está ciência passou por uma nova fase, dos VANT'S (Veículos Aéreos Não Tripulados), aumentando ainda mais os leques de aplicações. Paralelo aos VANT'S os sensores orbitais vem sendo cada vez mais refinados no que versa sobre os tamanhos e resoluções, bem como disponibilidade de informação de modo gratuito, nesta perspectiva os dados de RADAR/SAR estão sendo uma forte alternativa de pesquisa devido ao uso restrito de imagens óticas em função das condições atmosféricas.

Em pesquisas já realizadas na África Ocidental, dado à indisponibilidade de imagens devido á cobertura excessiva de nuvens, foram integrados dados *Rapid Eye* e Terra SAR-X, a fim de mapear culturas e grupos de culturas, e os resultados para este tipo de fusão apontam que a integração de dados melhoram a precisão da classificação entre 10 a 15% (FORKUOR et al., 2014; MCNAIRN et al., 2009). Na África para regiões de vegetação lenhosas e pastagens foram integrados dados óticos (Landsat) e SAR (PaISAR-1) para períodos secos e chuvosos, com um aumento de 10% na precisão geral (SYMEONAKIS et al., 2018). Na China para plantação de arroz (ZHANG et al., 2018) e área de plantio de trigo de inverno usando séries temporais Sentinel-1, especialmente em áreas

sem dados óptico, caso da Planície Norte da China, alcançaram um Kappa de 0,77 (SONG; WANG, 2019).

O Sentinel 1A e 1B utilizado nesta pesquisa, é parte da missão Copernicus, ESA, responsável por fornecer imagens de RADAR utilizando a técnica TOPSAR, uma continuação das missões ESA ERS, ENVISAT e RADARSAT. O Sentinel-1A foi lançado em abril de 2014 e o Sentinel-1B em abril 2016, com dados de alta resolução temporal (ESA, 2015; BARGIEL, 2017). Os sensores operam na banda C, a uma frequência de 5.405 GHz com resolução temporal de 12 dias ou 06 dias quando os dois satélites estão em operação e resolução espacial de 10 metros. O sistema tem a capacidade de operar nos modos de polarização única (HH ou VV) e ainda de dupla polarização (HH/HV ou VV/VH) (TORRES et al., 2012), preservando a fase, o que o torna de uso satisfatório para classificações da cobertura do solo (RAO e KUMAR, 2017).

Outro fator importante para análises temporais está conectado a alta frequência de dados de RADAR/SAR, a qual pode determinar um número suficiente de observações, durante toda a estação de crescimento da planta, possibilitando mapear tantos os tipos de culturas, como a sua rotação (VUOLO et al., 2018). Para estes fins o programa Sentinel-1, aponta diversas possibilidades, uma vez que oferece resoluções gratuitas sem precedentes com informações mais ricas, aumentando as precisões em comparação com as classificações realizadas apenas com imagens óticas (VAN TRICHT et al., 2018).

A alta frequência de dados, permitiu diversos estudos nos últimos anos com a utilização de imagens multitemporais (WEST et al., 2018); MELAAS; FRIEDL; ZHU, 2013; BELGIU; CSILLIK, 2018; KOLECKA et al., 2018; LAMBERT et al., 2018; NASRALLAH et al., 2018; PALCHOWDHURI et al., 2018; SONOBE et al., 2018; WANG et al., 2019; TIAN et al., 2019; MOODY et al., 2017; MARDANI et al., 2019). No entanto estas séries possibilitam as mais diversas aplicações, tais como mapear áreas de: espécies arbóreas (MELAAS; FRIEDL; ZHU, 2013; RENGARAJAN; SCHOTT, 2018; PERSSON; LINDBERG; REESE, 2018); área de pastagem (KOLECKA et al., 2018; SHOKO et al., 2018), fisionomia do bioma Caatinga (DA SILVEIRA et al., 2018), em áreas úmidas (CHATZIANTONIOU; PETROPOULOS; PSOMIADIS, 2017), na recuperação de métricas fenológicas (VRIELING et al., 2018) e, principalmente em áreas

agrícolas (SONG et al., 2017; TORBICK et al., 2017; VREUGDENHIL et al., 2018; ZHANG et al., 2018; MOKHTARI et al., 2019; RIBEIRO et al., 2017; VERMA; KUMAR; LAL, 2019; HE; MOSTOVOY, 2019; CLAUSS et al., 2018; C. SUN, Y. BIAN, T. ZHOU, 2019; VALCARCE-DIÑEIRO et al., 2019; BAZZI et al., 2019; KHABBAZAN et al., 2019; SILVA, 2018; VELOSO et al., 2017).

A resolução espacial e temporal dos satélites Sentinel é altamente adequada para o monitoramento das culturas (VERMA; KUMAR; LAL, 2019), produzindo classificações precisas, de até 96%, como ocorreu no sul de Mianmar, (NOMURA; MITCHARD, 2018), permitindo desta forma, alcançar efetivamente altas precisões nas classificações (BARGIEL, 2017; GAO et al., 2018a ; ABDIKAN et al., 2016; XU et al., 2019).

Com o avanço na gama de dados disponíveis em sensoriamento remoto houve a necessidade de aprimorar as técnicas já existentes, a partir de modelos de classificações avançados baseados em aprendizados de máquinas ou objetos, agora, não paramétricos (ZHU et al., 2017; MA et al., 2019; LI et al., 2018; INTERDONATO et al., 2019; SIDIKE et al., 2019; CAI et al., 2018; CHATZIANTONIOU; PETROPOULOS; PSOMIADIS, 2017; SNOBE et al., 2018; IENCO et al., 2019). O método Machine Learning é um dos tipos de aprendizado de máquina, caracterizado como um subcampo da Inteligência Artificial (AI) sobre o qual consiste uma variedade de algoritmos e técnicas que se baseiam no conceito de "aprendizado" (SAINI; GHOSH, 2019).

Estes algoritmos são capazes de lidar de modo eficiente com dados de alta dimensão e mapear classes com características muito complexas (MAXWELL; WARNER; FANG, 2018). Estas técnicas fornecem uma precisão mais alta e um desempenho mais refinado se comparado com os classificadores convencionais. Tal diferença ocorre em função da capacidade de modelar a complexidade por meio de treinamento (KAYAD et al., 2019). Dentre os modelos mais utilizados de Machine Learning estão o *Random Forest* (RF), *Support Vector Machine* (SVM) e *K-Nearest Neighbor* (KNN).

As florestas aleatórias ou RF, consistem em um método de aprendizado baseado em árvores de decisão, para classificação e regressão, partindo do princípio de que uma combinação de classificadores agregados possui melhor desempenho que um único classificador. As melhores combinações de divisões são definidas por uma abordagem de auto inicialização e por voto e, então, se

define a melhor classe (BREIMAN, 2001). O RF possui algumas vantagens, como mensurar a importância da variável, é menos sensível ao ruído ou ao excesso de ajuste favorecendo maior precisão, possui alta capacidade de diferenciar culturas além de ser indicado para análises multitemporais (WANG et al., 2019; LAMBERT et al., 2018; VUOLO et al., 2018; MASSEY et al., 2017), com um tempo computacional relativamente rápido se comparado a outros classificadores (BREIMAN, 2001; BELGIU; DRĂGU, 2016; SITOKONSTANTINOOU et al., 2018; PELLETIER et al., 2016; LI et al., 2016) oferecendo uma redução considerável no tempo de processamento dos dados (LEBOURGEOIS et al., 2017).

O SVM, um segundo classificador abordado, define limites no espaço de alta dimensão, ou seja, um hiperplano capaz de separar os dados de treinamento em classes rotuladas, possibilitando o uso de funções polinomial ou do tipo Radial Basis (KAYAD et al., 2019). O algoritmo encontra a minimização ideal, isto é, limite de decisão em um espaço problemático, buscando distinguir problema de classificação em um conjunto predefinido de classes (ABDI, 2019). Este método é muito utilizado para a classificação de culturas e consegue obter resultados de classificação com alta precisão e eficiência significativa, dispondo de apenas algumas amostras de treinamento (GAO et al., 2018b; MOUNTRAKIS; IM; OGOLE, 2011).

O outro classificador é o KNN, o qual dispõe de precisões consideráveis em estudos comparativos já realizados (NOI E KAPPAS, 2018; HEYDARI; MOUNTRAKIS, 2018). O classificador KNN é diferente dos demais uma vez que, não necessita de treinamento para produzir um modelo. É realizado um comparativo com os dados originais de treinamento e então a amostra desconhecida é atribuída à classe mais comum das  $k$  amostras de treinamento que estão mais próximas no espaço. Um  $k$  baixo produzirá, portanto, um limite de decisão muito complexo, e um  $k$  mais alto resultará em uma maior generalização na classificação (MAXWELL; WARNER; FANG, 2018).

Alguns estudos já realizados atestam a eficácia destes classificadores, principalmente a título de comparação. Dados de retroespalhamento na polarização VH através do uso de séries temporais Sentinel-1, entre os padrões de cultivo de arroz e os de outros tipos de uso da terra foram utilizados, chegando a resultados que apontam o RF ligeiramente melhor que o SVM. A precisão geral

e o coeficiente Kappa alcançados a partir do RF foram 86,1% e 0,72, respectivamente, enquanto os valores de SVM foram 83,4% e 0,67 (SON et al., 2018). Na França o classificador SVM foi testado, tanto para imagens óticas e de RADAR, em áreas de pastagens e demais culturas agrícolas obtendo melhor precisão para os dados SAR, com 0,98, em comparação ao sensor ótico, com 0,81 (DUSSEUX et al., 2014).

Ainda a título de comparação dos classificadores para cobertura da terra usando o Sentinel-2, foi apontado que o SVM, diante dos testes de balanceamentos, respondeu com resultados mais precisos, seguido do RF e KNN. As maiores precisões para os três métodos ocorreram quando o tamanho da amostra de treinamento foi grande o suficiente, acima de 750 pixel. O SVM alcançou uma precisão geral de 95,32%, RF de 94,70% e o KNN de 94,59% respectivamente (NOI; KAPPAS, 2018). Os dados polarimétricos de SAR com todas as quatro polarizações e informações de fase podem ser úteis no mapeamento de culturas com muito mais precisão, uma vez que quando combinado com o ótico, atingiu uma precisão geral de 83,87% e um Kappa de 0,78 (VERMA; KUMAR; LAL, 2019).

Na Bélgica foram utilizadas séries temporais Sentinel-1 (SAR) e Sentinel 2 (ótico) para identificação de culturas, com uma precisão geral de 0,68 para os dados SAR e 0,70 para os dados óticos, utilizando o classificador RF. No entanto, existiram meses onde o valor de Kappa se manteve maior para os dados SAR (0,31) do que para os óticos (0,22). Isto ocorre devido ao maior número de dados de entrada no início da temporada de plantio com imagens de RADAR, do que de imagens óticas devido à interferência atmosférica (VAN TRICHT et al., 2018). Em áreas agrícolas da Áustria, o RF também foi utilizado na identificação de tipos de culturas com dados Sentinel-2 e apresentou a mesma deficiência no início da temporada que o estudo anterior realizado na Bélgica, com precisões mais baixas (VUOLO et al., 2018).

Para identificação de campos de arroz, na Espanha, foram utilizados os classificadores SVM e RF para imagens Sentinel-1, o primeiro alcançou uma acurácia geral de 81,08% e o segundo de 82,2%, como estes resultados, essa abordagem pode ser usada em qualquer área agrícola quando os dados de SAR estão disponíveis (GAO et al., 2018b). Já Bazzi et al., (2019) encontraram uma precisão geral de 90,7% em parcelas irrigadas derivadas do classificador

de RF com dados Sentinel-1. Em estudo realizado na área central de Suzhou província de Jiangsu, China, foi avaliado a capacidade e a contribuição do uso de recursos de intensidade de retroespalhamento, textura, coerência e cor extraídos dos dados do Sentinel-1A para a classificação da cobertura do solo urbano utilizando o classificador RF. A precisão geral e o coeficiente Kappa foram significativos, 90% e 0,88. Comparando informações de polarização VV e VH, foi possível afirmar ainda que a polarização do VH contribuiu mais para a classificação do que a polarização do VV (ZHOU; LI; PAN, 2018).

