



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA



Ana Flávia Carrara Bonamigo

Mapeamento de pastagens e potencial de intensificação na região
Oeste do Estado de São Paulo.

CAMPINAS
2021



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA



Ana Flávia Carrara Bonamigo

Mapeamento de pastagens e potencial de intensificação na região
Oeste do Estado de São Paulo.

Trabalho de Conclusão de Curso apresentado
como requisito parcial para obtenção do título de
Engenheira Agrícola à Faculdade de
Engenharia Agrícola da Universidade Estadual
de Campinas.

Orientadora: Dra. Julianne de Castro Oliveira

CAMPINAS
2021

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

B641m Bonamigo, Ana Flávia Carrara, 1997-
Mapeamento de pastagens e potencial de intensificação na região Oeste do Estado de São Paulo / Ana Flávia Carrara Bonamigo. – Campinas, SP : [s.n.], 2021.

Orientador: Julianne de Castro Oliveira.
Trabalho de Conclusão de Curso (graduação) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Pastagens. 2. Satélites artificiais em agricultura. 3. Geoprocessamento. 4. Análise de séries temporais. I. Oliveira, Julianne de Castro. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

Informações adicionais, complementares

Palavras-chave em inglês:

Pastures

Artificial satellites in agriculture

Geoprocessing

Time series analysis

Titulação: Engenheiro Agrícola

Banca examinadora:

Aliny Aparecida dos Reis

Gleyce Kelly Dantas Araújo Figueiredo

Data de entrega do trabalho definitivo: 13-01-2021



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA AGRÍCOLA



Ana Flávia Carrara Bonamigo

BANCA EXAMINADORA

.....
Dra. Julianne de Castro Oliveira
Orientadora

.....
Dra. Aliny Aparecida dos Reis

.....
Profa. Dra. Gleyce Kelly Dantas Araújo Figueiredo

AGRADECIMENTOS

Agradeço aos meus pais, Jaime e Laís, por terem me dado tanto amor e suporte, por terem sempre me apoiado e me incentivado em todos os passos na minha trajetória. Agradeço ao meu namorado Jonesmar, por seu amor e companheirismo em tantos momentos que tivemos. Agradeço à minha orientadora Julianne por todos os ensinamentos, conhecimentos e todo o suporte que me proporcionou, e por ter feito parte de minha formação profissional. Agradeço às minhas amigas e amigos da faculdade, Bárbara, Brunno, Fernanda, Isabela e Juliana, por todos os momentos bons, com certeza levaremos uns aos outros no coração. Agradeço aos meus colegas e professores do Laboratório de Geoprocessamento, Aliny, Bruna, Gisela, Gleyce, João e Yane, pelo acolhimento e por todo o conhecimento compartilhado. Agradeço a todos que de alguma forma fizeram parte de minha trajetória durante o trabalho desenvolvido e durante a graduação na Faculdade de Engenharia Agrícola, levarei todos comigo com muito carinho para a vida toda.

RESUMO

As pastagens possuem dinâmicas complexas de manejo e o monitoramento dessas áreas com dados de sensoriamento remoto mostra-se promissor para análise da produtividade e potencial de produção. Neste âmbito, uma variedade de métodos de classificação de imagens tem sido proposta; sendo um deles o algoritmo *Time-Weighted Dynamic Time Warping* (TWDTW). Desta forma, o objetivo deste estudo foi mapear manejos de pastagem (manejo tradicional, manejo com integração lavoura-pecuária e manejo com sinais de degradação) em quatro fazendas na região Oeste do Estado de São Paulo entre os anos de 2016 e 2018. Para isto, foi utilizado o algoritmo TWDTW e dados de séries temporais do índice de vegetação *Normalized Difference Vegetation Index* (NDVI) do sensor MODIS e do satélite Sentinel-2. As séries temporais de NDVI das imagens de ambos os sensores foram pré-processadas para a remoção de nuvens e ruídos, interpoladas para o preenchimento de dados faltantes e filtradas com o filtro Savitzky-Golay. A classificação das séries temporais de NDVI com o TWDTW utilizou 70% das amostras para treino e 30% para teste. Posteriormente à classificação, foi realizada a segmentação dos mapas por meio do algoritmo Simple Linear Interactive Clustering (SLIC), de forma a regionalizar os padrões de manejo ao redor da área de estudo. De forma geral, as classificações obtidas a partir das imagens do sensor MODIS tiveram uma boa performance para os períodos de análise nas fazendas da área de estudo (acurácia global de 78%). Para as classificações com as imagens do Sentinel-2 observou-se grande diferença de performance entre as classificações do período de 2016-2017 em relação ao período de 2017-2018 (acurácia global variando de 29 a 58% entre as fazendas considerando todo o período de estudo de 2 anos), sendo este último período mais coerente com os manejos existentes. A maior parte das áreas das fazendas apresentou o manejo tradicional e manejo com sinais de degradação. Os resultados de segmentação para as imagens MODIS mostraram-se condizentes com a realidade das áreas no entorno das fazendas, e puderam captar duas macrorregiões com manejos predominantes - pastagens com baixa produtividade na porção à noroeste da região e manejo tradicional com produtividade intermediária nas regiões central e sul. As segmentações dos mapas obtidos com as imagens Sentinel-2 puderam captar os limites dos talhões, demonstrando, entretanto, limitações quando os tamanhos destes são heterogêneos na propriedade. Perspectivas futuras apontam o uso da segmentação como etapa anterior à aplicação do algoritmo TWDTW como forma de melhorar a performance do mapeamento dos manejos das pastagens na região.

Palavras-chave: Pastagens, Satélites artificiais em agricultura, Geoprocessamento, Análise de séries temporais

ABSTRACT

Pasture areas have complex management dynamics, and monitoring these areas using remote sensing data is a promising tool for analyzing productivity and production potential. Within the scope of remote sensing, various image classification methods have been proposed, and one of them is the Time-Weighted Dynamic Time Warping (TWDTW) algorithm. Therefore, the objective of the present study was to map different pasture management (traditional management, crop-livestock management, and management with signs of degradation) in four farms located in the western region of São Paulo state, between the years 2016 and 2018. For this purpose, we used the TWDTW algorithm and Normalized Difference Vegetation Index (NDVI) time series data from the MODIS sensor and the satellite Sentinel-2. The NDVI time series images were pre-processed in order to remove pixels flagged as cloudy and noisy, and the missing values were interpolated and filtered using the Savitzky-Golay smoothing filter. The time series classification with TWDTW used 70% of the samples for training and 30% for testing. Next step was to perform a segmentation in the classified maps using the Simple Linear Interactive Clustering (SLIC) algorithm in order to obtain a regionalization of the management in the surrounding areas. In general, the classifications obtained from the MODIS sensor images performed well in the two considered periods in the study area (overall accuracy of 78%). For the classifications with the Sentinel-2 MSI sensor images, it was possible to observe a significant difference between the classifications for 2016-2017 compared to that of the 2017-2018 (overall accuracy varying from 29% and 58%, considering the two years), being this last period more consistent with the existing management. Most of the farms showed the traditional and degraded management. The segmentation results for the MODIS images were consistent with the realities of the surrounding areas, and were able to consistently capture two macro-regions with different predominant management - pasture with low productivity on the northwest and traditional management with intermediated productivity on the central and south regions. The map segmentations obtained with the Sentinel-2 images were able to capture the boundaries of the fields and paddocks, but showed limitations when their sizes are heterogeneous in the farm. Future perspectives are the use of this segmentation as a step prior to the application of the TWDTW algorithm for improving the mapping performance of the pasture management in the region.