Ao diagnosticar o potencial de dados do Sentinel-1 para diferentes aplicações de mapeamento da cobertura agrícola, para a região de Camargue na França, os resultados do valor de Kappa foram satisfatórios, com 0,83 para RF e SVM e 0,82 para o KNN. Esses resultados confirmam a adequação dos dados das séries temporais do Sentinel-1 para aplicações de cobertura da terra agrícola (NDIKUMANA et al., 2018).

O RADAR/SAR Sentinel-1 é utilizado também na área agrícola para identificar as características da área de plantio do milho. A análise de correlação foi realizada entre a altura das plantas de milho antes e após o plantio e as diferentes combinações de polarização (SHU et al., 2020). As informações de séries temporais Sentinel-1 para identificação de tipos de cultura na China, possibilitou um Kappa de 0,67 para o SVM e 0,72 para o RF. Os resultados mostraram que é possível distinguir tipos de culturas de outros tipos de cobertura da terra usando características VV e VH (C. SUN, Y. BIAN, T. ZHOU, 2019).

Os estudos que envolvem de modo específico o RADAR/SAR Sentinel-1 voltados para agricultura, ainda são vastos, estando mais direcionados ao sensor ótico do programa Copernicus, Sentinel-2, ou para a fusão de ambos, conforme os casos já mencionados. No entanto é notável as precisões alcançadas com a inserção de imagens de RADAR/SAR Sentinel-1 nas pesquisas mais recentes e seu uso satisfatório para regiões agrícolas, sendo um dos métodos mais eficientes para a classificação de culturas principalmente devido à alta capacidade do sensor na geração de imagens para todas as condições de clima e tempo (KUSSUL et al., 2016; OLDONI et al., 2019).

### 3. MATERIAL E MÉTODOS

#### 2.1 ÁREA DE ESTUDO

A área de estudo está localizada na região do Panambi, situada na divisa entre os estados de Tocantins e Bahia, entre as coordenadas L 327428.55 E 8740839 e L 376284.29 E 8801506.08 (Figura 01), tendo como centro a rodovia estadual BA 458, umas das principais vias para escoamento agrícola. Essa região está incluída dentro dos limites do MATOPIBA, um grande polígono agrícola delimitado de acordo a sua expressiva produção de grãos, envolvendo os estados de Maranhão, Tocantins, Piauí e Bahia.

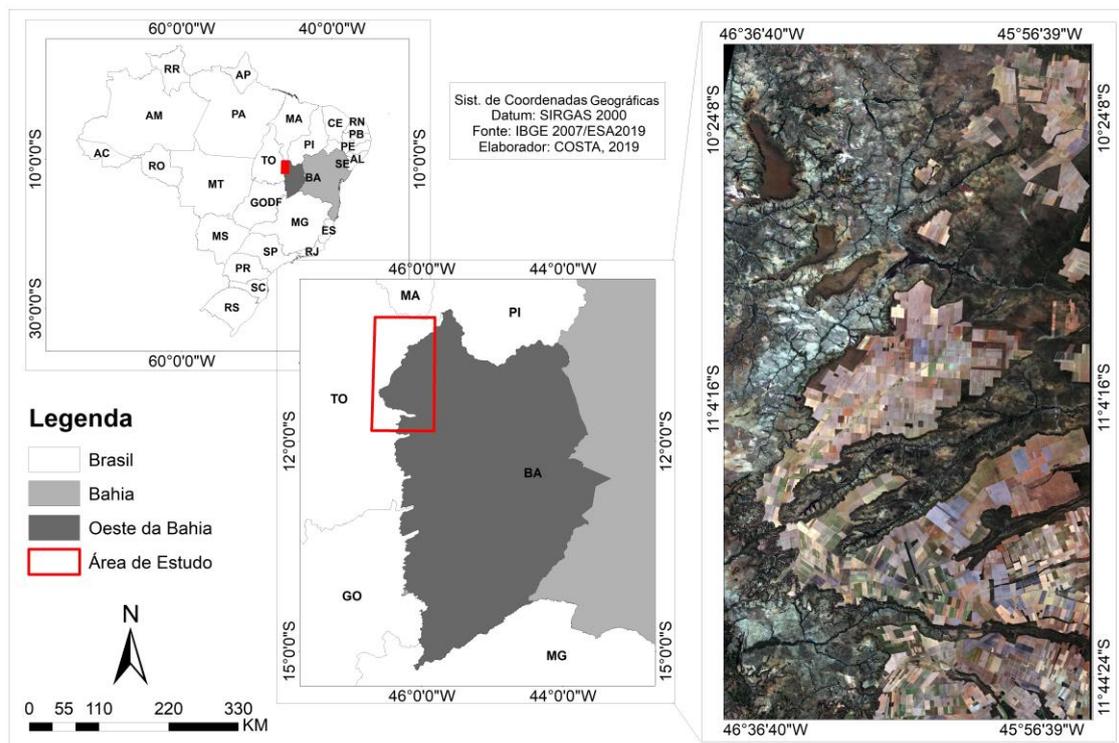


Figura 1: Localização da área de estudo

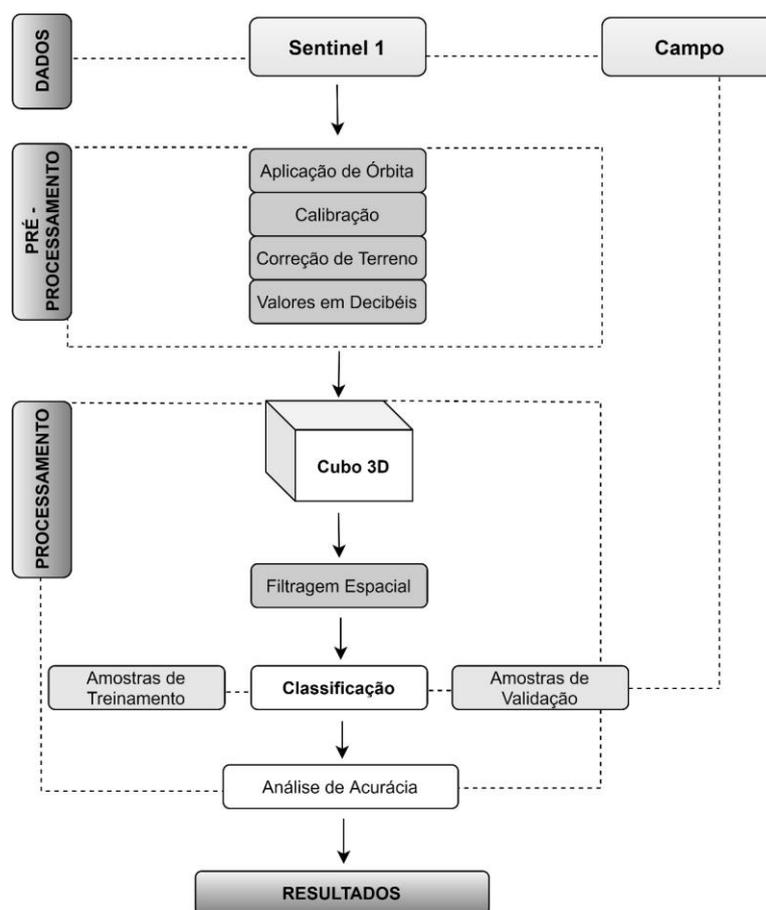
O clima contempla três zonas climáticas: tropical Brasil central, tropical zona equatorial e equatorial, porém é o clima subúmido o de maior predominância, com temperaturas médias de 18°C, estações bem definidas e regimes pluviométricos médios anuais de 1000 mm. A região em análise fica localizada em uma área rica geomorfologicamente, com presença de escarpas, superfícies aplainadas e *inselbergs*, porém os limites de maior interesse estão inseridos em sua maioria sobre os arenitos do morfodomínio do Chapadão do

Urucuia (COSTA, 2017), região de maior concentração de talhões agrícolas mapeados.

Quanto a geologia a área se encontra sobre Cratón do São Francisco, uma unidade tectônica do embasamento da Plataforma Sul Americana, área tectonicamente estável, datada do Paleoproterozóico (BARBOSA; SABATÉ; MARINHO, 2003). Possui uma vegetação típica do bioma Cerrado com predominância de Latossolos amarelos e Neossolos quartzarênicos e Litólicos, com baixa fertilidade e características físicas favoráveis ao manejo agrícola, como a alta permeabilidade e porosidade, em síntese, caracterizam-se por serem solos muito bem drenados (MAGALHÃES; MIRANDA, 2014).

## 2.2 PROCEDIMENTOS METODOLÓGICOS

Os procedimentos metodológicos consistem em quatro etapas: I) Aquisição dos dados; II) pré-processamentos; III) processamento e; IV) resultados, conforme demonstrado na figura 02.



**Figura 2:** Fluxograma metodológico de pesquisa

### 2.2.1 Aquisição dos Dados

Nesta primeira etapa foi realizado o levantamento e sistematização de dados para validação e treinamento dos classificadores. No primeiro momento foi estabelecido contato direto com produtores e associações da região do Panambi, possibilitando a construção de um banco de dados com as seguintes informações por talhões agrícolas: Coordenadas/ ano/ safra/ tipo de cultura, sendo composta por Soja, Milho, Algodão/ área/ há/ UF/ data de plantio e para algumas áreas, data de colheita, totalizando 143 talhões agrícolas distribuídos ao longo dos limites da área de estudo, sendo destes, 69 para a safra 2016/2017 e 74 para 2017/2018, todos com dimensões distintas.

Os dados adquiridos contemplam o período de 2016 a 2018, que correspondem às safras de 2016/2017 e 2017/2018, as quais estão de acordo a disponibilidade de imagens dos programas Sentinel-1A e 1B. As imagens dos sensores RADAR, foram adquiridas no site da ESA (<https://scihub.copernicus.eu>). Os produtos utilizados foram baixados com a configuração do tipo *Ground Range Detected* (GRD) e no modo sensor *Interferometric Wide Wath* (IW).

A aquisição das imagens foi de acordo ao ano safra, para tal foram utilizadas 26 imagens de RADAR para a safra 2016/2017 que compreendem ao período de 26 de setembro de 2016 a 21 de setembro de 2017 e 30 imagens para a safra 2017/2018 iniciando em 09 de setembro de 2017 a 16 de setembro de 2018, com polarização VV e VH. Iniciamos o cubo temporal antes do mês inicial da safra e concluímos um mês após o fim da safra, na intenção de melhor identificar a resposta dos alvos em questão.

### 2.2.2 Pré-Processamento dos Dados

Na segunda etapa foi realizado o pré-processamento das imagens de RADAR, que inclui: I) aplicação de órbita, a fim de fornecer informações precisas sobre a posição e velocidade do satélite, fazendo uma atualização nos metadados da imagem; II) calibração, onde é realizada a conversão simples dos valores de intensidade das imagens em valores de sigma, favorecendo um ganho de faixa margeada, está calibração absoluta dos dados SAR fornecem valores de pixels diretamente relacionados ao retroespalhamento das superfícies

refletidas; III) correção de terreno, onde os pixels das imagens são corrigidos em função de Modelo Digital de Elevação (MDE), passando a representar a geometria do terreno e não mais a do SAR e; IV) a transformação dos valores da imagem em decibéis (FILIPPONI, 2019). Todos os pré-processamentos são realizados no *Software Sentinel's Application Platform* (SNAP) da ESA, desenvolvido especificamente para estes fins.

### 2.2.3 Processamento dos dados

#### 2.2.3.1 Empilhamento de Imagens

Na terceira etapa as imagens de RADAR foram empilhadas no *Software Abílius*, desenvolvido no Laboratório de Sistemas de Informações Espaciais (LSIE) da Universidade de Brasília (UNB). Para o empilhamento, foi construído um cubo temporal, onde os eixos X e Y corresponderam às coordenadas geográficas e o eixo Z às assinaturas temporais (Figura 03), a fim de refinar a precisão da classificação, dado as características temporais nos dados de Sensoriamento Remoto com resoluções mais precisas (JIA et al., 2014).