Key-words: Pastures, Artificial satellites in agriculture, Geoprocessing, Time series analysis

Sumário

1. Introdução	1
2. Revisão Bibliográfica	3
2.1 Sensoriamento remoto aplicado ao monitoramento de pastagens	3
2.2 Manejo de Pastagens e séries temporais de índice de vegetação	5
2.3 Método <i>Time-Weighted Dynamic Time Warping</i>	8
2.4 Segmentação de imagens de satélite	10
3. Material e Métodos	13
3.1 Caracterização da área de estudo	13
3.2 Aquisição das imagens de satélite	15
3.3 Aplicação do algoritmo Time-Weighted Dynamic Time Warping (TWDTW)	17
3.4 Segmentação utilizando técnica de superpixel - SLIC	19
4. Resultados	21
5. Discussão	32
6. Conclusões	36
7. Referências Bibliográficas	37

1. Introdução

O Brasil possui área de pastagem de, aproximadamente 158,6 milhões de hectares, considerando-se áreas plantadas e naturais (IBGE, 2019). A maior parte dessas áreas destina-se à produção de carne bovina, tendo o Brasil como o maior exportador mundial com uma produção de cerca de 9,9 milhões de toneladas em 2018 (USDA, 2019). A maior parte dessa produção de bovinos é feita em sistema de pastagem extensiva sob diferentes manejos e condições de utilização.

A pecuária desenvolvida com pastagem extensiva é uma atividade que tem sido historicamente penalizada no Brasil como pouco exigente em uso de insumos e tecnologia, culminando em situações de degradação (Dias-Filho, 2014). No Brasil, a degradação de pastagens está presente em todas as regiões, e há estimativas que entre 50% e 70% dessas áreas apresentam algum grau de degradação (Dias-Filho, 2014). Dentro deste contexto, uma importante premissa para o aumento da produtividade de carne bovina é o melhoramento da qualidade dos pastos e também a inversão de processos de degradação, que é a maior causa da perda de qualidade da forragem em países tropicais (Aguiar, 2017). Aliado a isso, em virtude da maior demanda por alimentos e da necessidade de reduzir o desmatamento, a busca por sistemas agropecuários que aliem de forma sinérgica produção e sustentabilidade, vem aumentando anualmente (Matos et al., 2019).

De uma forma geral, os solos ocupados por pastagens são marginais quando comparados àqueles usados pela agricultura de grãos, apresentando problemas de fertilidade natural, acidez, topografia, entre outros (Macedo e Araújo, 2019). Esses problemas têm sido mitigados pela utilização de tecnologias importantes e sistemas alternativos de produção, como os sistemas de integração lavoura-pecuária (iLP) e integração lavoura-pecuária-floresta (iLPF). Segundo Balbino et al. (2011, 2019), o sistema conhecido por iLP integra o componente agrícola e pecuário em rotação na mesma área, podendo ser em consórcio ou sucessão, e o sistema conhecido por iLPF integra os componentes agrícola e pecuário em rotação, consórcio ou sucessão, incluindo também o componente florestal. Sendo sistemas com premissa de diversificação do uso da terra, os sistemas de iLP e iLPF podem servir como alternativa de recuperação de pastagens degradadas, assim como podem favorecer a agricultura anual (Macedo e Araújo, 2019). Além disso, algumas aplicações de sistemas de iLP apontam seu potencial de melhorar a capacidade de estocagem de carbono pelo solo devido a seu mínimo revolvimento e, conseqüentemente, a redução da emissão de carbono na atmosfera (Carvalho et al., 2010).

As pastagens possuem dinâmicas complexas de manejo e o monitoramento dessas áreas no tempo e no espaço em que ocorrem, como os próprios processos de degradação e de intensificação, são essenciais para análise da produtividade e entendimento de seu potencial de produção. Dados de sensoriamento remoto e ferramentas de geoprocessamento têm se mostrado promissoras para o monitoramento dessas áreas, proporcionando informações para a análise de padrões temporais e espaciais das mudanças no ecossistema, bem como de estimativas de características biofísicas (Atzberger, 2013; Numata et al., 2007).

Dentre as possibilidades do uso de dados de sensoriamento remoto, destaca-se o monitoramento espaço-temporal por meio da utilização de séries temporais de índices espectrais de vegetação, tais como o *Normalized Difference Vegetation Index* (NDVI) e o *Enhanced Vegetation Index* (EVI), obtidos por imagens de satélite. Como exemplo, destacam-se os produtos de NDVI e EVI do sensor *Moderate-Resolution Imaging Spectroradiometer* (MODIS), que são bem estabelecidos em aplicações para mapeamento e monitoramento de grandes áreas de cultivo em diferentes níveis de escala (Wardlow e Egbert, 2010; Manabe et al. 2018). Mais recentemente, também têm sido feitas aplicações dos satélites da família Sentinel, na qual as imagens de radar do Sentinel-1 e as ópticas com 10 metros de resolução espacial do sensor *Multispectral Instrument* (MSI) do Sentinel-2 adquiridas a cada 5 dias, são promissoras para estudos de práticas e manejos de culturas em diversos sistemas de produção agrícola (Bégué et al., 2018). Os produtos de ambos os satélites se destacam também por serem disponibilizados de forma gratuita.

Dentro de uma ampla gama de produtos de sensoriamento remoto, uma grande variedade de métodos de classificação tem sido propostos e utilizados para o mapeamento e monitoramento da cobertura da terra (Rodriguez-Galiano et al., 2012). Os métodos de classificação incluem diversos tipos de abordagens utilizando algoritmos estatísticos e de aprendizagem de máquina. Um dos algoritmos que têm sido utilizados na área de aprendizado de máquinas para classificação de cobertura da terra é o algoritmo *Time-Weighted Dynamic Time Warping* (TWDTW), o qual utiliza a similaridade entre duas ou mais séries temporais extraídas da área de estudo para fazer a classificação do uso e cobertura da terra (Maus et al., 2016). Levando-se em consideração áreas com pastagens intensificadas em sistemas de iLP e iLPF, a utilização de um algoritmo que identifica o aspecto temporal das áreas, como o TWDTW, pode auxiliar na identificação de mudança de uso da terra e também na sucessão de culturas, característicos desses sistemas. Manabe et al. (2018) utilizaram o algoritmo TWDTW para identificação de sistemas de integração com imagens do sensor MODIS, onde áreas de pastagem com iLP puderam ser identificadas e diferenciadas de outras classes, como lavoura e floresta nativa, demonstrando o potencial deste algoritmo para mapeamento destes sistemas de produção. O estudo então desenvolvido teve como foco principal os sistemas iLP, sendo destacadas as limitações do método TWDTW no que diz respeito à resolução espacial das imagens MODIS. Dessa forma, a utilização deste método aplicado à identificação de manejos específicos de pastagem, assim como a utilização de imagens com maior resolução espacial, são alternativas até então inéditas em sistemas de produção brasileiros e poderiam contribuir com o monitoramento de áreas de pastagem em diferentes condições e auxiliar na identificação de regiões com potencial de intensificação de uso das pastagens para posteriores incentivos e tomadas de decisão locais.

Dentro desse contexto, o presente estudo teve como objetivo mapear diferentes manejos de pastagem (manejo tradicional, manejo de integração lavoura-pecuária e manejo com sinais de degradação) na região oeste do estado de São Paulo utilizando o algoritmo TWDTW e dados de séries temporais de NDVI do sensor MODIS e do satélite Sentinel-2. Dessa forma, buscou-se então identificar, monitorar e comparar sistemas de

manejos de pastagens utilizando imagens de satélite com diferentes resoluções espaço-temporais, bem como avaliar o potencial de generalização dessa abordagem.

2. Revisão Bibliográfica

2.1 Sensoriamento remoto aplicado ao monitoramento de pastagens

De acordo com Mather e Koch (2011), um princípio fundamental dentro do uso de dados de sensoriamento remoto é que diferentes objetos na superfície terrestre e na atmosfera refletem, absorvem, transmitem e emitem energia eletromagnética em diferentes proporções dentro da gama de comprimentos de onda, e essas diferenças permitem que estes objetos na superfície terrestre sejam identificados de forma única. O fato dos diferentes instrumentos de imageamento no sensoriamento remoto possuírem diferentes resoluções (espacial, espectral, radiométrica e temporal) está relacionado com o uso que é feito dos dados coletados por estes sistemas (Mather e Koch, 2011).

O uso de diferentes sensores nas aplicações de monitoramento da produção agrícola explora as diferentes características e como cada uma pode ser utilizada dentro do âmbito do monitoramento agrícola. De acordo com Atzberger (2013), técnicas de sensoriamento remoto são amplamente utilizadas na agricultura e na área agrônômica pela característica da produção agrícola de ter consistentes padrões temporais que são relacionados aos ciclos das culturas comerciais. O sensoriamento remoto pode contribuir proporcionando um retrato temporal e assertivo do setor agrícola, por ter capacidade de combinar informação de grandes áreas com alta frequência de revisita (Atzberger, 2013).

O sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS), a bordo das plataformas Terra e Aqua, proporciona um valioso conjunto de informações de alta resolução temporal (imagens diárias e diferentes composições temporais). O sensor contém 7 bandas espectrais desenvolvidas especificamente para mapeamento da superfície terrestre com 250 metros e 500 metros de resolução espacial (Pittman et al., 2010). Pittman et al. (2010) argumenta que o sensor MODIS pode não ser uma opção viável para o mapeamento de cultivos em algumas regiões pela sua dificuldade em mapear cultivos em áreas pequenas. Entretanto, o sensor é capaz de proporcionar meios de identificar cultivos em áreas extensas.

O estudo de Estel et al. (2015) argumenta que os sensores com resolução espacial como a do sensor MODIS proporcionam dados consistentes de fazendas de produção agrícola em uma gama de escalas geográficas, e que o sensor MODIS em particular permite capturar dinâmicas da vegetação que vão de sazonal à escala de década com uma resolução temporal relativamente alta. Este possui dados disponíveis desde o ano de 2000 sendo muito utilizado em estudos de mudança de uso da terra.

Assim, apesar de terem resolução espacial de 250 e de 500 m, os produtos de índice de vegetação do sensor MODIS possuem resolução temporal considerada adequada para monitoramento agrícola (8 dias entre as duas plataformas Terra e Aqua) e, no âmbito de pastagens, têm potencial de serem utilizados devido às suas características espectrais, de histórico de dados e de período de revisita.

O estudo de Nitze et al. (2015) utilizou informação temporal do sensor MODIS obtidas de 2001 a 2011 para mapear o uso e cobertura da terra com classes como floresta, pastagens e cultura anual, e conseguiu diferenciar classes de pastagens altamente manejadas e moderadamente manejadas; concluindo que a informação dos alvos entre os anos e também seu comportamento dentro o mesmo ano pode auxiliar na separabilidade das classes. Green et al. (2016) utilizou informações do sensor MODIS para o mapeamento e modelagem de forragem em áreas de pastagem na Irlanda, enfatizando que o uso deste sensor tem resolução espacial satisfatória e disponibilidade de imagens desde 2000, superando sensores que já não estavam mais disponíveis desde 2012. O estudo de Picoli et al. (2018) utilizou imagens do sensor MODIS para mapeamento de diferentes culturas anuais, pastagem e floresta natural no estado do Mato Grosso, cobrindo área de aproximadamente 900000 km² de área mapeada. O estudo destaca que o mapeamento das pastagens em grande período no tempo evidencia a importância do mapeamento dessa cultura frente ao desmatamento. O estudo com pastagens feito por Jakimow et al. (2018), entretanto, ao reportar o mapeamento de pastagens no bioma Amazônia, analisou que os mapeamentos promissores no entendimento da dinâmica das pastagens, principalmente em propriedades familiares, seriam aqueles com resolução espacial como com o sensor Sentinel-2 (resolução espacial de 10 m), unificados com imagens como MODIS (resolução espacial de 250 m) e Landsat (resolução espacial de 30 m).

A missão Sentinel-2 oferece uma combinação sem precedentes de cobertura sistemática no globo terrestre, com alta resolução temporal (5 dias) sob as mesmas condições de visada, alta resolução espacial (10 metros) e um largo ângulo de visada (295 km) para observações multiespectrais de 13 bandas presentes nos espectros eletromagnéticos do visível, infravermelho próximo e infravermelho de ondas curtas (Gascon et al., 2017), além de serem disponibilizadas de forma gratuita. Essas características possibilitam um frequente monitoramento e mapeamento de áreas agrícolas, e têm aberto caminhos para novos desafios relacionados à diversificados sistemas de produção em escala global (Defourny et al., 2019).

A resolução espacial do sensor Sentinel-2 tem potencial de proporcionar alta precisão em monitoramento de áreas que possuem alta variabilidade, e também indicar dentro de uma mesma área de cultivo agrícola as variações de produção que podem estar presentes. Lebourgeois et al. (2017), que propôs mapeamento de áreas de agricultura familiar em região de Madagascar, argumenta que o monitoramento em regiões que possuem alta densidade de propriedades de produção familiar demonstrou que a resolução de 10 metros do sensor Sentinel-2 apresenta maior acurácia.

Estudos utilizaram imagens do Sentinel-2 para mapeamento agrícola e de pastagens. Belgiu e Csillik (2018) utilizou metodologia baseada em pixel e baseada em objetos com o sensor Sentinel-2 para mapeamento de área agrícola, onde o mapeamento baseado em objeto demonstrou melhor performance do que o mapeamento de cada pixel da imagem. O estudo desenvolvido por Punalekar et al. (2018) utilizou os dados do sensor Sentinel-2 para modelagem de biomassa em pastagem em região da Inglaterra, onde a resolução espaço-temporal do sensor Sentinel-2 foi considerada adequada para o monitoramento da biomassa de pastagens, além de ser de amplo acesso para utilização.

Ambos os tipos de imagens de satélite, do sensor MODIS e do satélite Sentinel-2, demonstraram em diversos estudos potenciais e limitações de suas aplicações para o monitoramento de diferentes áreas e dinâmicas agrícolas, sendo então de extrema importância analisar as características de cada um dos tipos de imagem (e tipos de resolução) para entender suas aplicações mais adequadas.

2.2 Manejo de Pastagens e séries temporais de índice de vegetação

As pastagens no Brasil possuem diferentes níveis de produtividade, e um dos fatores que influenciam nesse aspecto é o manejo praticado nas propriedades. De acordo com Santos e Corrêa (2009), o manejo adequado de pastagens tropicais permite o melhor aproveitamento de seu potencial de produção. Para se explorar ao máximo o potencial de produção das plantas forrageiras, é preciso considerar suas curvas de crescimento, após cada corte e ao longo das estações do ano, e observa-se de modo geral que a produção é maior no período de verão, quando as condições de temperatura, de luminosidade e de precipitação são favoráveis ao desenvolvimento das plantas (Santos e Corrêa, 2009). Considerando as características gerais de um sistema de pastagem extensivo, pastagens com diferentes manejos apresentam diferenças dentro do comportamento da biomassa ao longo do tempo, apresentando algumas características que os diferenciam. Os manejos principais a serem considerados no presente trabalho são pastagem com manejo tradicional, pastagem com manejo intensificado e pastagem com sinais de degradação.

Nos sistemas tradicionais de manejo da pastagem, o ajuste da lotação é feito com base na produção de inverno e dessa forma, no período de verão, há maior sobra de forragem (Santos e Corrêa, 2009). No manejo intensificado em sistema de integração lavoura-pecuária, o uso da terra é intensificado com consórcio, sucessão, rotação de culturas e produção animal (Machado et al., 2011). No caso de pastagem degradadas ou com sinais de degradação, a característica é a contínua perda de vigor, produtividade, e de capacidade de recuperação natural para sustentar a produção animal (Macedo e Araújo, 2019).