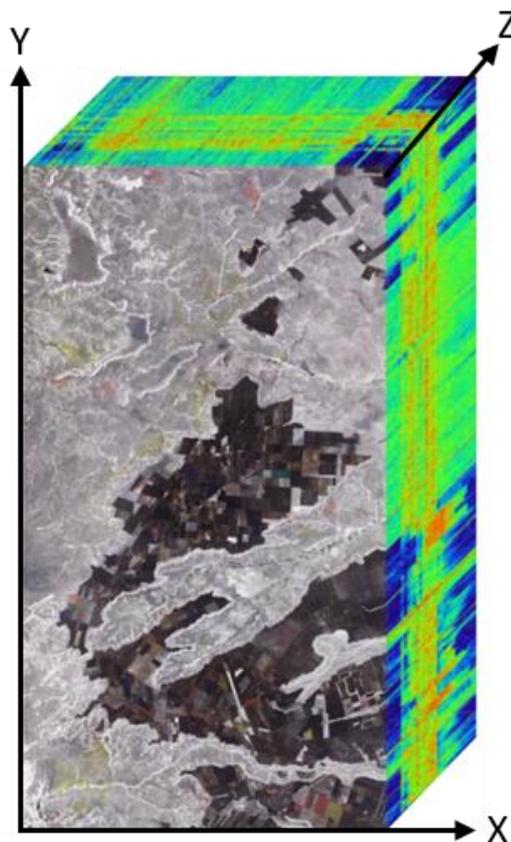


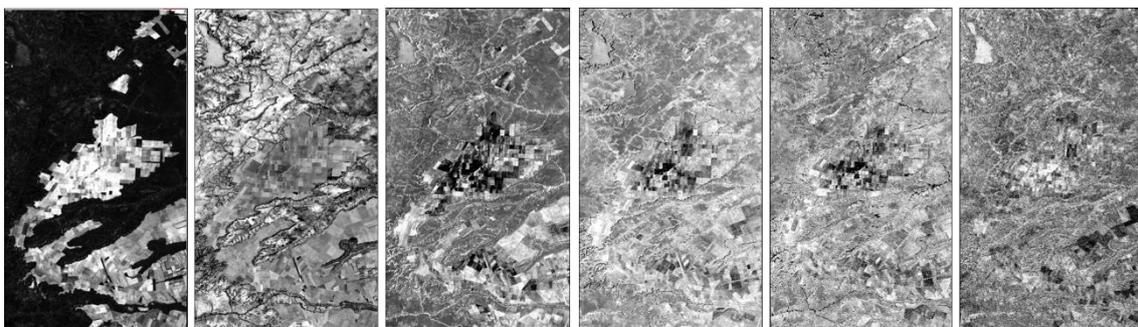
Figura 3: Cubo Temporal 3D

### 2.2.3.2 Filtragem Espacial

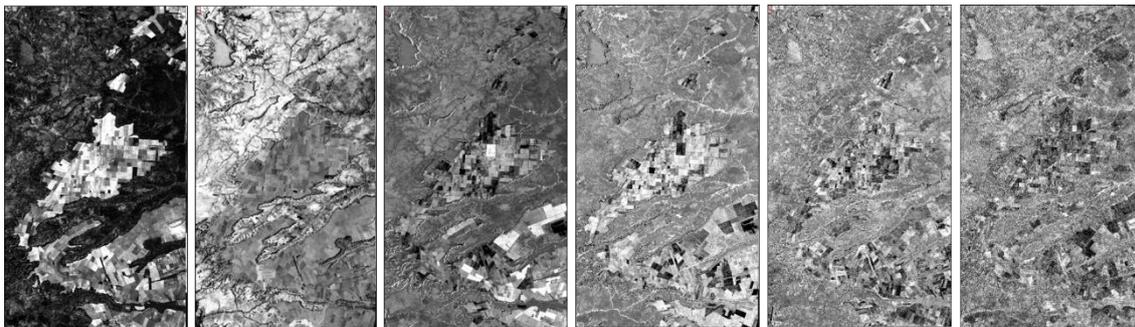
Após a elaboração do cubo temporal, as imagens passaram pelo processo de filtragem no *Software* Abílius. Com esse processamento, buscamos otimizar a relação sinal ruído (efeito *speckle*) das imagens, pixel a pixel. O método utilizado foi a Análise de Componentes de Densidade de Probabilidade (ACDP) (DE CARVALHO JÚNIOR et al., 2014). Este método trabalha combinando o histograma de filtragem e frequência.

O algoritmo faz uso de uma janela móvel sobre a imagem, definida neste estudo após alguns testes realizados, como 11X11, valor este que melhor respondeu às particularidades da área proposta, calculando o histograma de frequência e na sequência distribuindo os valores de cada categoria em uma componente específica da imagem, gerando como dado de saída uma sequência de imagens. O Método considera ainda o *Lag* temporal, sendo definido aqui com 26 tempos (total de imagens utilizadas na etapa de empilhamento), para o ano safra de 2016/2017 e 30 tempos para o ano safra 2017/2018, correspondendo ao total de dados presentes no histograma, e os níveis de cinza, cujo o parâmetro utilizado foi de 32 bits para cada polarização.

Na sequência é realizada uma análise pixel a pixel através do *Transformação Minimum Noise Fraction* (MNF) (GREEN et al., 1988), onde o ruído é retirado na frequência da imagem, estando concentrada a fração sinal nas primeiras bandas, 1 a 6 para safra 2016/2017 e 2017/2018, enquanto que as demais bandas representam a fração ruído, isso ocorre tanto no tempo como no espaço (Figura 04 e 05).



**Figura 4:** Bandas de 1 a 6, polarização VH, apenas com a fração sinal após o processamento do MNF.



**Figura 5:** Bandas de 1 a 6, polarização VV, apenas com a fração sinal após o processamento do MNF

Em síntese o MNF é responsável por diminuir a dimensionalidade dos dados ao passo que ordena as componentes em termos de qualidade de imagem, melhorando a relação sinal-ruído (DE CARVALHO JÚNIOR et al., 2014). Após reconstruímos a imagem pelo método do MNF invertido de acordo suas componentes originais, agora suavizadas e com a eliminação dos ruídos, obtendo apenas as componentes relativas ao sinal.

### 2.2.3.3 Classificação

Ainda na etapa de processamento de dados foi realizada a classificação das imagens SAR no *software* Abílius. A classificação das imagens Sentinel-1, ACDP-MNF foi realizada pelos algoritmos RF, SVM e KNN. O RF é um método baseado em crescimento aleatório de árvore sendo determinado por voto, considerando as classes mais homogêneas entre si (BREIMAN, 2001). Neste método de classificação cada árvore é construída executando um algoritmo de aprendizado individual que divide a variável de entrada em subconjuntos, gerando deste modo diversas árvores. Este processo de divisão de árvores é repetido inúmeras vezes até que o nó contenha amostras muito semelhantes ou quando a divisão não agrega mais valor às previsões. Durante a fase de decisão cada árvore classifica os dados do recurso de entrada, para então definir quem receberá maior número de votos (PELLETIER et al., 2016).

O segundo método utilizado foi o SVM, o qual consiste em uma classificação supervisionada baseada na teoria de aprendizagem estatística. Utiliza como base uma superfície de decisão ou um hiperplano ideal, definida por vetores amostrais ou vetores de suporte identificados e distribuídos, onde cada superfície lança um voto unitário para a classe, permitindo assim a separação destas superfícies, maximizando a margem de separação entre elas, tem como principal característica a sua capacidade de lidar com sucesso com

pequenos conjuntos de dados de treinamento, assim como a de boa generalização a partir de uma quantidade limitada e / ou qualidade dos dados de treinamento (MOUNTRAKIS; IM; OGOLE, 2011). Como primeira etapa o classificador SVM localiza um hiperplano de separação, maximizando desta forma a margem dos pontos mais próximos do plano, após busca tratar as amostras não separáveis afim de efetivar a separação fazendo uso de funções de decisões não-lineares para tratar os casos de amostras separáveis e não-separáveis (LIU, 2006). Para o método SVM, primeiro foi realizada uma classificação com valor 3 para a função Radial Basis e em seguida uma nova classificação, agora com polinômio de grau 4, para as polarizações VV e VH.

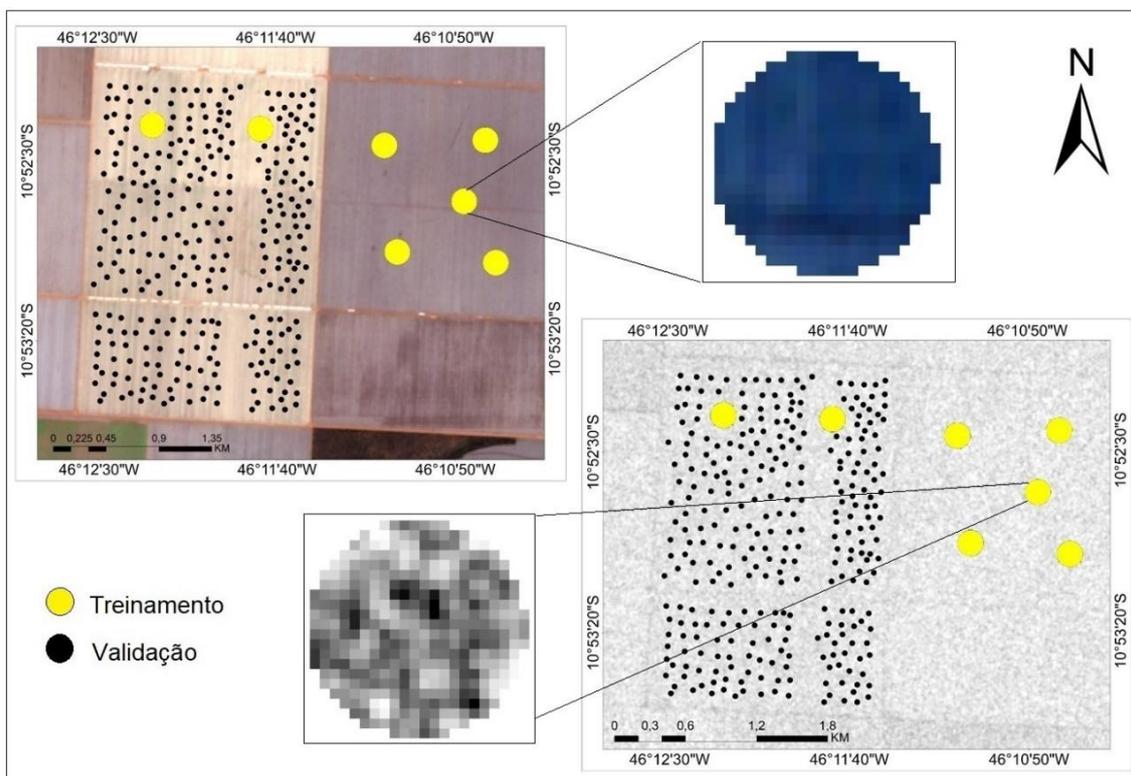
O método KNN também utilizado, consiste em um classificador não paramétrico. Este classificador faz uso da distância Euclidiana para identificar seus vizinhos mais próximo, neste caso quando o valor de K é igual a 1. Diante dos dados do conjunto de calibração o algoritmo encontra um outro grupo k de amostras mais próximo a uma outra amostra, agora desconhecida, onde a definição da classe é determinada em função da média das variáveis de resposta, ou seja, os atributos de classe do K vizinho mais próximo (AKBULUT et al., 2017; WEI et al., 2017). Para este método primeiro as imagens foram classificadas com o valor de K igual a 10 e em seguida com K igual a 5, para ambas as polarizações, VV e VH.