O sensoriamento remoto tem sido amplamente utilizado como meio de monitoramento de sistemas agrícolas como culturas anuais e pastagens, e uma das ferramentas utilizadas dentro do monitoramento agrícola são as séries temporais das imagens de satélite. Kuenzer et al. (2015) indica que dentro do contexto do sensoriamento remoto da superfície, a análise de séries temporais é entendida como o monitoramento intenso e temporário da dinâmica que ocorre na superfície por um determinado período de tempo, e exige uma quantidade razoável de informação de imagens de satélite para utilização e estudo. Explica também que nas últimas décadas, a disponibilização dos dados advindos de diversos satélites possibilitou o acesso a milhões de imagens de forma gratuita, e essa facilidade no acesso aliada ao melhoramento dos hardwares e softwares levou ao aumento substancial dos estudos que utilizam a abordagem com séries temporais pela comunidade de sensoriamento remoto.

Kuenzer et al. (2015) contextualiza que a análise de séries tem sido aplicada a uma gama de variáveis derivadas do sensoriamento remoto, desde bandas espectrais individuais e índices derivados dos dados, até predições de parâmetros biofísicos. No caso de índices de vegetação, estes são geralmente utilizados na caracterização da dinâmica da vegetação dentro das diferentes escalas temporais e diferentes processos naturais da vegetação (Kuenzer et al., 2015). Assim, o uso de séries temporais de índices de vegetação em uma área de cultivo agrícola permite monitorar o desenvolvimento de certa cultura e comparar os diferentes comportamentos ao longo do tempo. De acordo com Jakimow et al. (2018) em seu estudo com pastagens intensificadas, as práticas de manejo de pastagens e as frequências de intervenções afetam as características espectro-temporais das pastagens, apontando o sensoriamento remoto como uma ferramenta importante para o monitoramento de processos de intensificação de uso. Dentro do contexto, surge a análise de séries temporais derivadas de imagens de satélite para a identificação de diferentes manejos das pastagens.

Muitos estudos que trabalharam com monitoramento do efeito do pastejo em áreas de cultivo utilizaram as medições de índices de vegetação (IV) (Green et al., 2016). Um desses índices de vegetação é o NDVI (Equação 1). Dentro do uso em sensoriamento remoto, o NDVI descreve a diferença normalizada entre as bandas do vermelho (650 nm) e do infravermelho próximo (700 a 1300 nm), e cada uma dessas bandas tem reflectância diferente em relação à vegetação - a baixa reflectância na banda do vermelho indica a absorção de luz nessa faixa de comprimento de onda pelos pigmentos da planta, e a alta reflectância na região da banda do infravermelho próximo é associada com a estrutura interna das folhas. Huete et al. (2002) indica que o NDVI é associado à quantidade absoluta de biomassa nas plantas e é um índice de vegetação suficientemente estável para permitir comparações e detecção de mudanças sazonais e interanuais de crescimento e desenvolvimento da vegetação.

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

onde:

IVP é a reflectância da banda do infravermelho próximo;

V é a reflectância da banda do vermelho.

Portanto, séries temporais de NDVI utilizadas como fonte de informação sobre o manejo das pastagens se justificam devido à associação deste índice de vegetação com a quantidade de biomassa presente na área. Para cada um dos manejos - tradicional, com integração lavoura-pecuária e pasto com sinais de degradação - existe estreita relação entre o comportamento de sua série temporal com o manejo realizado na pastagem. As séries temporais possuem dinâmicas do índice de vegetação que indicarão o comportamento da biomassa na área, e essa variação no tempo é uma informação chave para identificação do tipo de manejo da pastagem.

A variação da biomassa em sistemas tradicionais de pastagem tem sazonalidade bem definida durante o ano, onde existe uma redução da biomassa no período do inverno, em contraste com a alta disponibilidade de forragem no verão (Figura 1a). Assim, a série

temporal possui os dois momentos do ano bem definidos. Dentro de pastagens que utilizam sistema de integração lavoura-pecuária a série temporal apresenta um pico de biomassa devido à rotação com a cultura anual - por exemplo com soja, sorgo ou milho - que acontece geralmente no verão entre os meses de novembro e fevereiro, que representa semeadura, desenvolvimento e senescência da cultura de ciclo curto (Figura 1b). Logo após a colheita da cultura utilizada como rotação, a pastagem é implantada e é tratada como a cultura do inverno, ocorrendo seu desenvolvimento e uso como suporte durante os meses de abril a outubro (Figura 1b). As pastagens que apresentam sinais de degradação podem também apresentar sazonalidade durante o ano com maior disponibilidade de biomassa durante o verão, e o que diferencia de uma pastagem tradicional é a menor biomassa disponível nos períodos, demonstrando baixa capacidade da pastagem recuperar-se do pastejo e do período do inverno (Figura 1c).

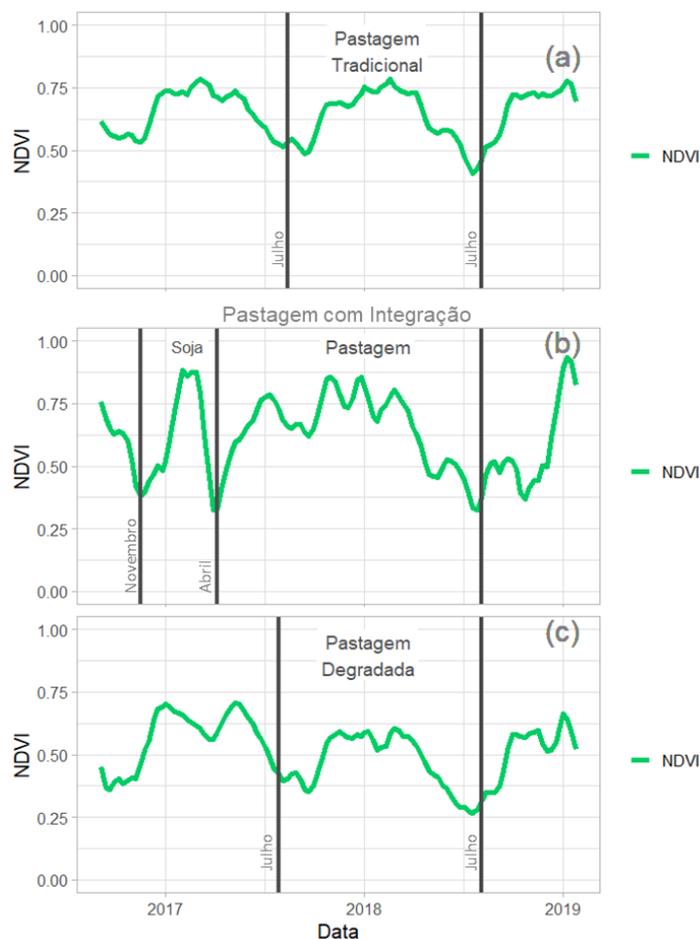


Figura 1. Exemplo de série temporal de NDVI de pastagem com (a) manejo tradicional, (b) manejo com integração lavoura-pecuária, e (c) degradada, onde as linhas verticais indicam o período de dinâmica temporal que é característica dos manejos em questão.

De acordo com Gómez et al. (2016), a aquisição de séries temporais é importante na diferenciação de tipos de uso e cobertura da terra e a variabilidade intra-anual é particularmente interessante nesse reconhecimento dos tipos de cobertura existentes, determinado pela fenologia da vegetação presente (por exemplo, floresta natural,

pastagens plantadas). Dentro do contexto de utilização das informações temporais, Gómez et al. (2016) indica que a informação espectral multitemporal das séries podem ser utilizadas por meio de estatísticas diversas extraídas das séries temporais, e essas informações, por sua vez, podem ser visualizadas como variáveis descritivas ou preditivas, conhecidas também como atributos da imagem. Assim, objetivando-se criar um mapeamento direcionado à quaisquer informações que se deseja como resultado na imagem, utilizam-se algoritmos que fazem a classificação da imagem de acordo com os atributos, isto é, características de cada pixel, para geração de mapas de classificação de uso e cobertura da terra.

Diversos métodos de classificação têm sido utilizados em estudos de uso e cobertura da terra com o uso de informação de sensoriamento remoto (Rodríguez-Galiano et al., 2012). O estudo de Aguiar et al. (2017) utilizou sete métricas derivadas da série temporal do índice de vegetação *Enhanced Vegetation Index* (EVI2) para extrair informações da série temporal de áreas de pastagem na região do Cerrado durante doze anos de imagens coletadas do sensor MODIS, e assim realizar análises e comparações das métricas entre um ano e outro, e verificaram pastagens que possuíam algum nível de degradação, pastagens que estavam em processo de recuperação e pastagens que sofreram intervenção antropogênica. O estudo desenvolvido por Pereira et al. (2018) estimou a área de pastagens degradadas no Cerrado a partir das séries temporais de análise principal da tendência da curva de NDVI para detectar anomalias no NDVI, sendo esse o indicador para o local ser indicado como degradado ou não-degradado.

Já o estudo desenvolvido por Jakimow et al. (2018) utilizou séries temporais de pastagens para identificação de processo de intensificação de uso da terra no bioma da Amazônia, na região do estado de Rondônia. O estudo utilizou séries temporais de onze índices de vegetação derivados das bandas dos satélites Landsat-7 e Landsat-8 e também três métricas extraídas das séries temporais para identificar áreas onde foi feita a queimada da vegetação natural para implementação de pastagem e também áreas onde existe já implementadas áreas com pastagem tradicional extensiva. De acordo com os autores, as sucessões de acontecimentos na série temporal foram utilizadas como informação chave na classificação da imagem em pastagem recém-formada e pastagem com manejo tradicional extensiva já implementada. Já o estudo de Manabe et al. (2018) utilizou as séries temporais de EVI do sensor MODIS como fonte de informação para identificação e classificação de sistemas de integração lavoura-pecuária no estado do Mato Grosso. O estudo utilizou como informação de entrada a série temporal em si, e obteve resultados positivos na diferenciação de áreas com integração lavoura-pecuária.

2.3 Método *Time-Weighted Dynamic Time Warping*

As séries temporais intra-anual e interanual trazem diferentes oportunidades dentro de uma grande gama de abordagens de classificação de imagens (Gómez et al., 2016), e um dos algoritmos que utiliza séries temporais para a classificação de imagens de satélite é o algoritmo *Time-Weighted Dynamic Time Warping* (TWDTW).

O método TWDTW é um algoritmo de classificação que utiliza como informação principal a série temporal de um pixel. Maus et al. (2019) descreve o algoritmo TWDTW como uma adaptação do método conhecido *Dynamic Time Warping* (DTW) utilizado para análise de séries temporais. O algoritmo DTW funciona originalmente com a comparação de duas séries temporais com a finalidade de encontrar o melhor ajuste baseado na medida de dissimilaridade entre essas séries (Maus et al., 2016).

Porém, segundo Maus et al. (2016) o algoritmo DTW não funciona com grande eficiência quando se trata de séries temporais de dados de sensoriamento remoto aplicado ao monitoramento de culturas agrícolas. Por ter um funcionamento que busca em todo o comprimento da série temporal o melhor alinhamento, este pode ser completamente deslocado nas abcissas. Isto pode ser perfeitamente possível em aplicações como reconhecimento de voz, porém, na aplicação no monitoramento agrícola, a característica fenológica de cada cultura não tem variações extremas em relação à sua ocorrência no período do ano e, por isso, o algoritmo TWDTW diferencia-se do algoritmo DTW por introduzir uma certa penalidade no cálculo do valor de dissimilaridade para variações na ocorrência de certo padrão no tempo.

O algoritmo TWDTW utiliza como medida principal de avaliação a dissimilaridade entre duas séries temporais. O algoritmo cria padrões com pontos de controle que são fornecidos pelo usuário, e estes padrões criados serão comparados com as séries temporais presentes na área a ser classificada (como demonstrado na Figura 2, onde os padrões construídos estão destacados em cores). Os padrões são construídos e a dissimilaridade é calculada a partir da distância euclidiana entre cada ponto comparado entre as duas curvas.

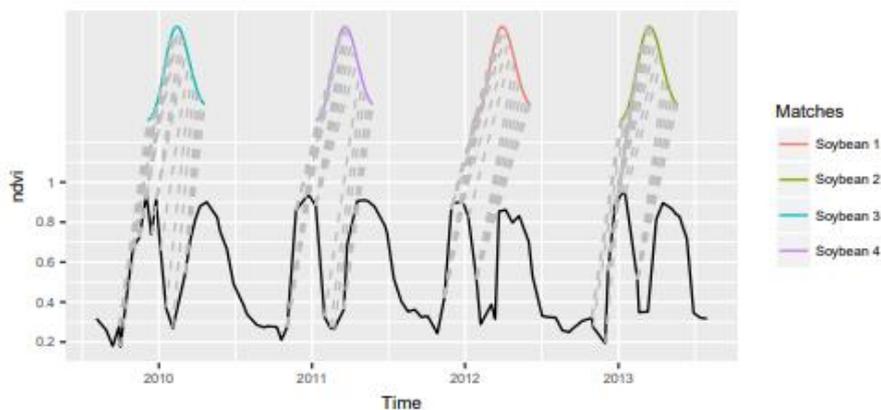


Figura 2. Exemplo de alinhamento que é feito pelo algoritmo. Fonte: Maus et al. (2019)

O cálculo da dissimilaridade também leva em consideração a penalização imposta pelo algoritmo quando um ponto na curva ocorre em um momento no tempo diferente do padrão original, mesmo que as curvas possam ter um ciclo fenológico semelhante. Dentro do algoritmo esta penalização cresce à medida que a série temporal a ser classificada fica distante da série padrão, levando em consideração dias de distância. A penalidade para o cálculo da dissimilaridade pode crescer linearmente ou com uma função logística, e é ajustada pelo usuário em sua aplicação específica. Segundo Maus et al. (2016), a função

logística utilizada em seu estudo de caso obteve melhor resultado em relação à função linear e também utilizando o algoritmo sem penalidades.

Estudos recentes utilizaram o algoritmo TWDTW como método de classificação de áreas agrícolas. O estudo de Belgiu e Csillik (2018) utilizou o algoritmo em imagens do satélite Sentinel-2 com objetivo de classificar áreas em classes de uso agrícola. O estudo de caso conduzido por Maus et al. (2016) também utilizou o algoritmo para classificação de área agrícola localizada no estado do Mato Grosso, e as imagens utilizadas foram do sensor MODIS. O estudo realizado por Manabe et al. (2018) utilizou o algoritmo TWDTW para identificação e classificação de áreas com sistema de integração lavoura-pecuária, utilizando a sucessão de lavoura e pastagem como informações chave da série temporal para classificação. Os diversos estudos que aplicaram o algoritmo demonstraram que este tem potencial de ter boa performance para identificação de uso e cobertura da terra, além de ter satisfatória aplicabilidade com imagens de diferentes resoluções espaciais e temporais.

2.4 Segmentação de imagens de satélite

De acordo com Costa et al. (2014), a classificação de imagens por pixels pode ter algumas desvantagens, tais como a suscetibilidade de pixels contaminados dentro da transição de um tipo de resposta espectral do alvo e de seu adjacente e, por isso, é bastante suscetível a ruídos dentro do resultado do mapeamento obtido. Assim, Costa et al. (2014) discutem que métodos alternativos de classificação podem contornar esta desvantagem, e a classificação orientada a objetos, feita a partir da segmentação da imagem, é uma delas. Desta forma, a segmentação é definida em Hossain e Chen (2019) como métodos que buscam dividir a imagem em regiões homogêneas.

O uso de segmentação leva à utilização de técnicas de classificação que são baseadas nos objetos criados na segmentação, chamadas de análise de imagem baseada em objeto (*Object-Based Image Analysis* - OBIA). De acordo com Csillik (2017), a classificação de imagens de alta resolução espacial baseada em objeto representa uma alternativa viável à classificação tradicional baseada em pixels, pois o uso de objetos para a classificação minimiza a variação espectral intraclasse. Porém, mesmo com suas vantagens, a principal desvantagem de realizar a classificação de imagens de satélite baseada em objetos é a dependência que a classificação final condiciona à qualidade da segmentação feita (Csillik, 2017).