#### 2.2.3.4 Separação das Amostras

Ainda no programa Abílius foram geradas amostras de treinamento, todas com tamanhos idênticos e quantidades distintas em função dos dados previamente levantados em campo (Tabela 01), em conformidade com os 0,25% mínimos de amostra da área total estabelecidos (NOI e KAPPAS, 2018) e com os devidos balanceamentos. Para este balanceamento ou padronização das amostras de treinamento, foram construídos *buffers* para cada uma das culturas previamente coletadas, todos em quantidades e tamanhos idênticos, contemplando todo o limite da área proposta, exceto para as classes de Área Úmida, as quais possuem uma quantidade inferior de *buffers* em função das disponibilidade de dados (Figura 06).

**Tabela 1:** Quantidade de amostras de treinamento e distribuição de classes para classificação por ano safra

Ano Safra	Amostra -Buffer 110m	Classes	Pixels
2016/2017	140 <i>Buffers</i>	01 – Soja	53200
2016/2017	140 <i>Buffers</i>	02 – Algodão	53200
2016/2017	140 <i>Buffers</i>	03 – Milho	53200
2016/2017	140 <i>Buffers</i>	04 – Vegetação	53200
2016/2017	85 <i>Buffers</i>	05 – Área Úmida	32300
2017/2018	140 <i>Buffers</i>	01 – Soja	53200
2017/2018	140 <i>Buffers</i>	02 – Algodão	53200
2017/2018	140 <i>Buffers</i>	03 – Milho	53200
2017/2018	140 <i>Buffers</i>	04 – Vegetação	53200
2017/2018	85 <i>Buffers</i>	05 – Área Úmida	32300



**Figura 6:** Buffer utilizados na etapa de treinamento dos dados para classificação

Para cada ano safra foram definidas classes distintas em função do plantio anual e da própria rotação de culturas. Para imagens Sentinel-1 na safra 2016/2017 e 2017/2018, foram definidas 05 classes para classificação (Tabela 01). Quanto às classificações, foram realizadas por ano safra, para cada um dos classificadores, levando em consideração a polarização dupla (VV e VH).

### 2.2.3.5 Análise de Acurácia

Para acurácia geral das classificações, foi efetuada uma proporção do número de pixels corretamente classificados pelo número total de pixels, ao passo que o coeficiente Kappa, o qual possibilitou a matriz de confusão, nos aponta uma concordância geral, o qual varia de 0 a 1 (CONGALTON; GREEN, 1993) (Tabela 02). Assim temos definidos os erros de Comissão e Omissão bem como a Acurácia do Usuário e do Produtor, além do índice de Concordância Geral (Kappa) e índice de Exatidão Global.

**Tabela 2:** Valores de Concordância do Índice Kappa. Adaptado de Congalton e Green, 1993.

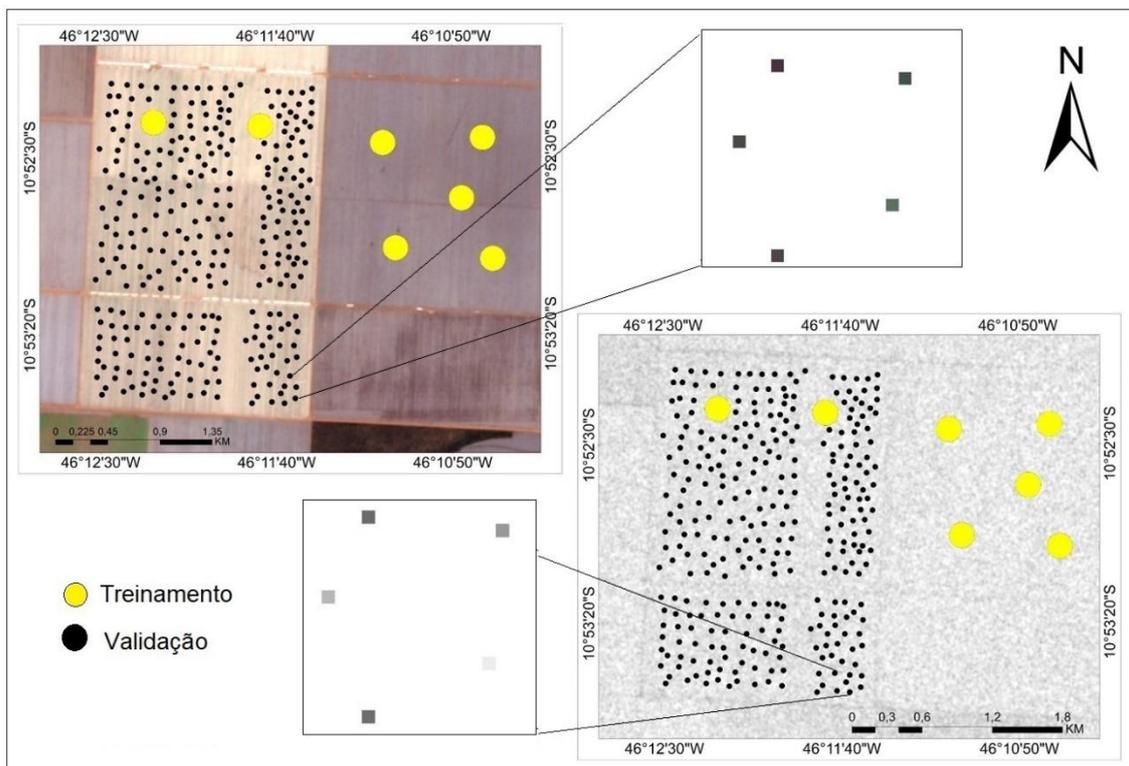
Valor do Coeficiente Kappa	Nível de Concordância
<0	Não existe concordância
0 -0,20	Concordância Mínima
0,21 – 0,40	Concordância Razoável
0,41 – 0,60	Concordância Moderada
0,61 – 0,80	Concordância Substancial
0,81 – 1,0	Concordância Perfeita

Neste estudo foram analisados de modo específico os valores de Exatidão Global, consistindo na soma da diagonal principal da matriz de confusão  $x_{ii}$ , pelo número total de amostras coletadas  $n$  (Equação I) e o Kappa, que é a mensuração estatística do quanto a classificação está de acordo aos dados de referência, onde temos que:  $x_{ii}$  é o valor na linha  $i$  e coluna  $i$ ;  $x_{i+}$  é a soma da linha  $i$  e  $x_{+i}$  é a soma da coluna  $i$  da matriz de confusão;  $n$  é o número total de amostras e  $c$ , o número total de classes (Equação II).

**Equação 1:** I) Fórmula da Exatidão Global e, II) Kappa.

$$\begin{array}{l}
 \text{I)} \\
 G = \frac{\sum_{i=1}^c x_{ii}}{n}
 \end{array}
 \quad
 \begin{array}{l}
 \text{II)} \\
 K = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}}
 \end{array}$$

Para que possibilitasse a análise de acurácia deste estudo, foi necessária à coleta de 300 pontos de pixel puro para cada uma das classes, afim de validar cada uma destas, previamente definidas (Figura 08). Na sequência esses pontos foram convertidos em ROIS no *Software* ENVI 5.3, possibilitando a aquisição da Matriz de Confusão e os demais índices.



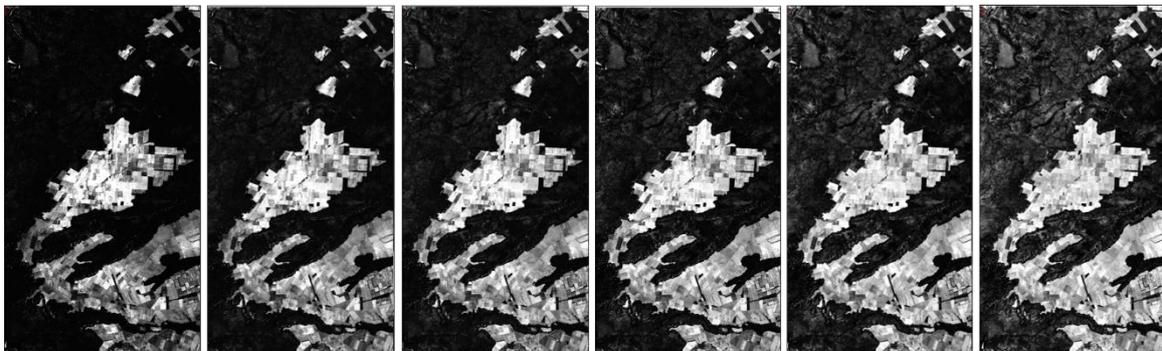
**Figura 7:** Pontos utilizados na etapa de validação da classificação.

### 3. RESULTADOS E DISCUSSÕES

#### 3.1 Filtragem

Os métodos de filtragem são capazes de identificar os recursos mais relevantes independente do classificador e de remover variáveis insignificantes para o usuário (BELGIU; DRĂGU, 2016). Na etapa de filtragem para as imagens SAR, utilizando o parâmetro de níveis de cinza 32, os resultados foram satisfatórios, para cada uma das polarizações, concordando com os resultados já encontrados quando comparado a outros filtros (HUANG; QU, 2014; CHATZIANTONIOU; PETROPOULOS; PSOMIADIS, 2017).

A partir do resultado do filtro ACDP, foi gerado o MNF invertido, para a polarização VH (Figura 08) e VV (Figura 09), o qual foi aplicado com o propósito de separar a fração ruidosa da demais componentes. O processamento inverso adotou as 6 primeiras componentes devido à queda dos valores nas componentes posteriores, com maiores concentrações de ruído.



**Figura 8:** Bandas de 1 a 6, polarização VH reconstruída de acordo as suas componentes originais e suavizadas, após o MNF Invertido.



**Figura 9:** Bandas de 1 a 6, polarização VV reconstruída de acordo as suas componentes originais e suavizadas, após o MNF Invertido.

O MNF invertido proporcionou uma intensa suavização das assinaturas temporais dos pixels, destacando o comportamento das áreas com cultivo

agrícola para a banda 1, na polarização VH, ao passo que a VV, respondeu com inferioridade, quando comparada ambas as polarizações, respondendo melhor para áreas úmidas.

### 3.2 Classificação e Acurácia

O aprendizado de máquina ofereceu um potencial eficaz para a classificação de imagens SAR, com boa capacidade de lidar com a dimensionalidade dos dados e identificação de classes (MAXWELL; WARNER; FANG, 2018). Em estudos já realizados os classificadores SVM e KNN oferecem maiores vantagens de precisão em relação ao RF, por possuírem uma maior complexidade algorítmica para os dados de treinamento (HEYDARI; MOUNTRAKIS, 2018), vez que a estrutura do RF é relativamente simples, já para áreas da França o SVM obteve maior vantagem com 87% de precisão, seguido do RF e KNN com 85% (NDIKUMANA et al., 2018).

Contudo, essas informações não refletem necessariamente nas precisões de acordo aos achados deste estudo, onde a ordem de precisão dos modelos testados consiste em KNN, seguido do RF e por fim SVM. Na tabela 03 são apontados os valores de Exatidão Global e Kappa, bem como a classificação destes valores que variam de Moderado à Perfeita, conforme classificação de Congalton & Green (1993).

**Tabela 3:** Valores de Exatidão Global e Kappa por classificadores, safra e polarizações.

Modelos	Ano/Safra e Polarização	Exatidão Global <sup>1</sup>	Exatidão Global <sup>2</sup>	Kappa <sup>1</sup>	Kappa <sup>2</sup>	Nível de Concordância
RF	2016/2017 - VH	0,69	*	0,61	*	Substancial
	2016/2017 - VV	0,76	*	0,71	*	Substancial
	2017/2018 - VH	0,83	*	0,78	*	Substancial
	2017/2018 - VV	0,81	*	0,76	*	Substancial
SVM	2016/2017 - VH	0,67	-	0,59	-	Moderada
	2016/2017 - VV	0,72	-	0,66	-	Substancial
	2017/2018 - VH	0,78	0,80	0,72	0,74	Substancial
	2017/2018 - VV	0,79	0,81	0,74	0,76	Substancial
KNN	2016/2017 - VH	0,79	0,78	0,74	0,72	Substancial
	2016/2017 - VV	0,77	0,77	0,72	0,71	Substancial
	2017/2018 - VH	0,88	0,88	0,85	0,85	Perfeita
	2017/2018 - VV	0,87	0,86	0,83	0,83	Perfeita

\*Para o Rondon Forest foi realizado teste único. – Não foi contemplado na classificação com novos valores. <sup>1</sup>Correspondem aos valores dos primeiros testes para os classificadores SVM e KNN, com a função Radial Basis e valor de K igual a 10, respectivamente. <sup>2</sup>Correspondem aos valores dos segundos testes para os classificadores SVM e KNN, com o polinômio de ordem quatro e valor de K igual a 05, respectivamente.