Uma das técnicas de partição da imagem que tem sido utilizada em imagens de satélite é a técnica de "superpixel". De acordo com Zhang et al. (2019), os métodos baseados em superpixel utilizam as informações espaciais e temporais de uma imagem, onde os métodos de superpixel têm sido aplicados à imagens de alta resolução espacial para auxiliar na subsequente segmentação da imagem. De acordo com Toro et al. (2015), os superpixels proporcionam meios de encontrar na imagem aspectos locais. O uso de superpixels não resulta em segmentação da imagem, mas sim uma sobre-segmentação composta de áreas que têm características espectrais semelhantes (Toro et al., 2015). Os

métodos de superpixel têm sido verificados em estudos inclusive em áreas urbanas de alta densidade de detalhes (Zhang et al., 2019).

Dentro das diversas abordagens existentes de superpixel, foi proposto por Achanta et al. (2012) o algoritmo *Simple Linear Interactive Clustering* (SLIC), que é uma adaptação de clusterização por *k-means* para a geração dos superpixels, sendo mais eficiente, rápido, com boa conformação às fronteiras das regiões e com a capacidade de melhorar a performance dos algoritmos de segmentação que são utilizados subsequentemente (Csillik, 2017). O trabalho de Toro et al. (2015) utiliza a abordagem de superpixel pelo método SLIC para encontrar regiões que exibem características espectrais semelhantes e então utilizar estas regiões nas etapas subsequentes de exploração das características e métricas destas regiões.

O uso de superpixels baseia-se na característica de encontrar regiões semelhantes que se relacionam, portanto, por sua característica espectral e também localização em relação aos demais pixels. Essa criação de regiões é o aspecto chave para diminuição da variabilidade dentro da classificação e pode ser alternativa para encontrar regiões bem homogêneas dentro da imagem de satélite.

O método SLIC (Achanta et al., 2012) possui como abordagem a clusterização. A partir de um número inicial de superpixels dado como entrada pelo usuário, os centros são distribuídos em uma grade uniforme na imagem, tendo a distância S entre eles, calculada como na Equação 2.

$$S = \sqrt{\frac{N}{K}} \quad (\text{Equação 2})$$

onde

N é o número total de pixels da imagem;

k é o número de superpixels inicializado.

Os k clusters são calculados a partir das propriedades de cor (RGB) e também de distância em coordenadas (x e y). O algoritmo foi originalmente concebido utilizando o espaço de cores CIELAB, que possui o canal de iluminação L (do preto ao branco), o canal de cor a (do verde ao vermelho) e o canal de cor b (do azul ao amarelo). Atualmente, existe grande aplicação com o espaço de cores RGB, podendo ser contextualizada de maneira análoga. Os k clusters criados podem ser representados conforme a Equação 3.

$$C_k = [R_k, G_k, B_k, X_k, Y_k]^T \quad C_k = [1, k] \quad (\text{Equação 3})$$

onde,

C_k é o k -ésimo cluster

R_k é o valor do canal vermelho do centro do k -ésimo cluster

G_k é o valor do canal verde do centro do k -ésimo cluster

B_k é o valor do canal azul do centro do k -ésimo cluster

X_k é o valor no eixo x do centro do k -ésimo cluster

Y_k é o valor no eixo y do centro do k-ésimo cluster

A partir dos centros iniciais, o algoritmo calcula os pixels ao seu entorno que farão parte de um segmento ou de outro segmento a partir de uma fórmula que leva em consideração os valores RGB e a coordenadas (x,y) deste pixel. A Equação 4 representa o cálculo da distância para definição dos pixels que serão incluídos no mesmo segmento a partir do centro inicializado em um grid regular

$$D_s = d_{RGB} + \frac{m}{S} d_{xy} \quad (\text{Equação 4})$$

onde,

$$d_{RGB} = \sqrt{(R_k - R_i)^2 + (G_k - G_i)^2 + (B_k - B_i)^2}$$
$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2}$$

D_s é a distância total ponderada

d_{RGB} é a distância calculada utilizando os valores de cores dos pixels

d_{xy} é a distância calculada utilizando as distâncias euclidianas entre pixels

R_k, G_k, B_k são os componentes de valor de pixel do centro do cluster

R_i, G_i, B_i são componentes de valor dos pixels do entorno do centro do cluster

x_k, y_k são as coordenadas do pixel central do cluster

x_i, y_i são coordenadas dos pixels no entorno do centro do cluster

m é o parâmetro compactness

S é a distância entre os centros dos clusters

O valor de m na Equação 4 representa o conceito de nível de contribuição que o usuário deseja para as distâncias no cálculo da imagem, e dentro do algoritmo SLIC este parâmetro é chamado de *compactness*. Valores menores de m representam maior importância do valor do pixel no cálculo das distâncias e menor peso à distância euclidiana entre os pixels, e o contrário também é verdadeiro.

Outro parâmetro importante no funcionamento do método SLIC é o parâmetro *connectivity enforcement*. O parâmetro “connectivity enforcement” identifica segmentos pequenos e soltos e os mescla com os vizinhos de forma a fazerem então parte de segmentos maiores, forçando assim uma maior homogeneidade.

Uma das formas de avaliação da acurácia de uma segmentação realizada quando se sabe de antemão quais as separações esperadas das regiões é a avaliação pelo coeficiente *Dice*. Este coeficiente já foi utilizado no trabalho de Alexandre et al. (2015) para avaliação da acurácia da segmentação SLIC em contraposição à uma variação do método original proposto no trabalho. Este coeficiente avalia a sobreposição da segmentação alcançada em relação aos limites esperados, sendo sua fórmula geral a razão entre duas vezes a área de sobreposição pela soma das duas áreas (Equação 5), variando assim de

0 a 1, onde o valor de 1 significaria uma segmentação com regiões idênticas aos limites esperados.

$$dice = \frac{2 * (A \cap B)}{A + B} \tag{Equação 5}$$

onde,

dice é o valor do coeficiente Dice calculado

A é a área do segmento predito

B é a área do segmento considerado *ground truth*

$A \cap B$ é a área de intersecção entre A e B

3. Material e Métodos

3.1 Caracterização da área de estudo

A área de estudo compreende quatro fazendas de produção bovina localizadas na região oeste do estado de São Paulo (Figura 3).

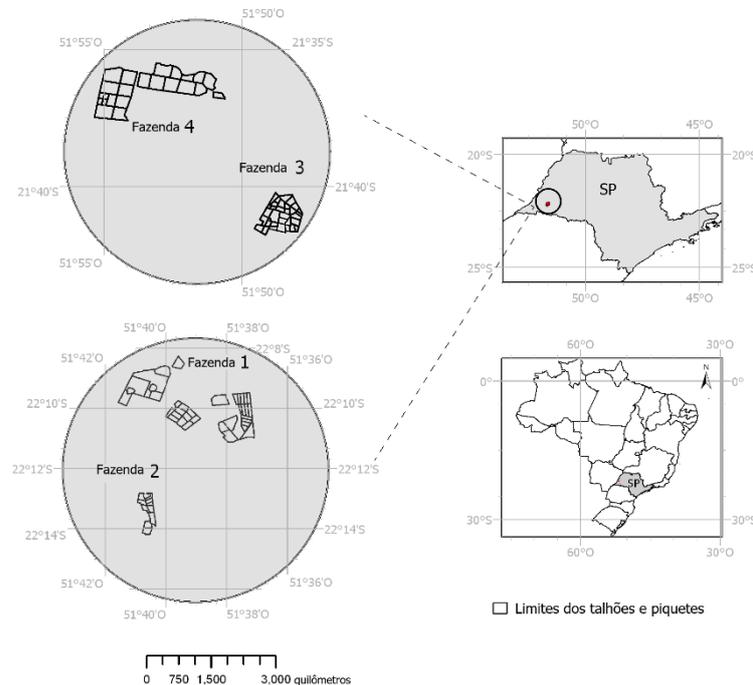


Figura 3. Localização da área de estudo com as fazendas visitadas.