O SVM se torna o modelo mais complexo por necessitar de um maior tempo de treinamento e previsão da amostra, com baixa otimização, corroborando com pesquisas já realizadas (LI et al., 2016). Em ordem comparativa, o RF possui um ganho computacional excelente, seguido do KNN, com um tempo de processamento moderado. A classificação resultante feita pelo KNN, modelo que melhor respondeu a esta análise comparativa com os melhores resultados nos testes realizados, alcançou uma concordância perfeita em ambas as polarizações, com destaque para a VH da safra 2017/2018 cujo Kappa foi de 0,85. Seguido temos o modelo RF, com um Kappa de 0,78, alcançando o nível substancial em ambas as polarizações, com destaque a VH, também da safra 2017/2018.

Em estudo já realizado foi constatado que à medida em o valor de K é aumentado, o erro do classificador aumenta subseqüentemente diminuindo a precisão (NOI; KAPPAS, 2018), porém nesta análise, ocorre o inverso. O classificador KNN foi analisado a primeira vez com o valor de K igual a 10 (Figura 10), e em seguida o valor de K foi reduzido para 5 (Figura 11), respondendo de maneira mais eficiente no primeiro teste realizado, ou seja, com um valor de K maior, para a safra 2016/2017 e 2017/2018, em ambas na polarização, atestando que a medida em que o valor de K é reduzido, a precisão também reduz.

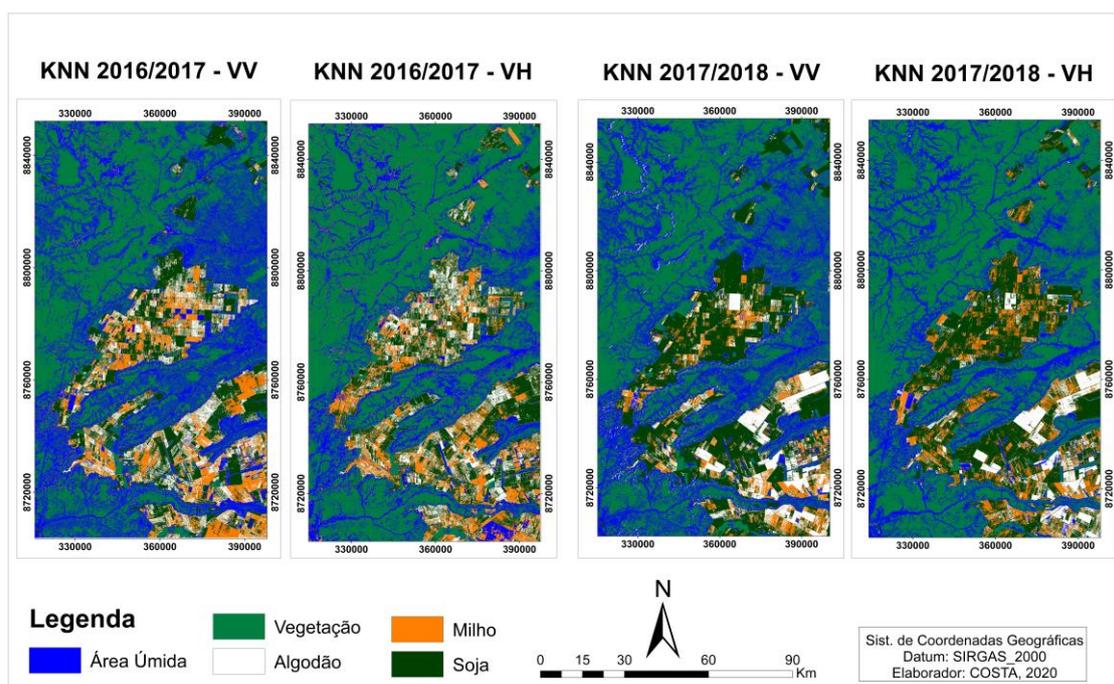


Figura 10: Classificação KNN com K sendo igual a 10.

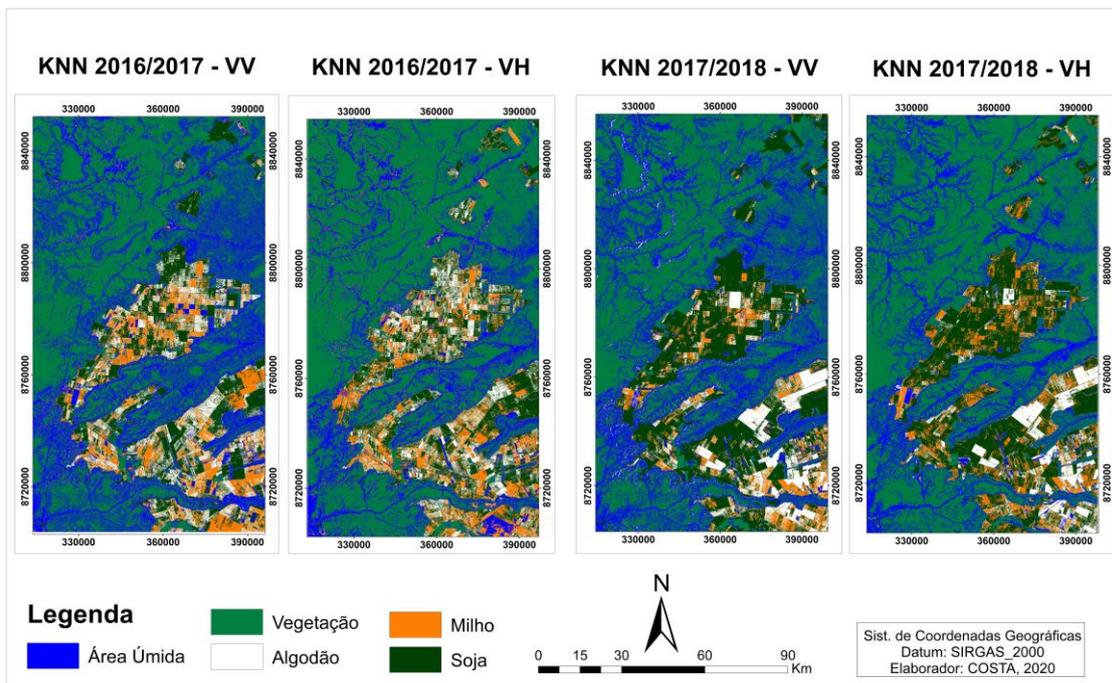


Figura 11: Classificação KNN com K sendo igual a 05.

O RF foi o classificador que alcançou precisão intermediária em relação aos demais, no entanto possui um tempo computacional muito mais eficiente, com uma redução expressiva no tempo de processamento, conforme já comprovado (SITOKONSTANTINO et al., 2018; BÉGUÉ et al., 2017), obtendo melhores resultados para a safra 2017/2018 na polarização VH (Figura 12).

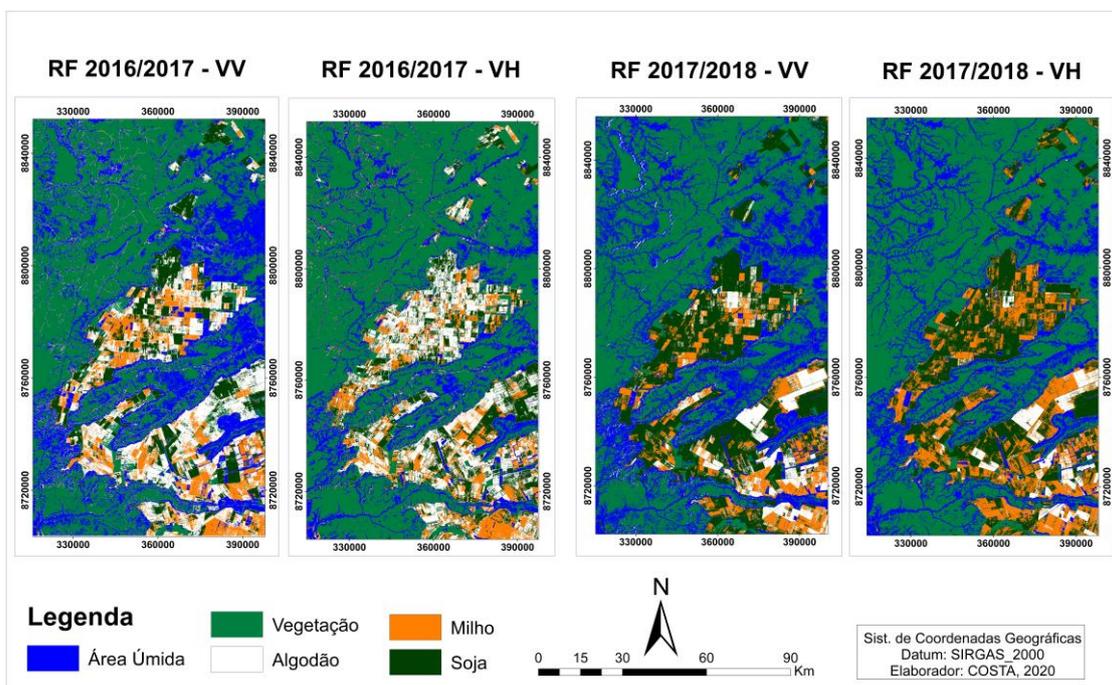


Figura 12: Classificação Randon Forest para as safras 2016/2017, 2017/2018 nas polarizações VV e VH.

O que torna este modelo eficiente frente às técnicas de Machine Learning é justamente sua otimização computacional, permitindo a exploração do comportamento de imagens SAR (BAZZI et al., 2019) com valores de Kappa consideráveis quando comparados aos demais modelos em teste e as acurácias finais, concordando com pesquisas já realizadas que possuem objetivos semelhantes (BELGIU; DRĂGU, 2016).

Já o modelo SVM alcançou valores intermediários concordando com avaliações já realizadas para o mesmo classificador em áreas agrícolas (MARDANI et al., 2019), ainda que dentro da concordância substancial para a mesma safra que os anteriores, 2017/2018, porém com melhor resposta na polarização VV seguida da VH, com os valores 0,72, 0,74 respectivamente. O SVM foi também o método com menor desempenho, chegando ao nível moderado para a safra 2016/2017, VH, com Kappa de 0,59, sendo processado por duas vezes. Na primeira vez foi utilizado a função Radial Basis de valor três (Figura 13) e no segundo processamento a função polinomial de quarta ordem (Figura 14), apenas para os anos/safras e polarizações que obtiveram melhor Kappa na primeira classificação. O uso de polinômios de grau quatro, permitiu maior precisão geral na safra 2017/2018 na polarização VV concordando com os achados de Mountrakis; Im e Ogole (2011).