As informações meteorológicas de precipitação acumulada mensal e temperatura média mensal para o período de 2016 a 2018 estão ilustradas na Figura 4. Esses dados foram adquiridos do Instituto Nacional de Meteorologia (INMET) e correspondem à estação meteorológica de Presidente Prudente, município da região da área de estudo. Os dados

faltantes da série adquirida desta estação meteorológica no período de 2016 a 2018 foram preenchidos utilizando a média da série completa.

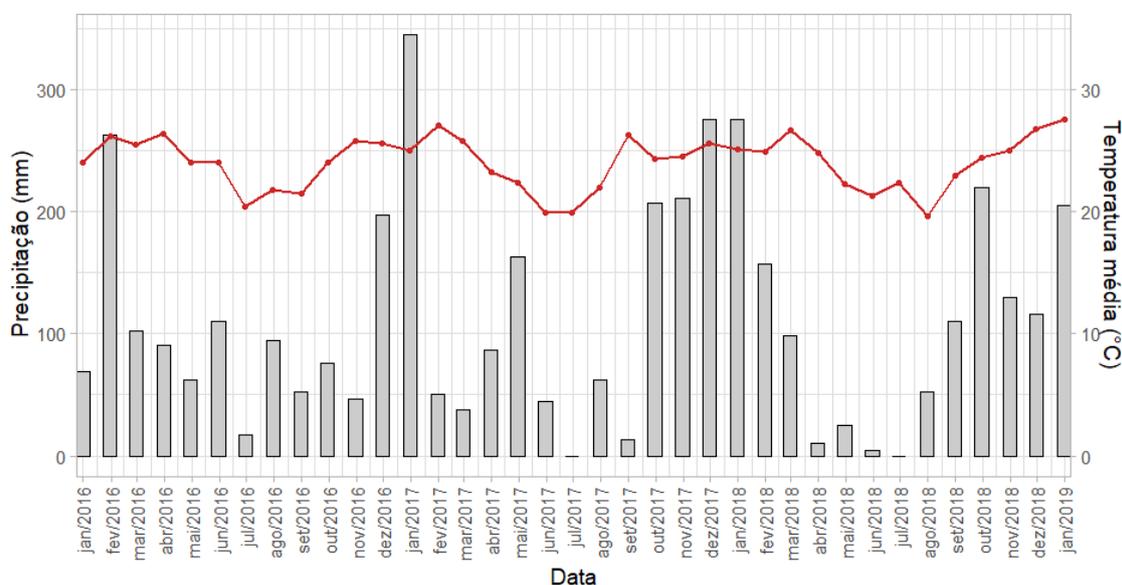


Figura 4. Dados de temperatura média mensal (linha vermelha) e precipitação acumulada mensal (colunas cinzas) para o período de janeiro de 2016 a janeiro de 2019.

As fazendas foram visitadas no período de agosto de 2017 a Novembro de 2018 para coletar informações de manejo da pastagem existentes nos talhões e piquetes das respectivas propriedades. As informações coletadas referem-se principalmente sobre produtividade, rotação de animais entre talhões e entre piquetes, e também o período do ano em que foi utilizado o sistema de integração com lavoura como cultura de verão. As informações detalhadas de cada manejo foram descritas em Bonamigo et al., (2019).

A fazenda 1 possui talhões com manejo tradicional da pastagem e produtividade em nível intermediário, sendo que a propriedade possui dois talhões com rotação de animais dentro do talhão separado em piquetes, e três talhões com integração lavoura-pecuária utilizando soja como cultura de verão, e o manejo intensificado sendo implantado em novembro de 2016. A fazenda 2 possui talhões com pastagem degradada, onde existe produtividade baixa e solo exposto, e também possui talhões com manejo tradicional do pasto. A fazenda 3 possui talhões com manejo tradicional com produtividade média a baixa e também possui talhões com pastagem degradada. A fazenda 4 possui talhões com manejo tradicional, utilizando rotação de animais em alguns de seus talhões, e também possui sistema de integração lavoura-pecuária em alguns de seus talhões.

Com as informações coletadas durante as visitas, para o presente trabalho foram considerados três classes principais de manejo, sendo eles “Degradado”, “Tradicional” e “Integração” - com sistema de integração lavoura-pecuária. As descrições gerais destas classes encontram-se na Tabela 1.

Tabela 1. Descrição dos três tipos de manejo utilizados.

Manejo	Descrição	
Tradicional	Pastagem com produtividade intermediária e com rotação de animais	
Integração	Pastagem com produtividade intermediária a alta, utilizando sistema de integração	
Degradado	Pastagem com produtividade baixa e com sinais de degradação	

3.2 Aquisição das imagens de satélite

As imagens de satélite utilizadas no presente estudo foram adquiridas do período de setembro de 2016 a janeiro de 2019. As imagens MODIS do produto NDVI (produtos MOD13Q1 e MYD13Q1 das plataformas Terra e Aqua, coleção 6, resolução espacial de 250 metros, composição de 16 dias - com 8 dias de diferença entre as plataformas) foram adquiridas a partir do pacote “MODISTsp” (Busetto & Ranghetti, 2016) do software R (R Core team, 2020).

As imagens adquiridas do satélite Sentinel-2 foram das bandas vermelho e infravermelho próximo (bandas 4 e 8, respectivamente; resolução espacial de 10 metros). As imagens adquiridas de setembro de 2016 a Março de 2017 foram do satélite Sentinel-2A com resolução temporal de 10 dias, e a partir de março de 2017, foram adicionalmente adquiridas imagens do satélite Sentinel-2B, compondo desta forma resolução de 5 dias de Março de 2017 a Setembro de 2018. As imagens foram adquiridas do repositório disponível do *Google Earth Engine* (Gorelick et al., 2017) e acessadas a partir da *API* no *software Python* através do pacote *earthengine-api*. As datas das imagens adquiridas foram filtradas de forma a adquirir as cenas em datas com um máximo de 30% de nuvem. As imagens adquiridas para todo o período foram do nível de processamento 1C, onde a imagem refere-se à reflectância de topo de atmosfera. Utilizando o processamento dentro da *API* do *Google Earth Engine*, cada imagem foi corrigida atmosféricamente com o algoritmo *Six-S*. Com as imagens das bandas corrigidas, foi implementado o cálculo do NDVI de acordo com a Equação 1 em todas as datas disponíveis para a construção da série temporal. A cena de interesse se localiza na intersecção de quatro *tiles* do satélite Sentinel-2 (*tiles* T22KCA, T22KCB, T22KDA e T22KDB) e, por isso, a imagem de cada *tile* foi processada de forma

independente. Com as imagens de NDVI, os mosaicos para cada cena foram feitos utilizando a função *mosaic* do pacote *raster* (Hijmans, 2020) do software R.

As séries temporais construídas foram então pré-filtradas para remoção de ruídos utilizando as máscaras de nuvem de cada um dos sensores. Para o sensor MODIS, a máscara de nuvem utilizada como pré-filtro foi a banda de qualidade *Pixel Reliability* e *Vegetation Index Quality*, onde os pixels sinalizados com interferência de nuvem foram removidos da cena. Para o satélite Sentinel-2, a máscara de nuvem foi adquirida juntamente com as datas filtradas (como no máximo 30% de nuvem), removendo-se os dados sinalizados como nuvem e como *cirrus*. O pré-filtro foi implementado removendo de cada tipo de imagem seus respectivos pixels sinalizados com nuvem, e posteriormente foi feita a interpolação linear dentro da série temporal dos dados faltantes.

O filtro Savitzky-Golay (SG) (Savitzky e Golay, 1964) foi utilizado para a suavização da série temporal de todos os pixels das imagens NDVI por meio da utilização do pacote "signal" (signal developers, 2013) do software R. Na Figura 5 são apresentados exemplos de uma série suavizada para cada um dos sensores.