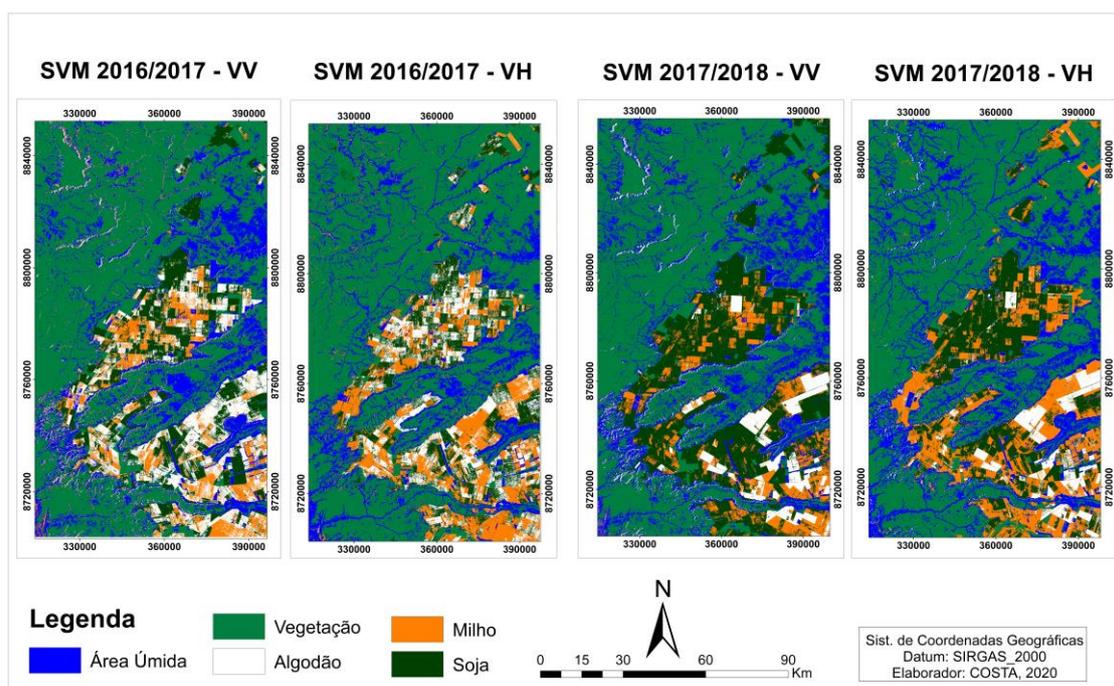
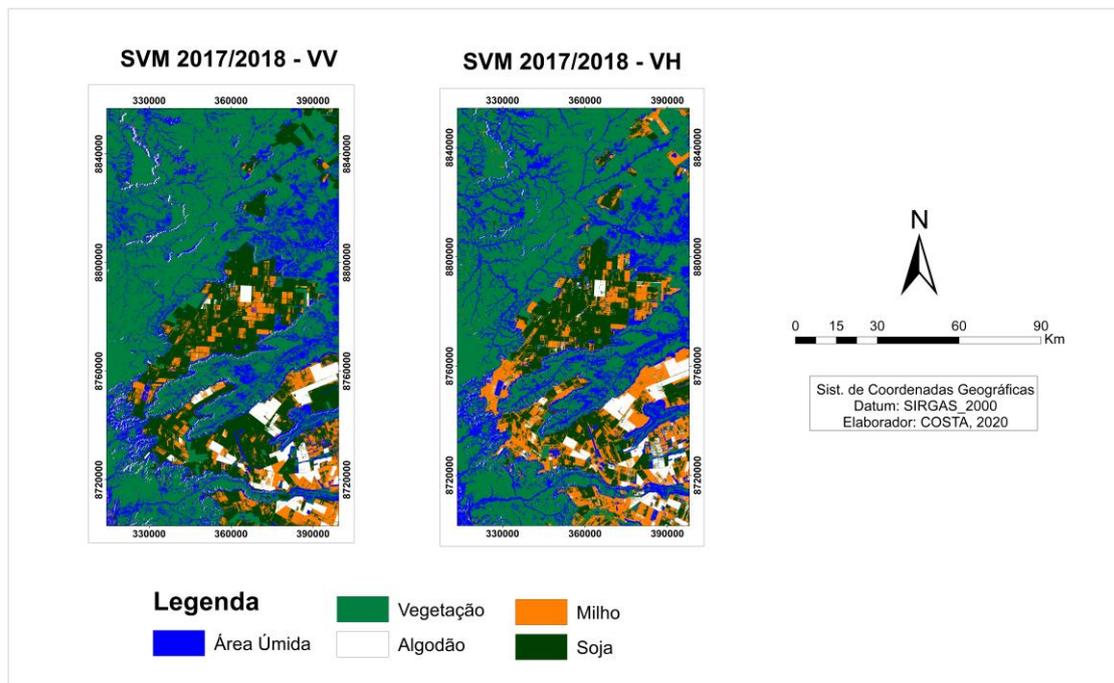


Figura 13: Classificação SVM utilizando a função Radial Basis



**Figura 14:** Classificação SVM utilizando a função polinomial de quarta ordem.

### 3.3 Matriz de Confusão

Fazendo uma análise de cada classe para ambas os modelos (Figura 15 e 16), temos que a Soja responde melhor na polarização VV para o método KNN, com 92% de acurácia geral, se mantendo estável para ambos os valores de K na safra 2017/2018, já seu pior desempenho foi na classificação RF, VH, safra 2016/2017, com 56,3%, comprovando com eficácia o comportamento da soja para essa polarização em específico (VELOSO et al., 2017). O Algodão teve desempenho semelhante na safra 2017/2018 em ambas as polarizações utilizando o KNN, com 96,7%, cujo valor de K foi 10, diferindo do SVM com a função polinomial de ordem quatro, possibilitando melhores respostas no canal VH, 94%, tendo seu pior desempenho na classificação SVM, safra 2016/2017, VH, 65%. A última cultura agrícola analisada foi o Milho, o qual mostrou uma acurácia de 92,7% para o método KNN, safra 2017/2018, VV, com maior valor de K e 56,7% no teste RF, na primeira safra, polarização VH, revalidando, no caso do Milho, os achados para a mesma polarização (XU et al., 2019; VELOSO et al., 2017; KHABBAZAN et al., 2019; SHU et al., 2020).

As classes de Área úmida e Vegetação, obtiveram uma acurácia baixa de 60% e 69,3% respectivamente. Estas classes não são foco dessa investigação, mas, influenciaram de modo direto nos resultados do índice Kappa. Onde temos

os maiores valores essas classes tenderam a estarem com menor acurácia. Os resultados encontrados estão de acordo aos achados em outras região agrícola com a utilização de imagens SAR para detecção de tipos de culturas, alcançando acurácias acima de 75%, e comprovando a eficácia da polarização VV na discriminação de alguns destes alvos (FORQUOR et al., 2014; VAN TRICHT et al., 2018), constatando que os dados SAR favorece maior precisão na classificação (CHATZIANTONIOU; PETROPOULOS; PSOMIADIS, 2017).

Traçando agora um comparativo entre as mesmas classificações, SVM e KNN, mas com valores de funções e de K distintos, temos que para o modelo SVM, a acurácia aumentou para sua melhor classe, o Milho, de 91% para 93,3%. o KNN apresentou baixa nos valores de suas melhores classe, o Algodão foi de 96,7% para 96,3 já o Milho caiu de 90% para 89,3%.

Contudo se observarmos estes valores de acurácia geral mais baixos, percebemos que ao comparar a primeira com a segunda safra, houve um aumento expressivo, isso se deu primeiro, em função da disponibilidade de amostras para treinamento dos modelos, as quais foram melhor distribuídas dentro da área de interesse para a safra 2017/2018, bem como pela dimensionalidade dos dados, estando o cubo temporal com uma quantidade de imagens inferior para a primeira safra 2016/2017 devido a algumas falhas na disponibilização de imagens. Quando essas amostras são melhores distribuídas, como ocorreu na segunda safra, a precisão dos modelos testados tende a aumentar significativamente conforme demonstrado nas matrizes (Figura 15 e 16), reafirmando desta forma, que o tamanho da amostra e a qualidade dos dados de treinamento possuem grande impacto na precisão da classificação, impacto este que pode ser maior do que a escolha dos modelos (MAXWELL; WARNER; FANG, 2018).

Quanto as diferentes polarizações, ambas podem ser utilizadas na discriminação de culturas, estando de acordo a pesquisas já realizadas, reafirmando ainda a importância de dados multitemporais para maior precisão nas classificações (MCNAIRN et al., 2009), do que aquelas com data única (SAINI; GHOSH, 2019).

RF 2016_2017_VH							RF 2017_2018_VH						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	66,0	18,7	7,0	0,0	0,0	18,33	Algodão	87,7	0,0	2,7	0,0	0,0	18,07
Vegetação	28,7	81,3	0,3	1,3	0,0	22,33	Milho	12,0	91,0	27,0	0,0	0,0	26,00
Milho	5,0	0,0	56,7	7,7	10,7	16,00	Soja	0,0	4,7	70,3	0,0	0,0	17,00
Algodão	0,3	0,0	18,0	83,7	33,0	27,00	Área Úmida	0,3	4,3	0,0	82,0	18,0	20,93
Soja	0,0	0,0	18,0	7,3	56,3	16,33	Vegetação	0,0	0,0	0,0	18,0	82,0	20,00
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	102
SVM 2016_2017_VH							SVM 2017_2018_VH						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	69,7	18,0	17,0	0,3	1,0	21,20	Algodão	92,7	1,7	4,0	0,7	0,7	19,93
Vegetação	29,3	82,0	1,0	0,0	0,0	22,47	Milho	6,3	80,7	32,3	0,0	0,0	23,87
Milho	1,0	0,0	57,0	20,3	14,3	18,53	Soja	0,7	14,0	63,3	0,0	0,0	15,60
Algodão	0,0	0,0	6,3	65,0	23,0	18,87	Área Úmida	0,3	0,0	0,3	75,0	22,3	19,60
Soja	0,0	0,0	18,7	14,3	61,7	18,93	Vegetação	0,0	3,7	0,0	24,3	77,0	21,00
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100
KNN 2016_2017_VH							KNN 2017_2018_VH						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	81,0	18,3	5,7	0,3	1,0	21,27	Algodão	96,7	1,3	3,0	0,0	0,0	20,20
Vegetação	16,0	81,7	1,3	1,0	0,0	20,00	Milho	1,0	90,0	13,3	0,0	0,0	20,87
Milho	2,7	0,0	74,3	9,0	7,3	18,67	Soja	2,0	4,7	83,3	0,0	0,0	18,00
Algodão	0,0	0,0	6,0	82,0	15,3	20,67	Área Úmida	0,3	4,0	0,3	87,0	16,7	21,67
Soja	0,3	0,0	12,7	7,7	76,3	19,40	Vegetação	0,0	0,0	0,0	13,0	83,3	19,27
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100
RF 2016_2017_VV							RF 2017_2018_VV						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	76,7	28,0	0,7	0,0	0,0	21,07	Algodão	90,3	9,7	5,7	0,0	0,0	21,13
Vegetação	21,7	72,0	0,0	0,0	0,0	18,73	Milho	8,7	88,0	17,7	0,3	0,0	22,93
Milho	0,3	0,0	81,7	11,3	7,0	20,07	Soja	0,7	2,0	76,7	0,3	0,0	15,93
Algodão	1,3	0,0	13,3	84,3	25,7	24,93	Área Úmida	0,3	0,3	0,0	78,3	30,0	21,80
Soja	0,0	0,0	4,3	4,3	67,3	15,20	Vegetação	0,0	0,0	0,0	21,0	70,0	18,20
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100
SVM 2016_2017_VV							SVM 2017_2018_VV						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	64,3	26,3	0,7	0,7	0,0	18,40	Algodão	89,3	2,3	0,0	0,0	0,3	19,93
Vegetação	31,0	72,3	0,7	0,0	0,0	20,80	Milho	8,0	91,0	15,0	2,0	0,0	23,87
Milho	4,7	1,3	74,0	11,0	7,7	19,73	Soja	2,3	5,7	85,0	0,0	0,0	15,60
Algodão	0,0	0,0	17,7	80,3	21,0	23,80	Área Úmida	0,3	1,0	0,0	60,0	30,3	19,60
Soja	0,0	0,0	7,0	8,0	71,3	17,27	Vegetação	0,0	0,0	0,0	38,0	69,3	21,00
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100
KNN 2016_2017_VV							KNN 2017_2018_VV						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	72,7	27,3	0,0	0,3	0,0	20,07	Algodão	96,7	3,3	1,3	0,0	1,3	20,53
Vegetação	26,0	72,7	0,0	0,0	0,0	19,73	Milho	2,0	92,7	6,7	0,0	0,0	20,27
Milho	0,7	0,0	84,0	9,3	7,3	20,27	Soja	1,3	2,7	92,0	0,0	0,0	19,20
Algodão	0,3	0,0	8,7	77,0	12,3	19,67	Área Úmida	0,0	0,0	0,0	76,0	22,3	19,67
Soja	0,3	0,0	7,3	13,3	80,3	20,27	Vegetação	0,0	1,3	0,0	24,0	76,3	20,33
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100

Figura 15: Matriz de Confusão, RF, SVM - Radial Basis e KNN - K igual a 10

KNN 2016_2017_VH							SVM 2017_2018_VH						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Área Úmida	78,7	18,3	6,7	0,3	0,7	20,93	Algodão	94,0	2,7	3,7	0,7	0,7	20,33
Vegetação	18,3	81,7	1,3	0,7	0,0	20,40	Milho	4,7	80,0	30,0	0,0	0,0	22,93
Milho	2,7	0,0	73,3	9,3	8,3	18,73	Soja	1,0	14,0	66,0	0,0	0,0	16,20
Algodão	0,0	0,0	6,3	81,7	17,0	21,00	Área Úmida	0,3	0,0	0,3	80,0	21,7	20,47
Soja	0,3	0,0	12,3	8,0	74,0	18,93	Vegetação	0,0	3,3	0,0	19,3	77,7	20,07
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100
KNN 2016_2017_VV							SVM 2017_2018_VV						
	Área Úmida	Vegetação	Milho	Algodão	Soja	TOTAL		Vegetação	Algodão	Milho	Soja	Área Úmida	TOTAL
Área Úmida	68,3	23,3	0,0	0,7	0,0	18,47	vegetação	69,3	0,0	0,0	0,0	30,7	20,00
Vegetação	30,3	76,7	0,0	0,0	0,0	21,40	Algodão	0,3	89,3	1,7	0,0	0,0	18,27
Milho	0,7	0,0	82,3	9,3	7,7	20,00	Milho	0,0	8,0	93,3	16,0	1,3	23,73
Algodão	0,3	0,0	10,0	78,3	13,0	20,33	Soja	0,0	2,3	4,7	84,0	0,0	18,20
Soja	0,3	0,0	7,7	11,7	79,3	19,80	Área Úmida	30,3	0,3	0,3	0,0	68,0	19,80
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100
KNN 2017_2018_VH							KNN 2017_2018_VV						
	Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL		Algodão	Milho	Soja	Área Úmida	Vegetação	TOTAL
Algodão	96,3	2,0	3,0	0,0	0,0	20,27	Algodão	96,3	4,0	1,3	0,0	1,7	20,67
Milho	1,3	89,3	12,0	0,0	0,0	20,53	Milho	2,0	91,3	6,7	0,0	0,0	20,00
Soja	2,0	5,7	84,7	0,0	0,0	18,47	Soja	1,7	3,3	92,0	0,0	0,0	19,40
Área Úmida	0,3	3,0	0,3	85,7	15,7	21,00	Área Úmida	0,0	0,0	0,0	77,0	24,0	20,20
Vegetação	0,0	0,0	0,0	14,3	84,3	19,73	Vegetação	0,0	1,3	0,0	23,0	74,3	19,73
TOTAL	100	100	100	100	100	100	TOTAL	100	100	100	100	100	100

Figura 16: Matriz de Confusão, SVM - Polinômio de quarto grau e KNN - K igual a 05

#### 4. CONSIDERAÇÕES FINAIS

A presente pesquisa avaliou o desempenho de três modelos de *Machine Learning*, RF, SVM e KNN, utilizando séries temporais Sentinel-1/SAR, com a finalidade de identificar os tipos de culturas presentes na região do Panambi, Bahia. Mostramos que as séries temporais permitem uma precisão maior na classificação, vez que é capaz de contemplar todo o ciclo de uma dada cultura, por se tratar de imagens SAR.

Os resultados encontrados para esta análise foram satisfatórios, o filtro ACDP utilizado, o qual possibilitou a reconstrução das imagens através do método MNF, auxiliou de modo positivo, retirando todo o ruído, que não era de interesse para a classificação, da frequência da imagem em questão. Conseguindo obter um Kappa de 0,85 para o classificador KNN, o modelo que melhor se destacou na distinção de alvos agrícolas. O modelo RF alcançou um Kappa de 0,78, sendo considerado intermediário nesta análise, seguido do SVM com 0,76, este último foi o que também apresentou o menor Kappa, 0,59. Quanto a polarização, esta variou em função do tipo de cultura. O Milho obteve sua melhor resposta na polarização VV, assim como a Soja, já o Algodão respondeu com valores semelhantes em ambas, VV e VH. Neste estudo conseguimos uma Acurácia geral máxima de 96,7%, para identificação do Algodão.

Como sugestão futura, fica a proposta de realizar a classificações combinando ambas as polarizações, VV e VH em um único cubo temporal, afim de refinar ainda mais as precisões dos classificadores *Machine Learning*, bem como testar valores mais elevado de K para o modelo KNN e polinômios pra o SVM. Nossa análise aponta que os dados Sentinel-1SAR podem ser efetivamente explorados para em ambas as polarizações para produzir mapas precisos de tipos de culturas considerando a variável temporal.

Os resultados mostram que a utilização de séries temporais contribuiu para precisão da classificação, favorecendo a identificação de tipos de cultura. A aquisição de imagens durante todo o ciclo da cultura, sem lacunas e interferências atmosféricas, permite a identificação da mesma dado ao seu comportamento, podendo utilizar este tipo de abordagem em qualquer área agrícola. Estes resultados apontam a possibilidade de utilizar ambas as polarizações na identificação de culturas e tipos de cobertura de uso da terra.

## 5. REFERENCIAS

- ABADE, N. A. et al. Comparative analysis of MODIS time-series classification using support vector machines and methods based upon distance and similarity measures in the brazilian cerrado-caatinga boundary. **Remote Sensing**, v. 7, n. 9, p. 12160–12191, 2015.
- ABDI, A. M. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. **GIScience and Remote Sensing**, v. 57, n. 1, p. 1–20, 2019.
- ABDIKAN, S. et al. Land cover mapping using sentinel-1 SAR data. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 41, n. July, p. 757–761, 2016.
- AKBULUT, Y. et al. NS-k-NN: Neutrosophic set-based k-nearest neighbors classifier. **Symmetry**, v. 9, n. 9, p. 1–10, 2017.
- BARBOSA, J. S. E.; SABATÉ, P.; MARINHO, M. M. O Cráton Do São Francisco Na Bahia: Uma Síntese. **Revista Brasileira de Geociências**, v. 33, n. 1, p. 03–06, 2003.
- BARGIEL, D. A new method for crop classification combining time series of radar images and crop phenology information. **Remote Sensing of Environment**, v. 198, p. 369–383, 2017.
- BAZZI, H. et al. Mapping Irrigated Areas Using Sentinel-1 Time Series in Catalonia, Spain. **Remote Sensing**, v. 11, n. 15, p. 1836, 2019.
- BÉGUÉ, A. et al. A Combined Random Forest and OBIA Classification Scheme for Mapping Smallholder Agriculture at Different Nomenclature Levels Using Multisource Data (Simulated Sentinel-2 Time Series, VHRS and DEM). **Remote Sensing**, v. 9, n. 3, p. 259, 2017.
- BELGIU, M.; CSILLIK, O. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing of Environment**, v. 204, n. January 2017, p. 509–523, 2018.
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.

- BREIMAN, L. Random Forest Draft. p. 1–33, 2001.
- C. SUN, Y. BIAN, T. ZHOU, AND J. P. Using of Multi-Source and Multi-Temporal Remote. **Remote, Multi-temporal Region, Subtropical Agriculture**, v. 19, p. 1–23, 2019.
- CAI, Y. et al. A high-performance and in-season classification system of field-level crop types using time-series Landsat data and a machine learning approach. **Remote Sensing of Environment**, v. 210, n. February, p. 35–47, 2018.
- CHATZIANTONIOU, A.; PETROPOULOS, G. P.; PSOMIADIS, E. Co-Orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. **Remote Sensing**, v. 9, n. 12, 2017.
- CLAUSS, K. et al. Estimating rice production in the Mekong Delta, Vietnam, utilizing time series of Sentinel-1 SAR data. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, n. July, p. 574–585, 2018.
- CLERICI, N.; VALBUENA CALDERÓN, C. A.; POSADA, J. M. Fusion of sentinel-1a and sentinel-2A data for land cover mapping: A case study in the lower Magdalena region, Colombia. **Journal of Maps**, v. 13, n. 2, p. 718–726, 2017.
- CONGALTON, R. G.; GREEN, K. Practical look at the sources of confusion in error matrix generation. **Photogrammetric Engineering and Remote Sensing**, v. 59, n. 5, p. 641–644, 1993.
- COSTA, D. H. Morfometria do sistema lacustre do médio curso do rio Grande e Preto oeste da Bahia GRANDE E PRETO OESTE DA BAHIA . n. September 2016, p. 1–6, 2017.
- CSORBA, A. et al. Characterization of rice agriculture in the Southern Province of Rwanda by means of microwave remote sensing. **Physics and Chemistry of the Earth**, v. 112, n. April 2018, p. 58–65, 2019.
- CUÉ LA ROSA, L. E. et al. Combining Deep Learning and Prior Knowledge for Crop Mapping in Tropical Regions from Multitemporal SAR Image Sequences. **Remote Sensing**, v. 11, n. 17, p. 2029, 2019.
- DA SILVEIRA, H. L. F. et al. Use of MSI/Sentinel-2 and airborne LiDAR data for mapping vegetation and studying the relationships with soil attributes in the Brazilian semi-arid region. **International Journal of Applied Earth**

- Observation and Geoinformation**, v. 73, n. June, p. 179–190, 2018.
- DE CARVALHO JÚNIOR, O. A. et al. Probability density components analysis: A new approach to treatment and classification of SAR images. **Remote Sensing**, v. 6, n. 4, p. 2989–3019, 2014.
- DEL'ARCO SANCHES, I. et al. Campo Verde Database: Seeking to Improve Agricultural Remote Sensing of Tropical Areas. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 3, p. 369–373, 2018.
- DUSSEUX, P. et al. Combined use of multi-temporal optical and Radar satellite images for grassland monitoring. **Remote Sensing**, v. 6, n. 7, p. 6163–6182, 2014.
- FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, v. 18, n. 1, p. 11, 2019.
- FORKUOR, G. et al. Integration of optical and synthetic aperture radar imagery for improving crop mapping in northwestern Benin, West Africa. **Remote Sensing**, v. 6, n. 7, p. 6472–6499, 2014.
- GAO, F. et al. Assessing the variability of corn and soybean yields in central Iowa using high spatiotemporal resolution multi-satellite imagery. **Remote Sensing**, v. 10, n. 9, 2018a.
- GAO, Q. et al. Irrigation mapping using Sentinel-1 time series at field scale. **Remote Sensing**, v. 10, n. 9, p. 1–18, 2018b.
- 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.
- GONG, P. et al. Stacked Autoencoder-based deep learning for remote-sensing image classification: a case study of African land-cover mapping. **International Journal of Remote Sensing**, v. 37, n. 23, p. 5632–5646, 2016.
- GREEN, A. A. et al. A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal. **IEEE Transactions on Geoscience and Remote Sensing**, v. 26, n. 1, p. 65–74, 1988.
- HE, L.; MOSTOVOY, G. Cotton Yield Estimate Using Sentinel-2 Data and an Ecosystem Model over the Southern US. **Remote Sensing**, v. 11, n. 17, p. 2000, 2019.
- HE, Y. et al. Feature Comparison and Optimization for 30-M Winter Wheat Mapping Based on Landsat-8 and Sentinel-2 Data Using Random Forest

- Algorithm. **Remote Sensing**, v. 11, n. 5, p. 535, 2019.
- HEYDARI, S. S.; MOUNTRAKIS, G. Effect of classifier selection, reference sample size, reference class distribution and scene heterogeneity in per-pixel classification accuracy using 26 Landsat sites. **Remote Sensing of Environment**, v. 204, n. February 2017, p. 648–658, 2018.
- HUANG, H.; QU, H. P. Hyperspectral remote sensing image classification based on SSDE. **Guangxue Jingmi Gongcheng/Optics and Precision Engineering**, v. 22, n. 2, p. 434–442, 2014.
- IENCO, D. et al. Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 158, n. February, p. 11–22, 2019.
- INTERDONATO, R. et al. DuPLO: A DUal view Point deep Learning architecture for time series classificatiOn. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 149, n. January, p. 91–104, 2019.
- JIA, K. et al. 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, 2014.
- KAYAD, A. et al. Monitoring within-field variability of corn yield using sentinel-2 and machine learning techniques. **Remote Sensing**, v. 11, n. 23, 2019.
- KHABBAZAN, S. et al. Crop Monitoring Using Sentinel-1 Data: A Case Study from The Netherlands. **Remote Sensing**, v. 11, n. 16, p. 1887, 2019.
- KUSSUL, N. et al. Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 6, p. 2500–2508, 2016.
- LAMBERT, M. J. et al. Estimating smallholder crops production at village level from Sentinel-2 time series in Mali's cotton belt. **Remote Sensing of Environment**, v. 216, n. June, p. 647–657, 2018.
- LEE, W. S. et al. Sensing technologies for precision specialty crop production. **Computers and Electronics in Agriculture**, v. 74, n. 1, p. 2–33, 2010.
- LI, Y. et al. Deep learning for remote sensing image classification: A survey. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 8, n. 6, p. 1–17, 2018.
- MA, L. et al. Deep learning in remote sensing applications: A meta-analysis and

- review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, n. March, p. 166–177, 2019.
- MAGALHÃES, L. A.; MIRANDA, E. E. DE. MATOPIBA: Quadro Natural - Nota Técnica 5. p. 1–41, 2014.
- MARDANI, M. et al. Integration of Machine Learning and Open Access Geospatial Data for Land Cover Mapping. **Remote Sensing**, v. 11, n. 16, p. 1907, 2019.
- MASSEY, R. et al. MODIS phenology-derived, multi-year distribution of conterminous U.S. crop types. **Remote Sensing of Environment**, v. 198, p. 490–503, 2017.
- MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784–2817, 2018.
- MCNAIRN, H. et al. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 5, p. 434–449, 2009.
- MELAAS, E. K.; FRIEDL, M. A.; ZHU, Z. Detecting interannual variation in deciduous broadleaf forest phenology using Landsat TM/ETM+ data. **Remote Sensing of Environment**, v. 132, p. 176–185, 2013.
- MOKHTARI, A. et al. Calculating potential evapotranspiration and single crop coefficient based on energy balance equation using Landsat 8 and Sentinel-2. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 154, n. June, p. 231–245, 2019.
- MONDARDO, M. a “Territorialização” Do Agronegócio Globalizado Em Barreiras - Ba: Migração Sulista, Reestruturação Produtiva E Contradições Sócioterritoriais. **Revista Nera**, v. 0, n. 17, p. 112–130, 2012.
- MOODY, D. I. et al. Crop classification using temporal stacks of multispectral satellite imagery. **Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XXIII**, v. 10198, n. May 2017, p. 101980G, 2017.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247–259, 2011.
- NASRALLAH, A. et al. A novel approach for mapping wheat areas using high

resolution sentinel-2 images. **Sensors (Switzerland)**, v. 18, n. 7, p. 1–23, 2018.

NDIKUMANA, E. et al. Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France.

**Remote Sensing**, v. 10, n. 8, p. 1–16, 2018.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. Editora Edgard Blucher Ltda. São Paulo, 2010.

NG, W.-T. et al. How much does multi-temporal Sentinel-2 data improve crop type classification? **International Journal of Applied Earth Observation and Geoinformation**, v. 72, n. July, p. 122–130, 2018.

NOI, P. T.; KAPPAS, M. Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using sentinel-2 imagery. **Sensors (Switzerland)**, v. 18, n. 1, 2018.

NOMURA, K.; MITCHARD, E. T. A. More than meets the eye: Using Sentinel-2 to map small plantations in complex forest landscapes. **Remote Sensing**, v. 10, n. 11, 2018.

OLDONI, L. V. et al. Mapeamento De Culturas Agrícolas Utilizando Dados Multitemporal Sar Polarimétricos Do Sentinel-1a. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto2**, p. 1–4, 2019.

OZDOGAN, M. The spatial distribution of crop types from MODIS data: Temporal unmixing using Independent Component Analysis. **Remote Sensing of Environment**, v. 114, n. 6, p. 1190–1204, 2010.

PALCHOWDHURI, Y. et al. Classification of multi-temporal spectral indices for crop type mapping: A case study in Coalville, UK. **Journal of Agricultural Science**, v. 156, n. 1, p. 24–36, 2018.

PELLETIER, C. et al. 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.

PERSSON, M.; LINDBERG, E.; REESE, H. Tree Species Classification with Multi-Temporal Sentinel-2 Data. **Remote Sensing**, v. 10, n. 11, p. 1794, 2018.

RENGARAJAN, R.; SCHOTT, J. R. Evaluation of sensor and environmental factors impacting the use of Multiple Sensor data for time-series applications. **Remote Sensing**, v. 10, n. 11, p. 1–27, 2018.

RIBEIRO, R. B. et al. Variabilidade Espaço-Temporal Da Condição Da Vegetação Na Agricultura Irrigada Por Meio De Imagens Sentinel-2<sup>a</sup>. **Revista**

- Brasileira de Agricultura Irrigada**, v. 11, n. 6, p. 1884–1893, 2017a.
- RIBEIRO, R. B. et al. Variabilidade Espaço-Temporal Da Condição Da Vegetação Na Agricultura Irrigada Por Meio De Imagens Sentinel-2<sup>a</sup>. **Revista Brasileira de Agricultura Irrigada**, v. 11, n. 6, p. 1884–1893, 2017b.
- RODRIGUES, M.; SILVA, D. A. Universidade De Brasília Instituto De Ciências Humanas Departamento De Geografia Programa De Pós-Graduação Em Geografia Uso De Séries Temporais Do Sensor Modis Para Identificar Diferentes Culturas Agrícolas. 2018.
- RUSSWURM, M.; K RNER, M. Multi-temporal land cover classification with sequential recurrent encoders. **ISPRS International Journal of Geo-Information**, v. 7, n. 4, 2018.
- SAINI, R.; GHOSH, S. K. Crop classification in a heterogeneous agricultural environment using ensemble classifiers and single-date Sentinel-2A imagery. **Geocarto International**, v. 0, n. 0, p. 1–19, 2019.
- SANTOS, M. A. DOS et al. O Cerrado Brasileiro: Notas Para Estudo. **Texto para discussão**, p. 15, 2010.
- SHOKO, C. et al. Characterizing the spatio-temporal variations of C3 and C4 dominated grasslands aboveground biomass in the Drakensberg, South Africa. **International Journal of Applied Earth Observation and Geoinformation**, v. 68, n. September 2017, p. 51–60, 2018.
- SHU, M. et al. Monitoring of maize lodging using multi-temporal Sentinel-1 SAR data. **Advances in Space Research**, v. 65, n. 1, p. 470–480, 2020.
- SIDIKE, P. et al. dPEN: deep Progressively Expanded Network for mapping heterogeneous agricultural landscape using WorldView-3 satellite imagery. **Remote Sensing of Environment**, v. 221, n. April 2018, p. 756–772, 2019.
- SITOKONSTANTINOOU, V. et al. Scalable parcel-based crop identification scheme using Sentinel-2 data time-series for the monitoring of the common agricultural policy. **Remote Sensing**, v. 10, n. 6, 2018.
- SON, N. T. et al. Assessment of Sentinel-1A data for rice crop classification using random forests and support vector machines. **Geocarto International**, v. 33, n. 6, p. 587–601, 2018.
- SONG, Y.; WANG, J. Mapping Winter Wheat Planting Area and Monitoring Its Phenology Using Sentinel-1 Backscatter Time Series. **Remote Sensing**, v. 11, n. 4, p. 449, 2019.

- SONOBE, R. et al. Crop classification from Sentinel-2-derived vegetation indices using ensemble learning. **Journal of Applied Remote Sensing**, v. 12, n. 02, p. 1, 2018.
- SYMEONAKIS, E. et al. Optimisation of savannah land cover characterisation with optical and SAR data. **Remote Sensing**, v. 10, n. 4, p. 1–18, 2018.
- TIAN, H. et al. Mapping winter crops in China with multi-source satellite imagery and phenology-based algorithm. **Remote Sensing**, v. 11, n. 7, p. 1–23, 2019.
- TORBICK, N. et al. 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.
- TORRES, R. et al. GMES Sentinel-1 mission. **Remote Sensing of Environment**, v. 120, p. 9–24, 2012.
- VAGLIO LAURIN, G. et al. Early mapping of industrial tomato in Central and Southern Italy with Sentinel 2, aerial and RapidEye additional data. **Journal of Agricultural Science**, v. 156, n. 3, p. 396–407, 2018.
- VALCARCE-DIÑEIRO, R. et al. Multi-temporal dual- and quad-polarimetric synthetic aperture radar data for crop-type mapping. **Remote Sensing**, v. 11, n. 13, 2019.
- VAN TRICHT, K. et al. Synergistic Use of Radar Sentinel-1 and Optical Sentinel-2 Imagery for Crop Mapping: A Case Study for Belgium. **Remote Sensing**, v. 10, n. 10, p. 1642, 2018.
- VELOSO, A. et al. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote Sensing of Environment**, v. 199, p. 415–426, 2017.
- VERBURG, P. et al. Regional Scale Mapping of Grassland Mowing Frequency with Sentinel-2 Time Series. **Remote Sensing**, v. 10, n. 8, p. 1221, 2018.
- VERMA, A.; KUMAR, A.; LAL, K. Kharif crop characterization using combination of SAR and MSI Optical Sentinel Satellite datasets. **Journal of Earth System Science**, v. 128, n. 8, 2019.
- VREUGDENHIL, M. et al. Sensitivity of Sentinel-1 backscatter to vegetation dynamics: An Austrian case study. **Remote Sensing**, v. 10, n. 9, p. 1–19, 2018.
- VRIELING, A. et al. Vegetation phenology from Sentinel-2 and field cameras for a Dutch barrier island. **Remote Sensing of Environment**, v. 215, n. November 2017, p. 517–529, 2018.

- WANG, L. et al. Crop Classification Based on a Novel Feature Filtering and Enhancement Method. **Remote Sensing**, v. 11, n. 4, p. 455, 2019.
- WANG, X. et al. Crop classification from Sentinel-2-derived vegetation indices using ensemble learning. **Journal of Applied Remote Sensing**, v. 12, n. 02, p. 1, 2018.
- WEI, C. et al. Estimation and mapping of winter oilseed rape LAI from high spatial resolution satellite data based on a hybrid method. **Remote Sensing**, v. 9, n. 5, 2017.
- WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, n. August 2019, p. 111402, 2020.
- WEST, H. et al. Assessing vegetation response to soil moisture fluctuation under extreme drought using sentinel-2. **Water (Switzerland)**, v. 10, n. 7, p. 1–22, 2018.
- XU, L. et al. Crop classification based on temporal information using Sentinel-1 SAR time-series data. **Remote Sensing**, v. 11, n. 1, p. 1–18, 2019.
- ZHANG, X. et al. Mapping up-to-date paddy rice extent at 10 M resolution in China through the integration of optical and synthetic aperture radar images. **Remote Sensing**, v. 10, n. 8, p. 1–26, 2018.
- ZHOU, T.; LI, Z.; PAN, J. Multi-feature classification of multi-sensor satellite imagery based on dual-polarimetric sentinel-1A, landsat-8 OLI, and hyperion images for urban land-cover classification. **Sensors (Switzerland)**, v. 18, n. 2, p. 1–20, 2018.
- ZHU, X. X. et al. Deep learning in remote sensing: a review. n. December, 2017.