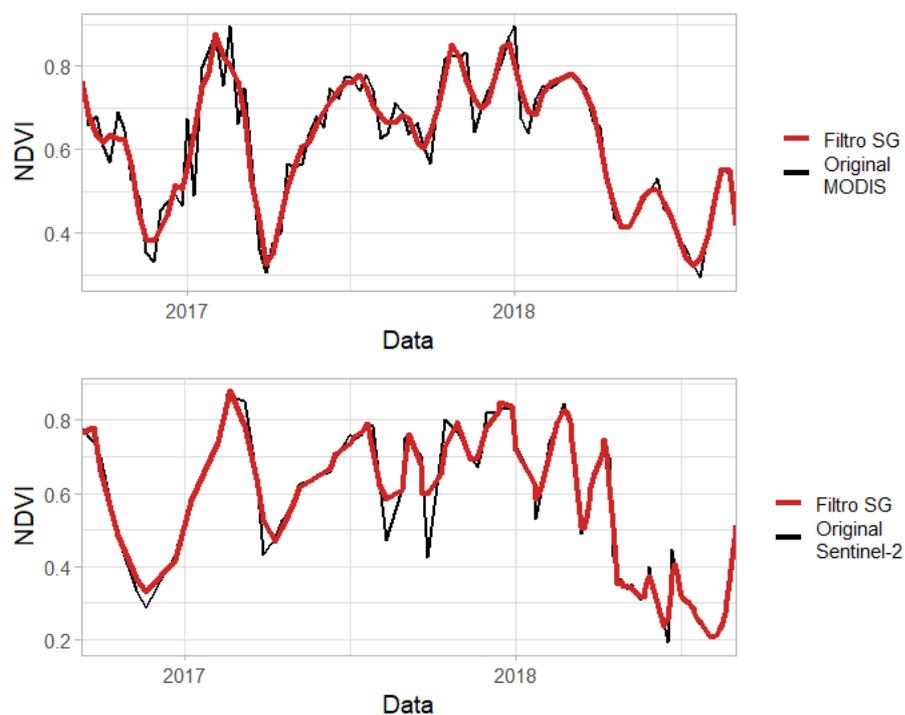


Figura 5. Exemplo de série temporal suavizada com o filtro SG nas imagens MODIS (superior) e Sentinel-2 (inferior) para a mesma localização no talhão que possui integração lavoura-pecuária na fazenda 1, abrangendo o período de setembro de 2016 a setembro de 2018.

Assim, depois de suavizadas, as séries temporais de NDVI foram utilizadas como base para classificação das áreas utilizando o algoritmo TWDTW. Para uma melhor performance da classificação, foi aplicada uma máscara que inclui áreas de pastagens e de cultura anual do estado de São Paulo proveniente dos dados do projeto MapBiomas no ano de 2017 (Projeto MapBiomas, 2017) como passo anterior à classificação da imagem.

A classificação foi dividida em dois anos, abrangendo o período de setembro de 2016 a setembro de 2017, e o outro período de setembro de 2017 a setembro de 2018.

3.3 Aplicação do algoritmo Time-Weighted Dynamic Time Warping (TWDTW)

O algoritmo TWDTW foi utilizado com o pacote “dtwSat” (Maus et al., 2019) do software R. O algoritmo tem três valores de entrada principais para que seja feita a classificação: coordenadas dos pontos a serem utilizados (isto é, latitude e longitude), o nome da classe a qual este ponto pertence, e em qual período no tempo caracteriza a classe desta amostra. Os pontos utilizados para a entrada no algoritmo foram selecionados dos talhões das quatro fazendas, com a utilização de pixels puros dentro dos talhões e de forma a obter número de pontos semelhantes para cada classe. As classes foram separadas em amostras de treino (pontos utilizados na construção das séries-padrão) e amostras de teste (pontos utilizados para verificação da acurácia da classificação final). As amostras foram obtidas separadamente para cada sensor, dado que possuem resoluções espaciais diferentes. A Tabela 2 indica o número de amostras utilizadas para cada classe em cada um dos sensores. As datas utilizadas para construir os padrões temporais definiram-se a partir dos dois anos de observação, sendo, portanto, utilizadas as datas de 05/09/2016 a 05/09/2017 para a temporada definida como “2016-2017”, e as datas de 05/09/2017 a 05/09/2018 para a temporada “2017-2018”. Esse padrão de datas de entrada no algoritmo foi utilizado para ambos os tipos de imagens utilizadas.

Tabela 2. Número de amostras utilizadas para construção dos padrões temporais para cada uma das imagens.

Classe	Fonte	Nº Amostras 2016/2017	Nº Amostras 2017/2018	Total de amostras
Tradicional	MODIS	46	41	87
Integração	MODIS	52	14	66
Degradado	MODIS	15	2	17
Tradicional	Sentinel-2	172	300	472
Integração	Sentinel-2	408	207	615
Degradado	Sentinel-2	84	48	132

Com as amostras de treino e suas coordenadas geográficas, o algoritmo construiu séries temporais que foram utilizadas como base de comparação para a classificação, chamadas de “padrões temporais” de cada classe. Para o presente estudo foram utilizadas 70% das amostras de cada classe para criação destes padrões temporais. Os padrões construídos foram então utilizados como base para a classificação das quatro fazendas. Os

padrões temporais construídos para cada um dos tipos de imagem são apresentados na Figura 6.

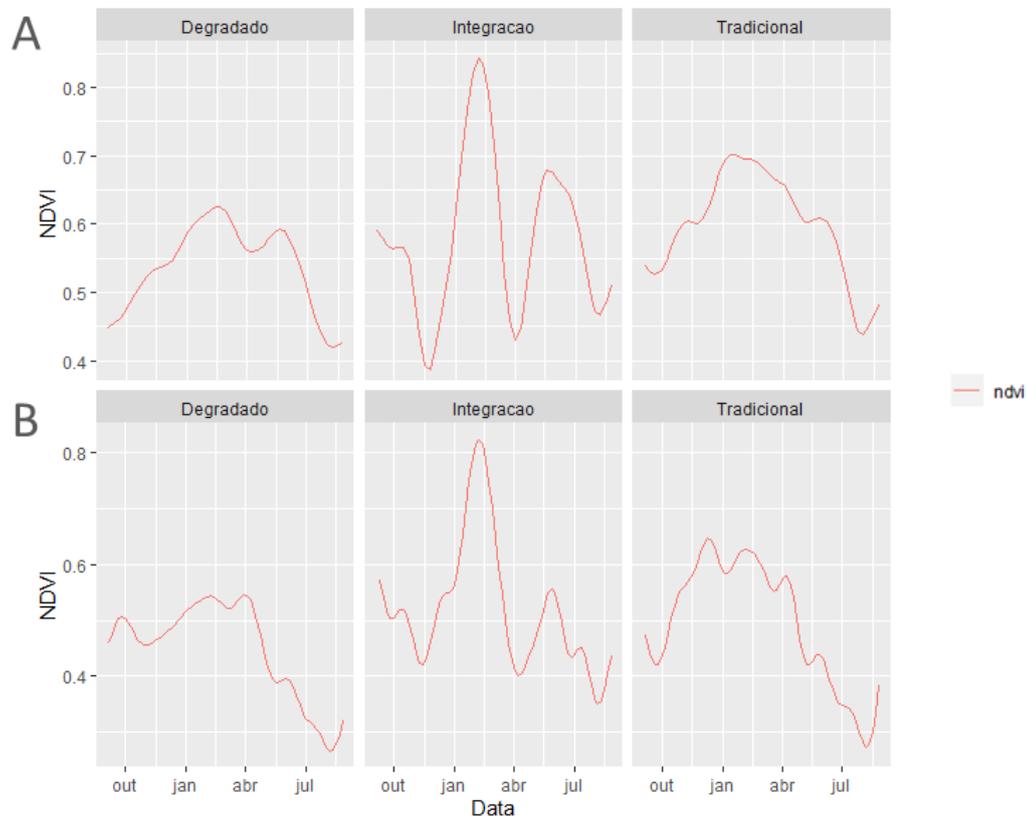


Figura 6. Padrões temporais construídos para a classificação com imagens MODIS (A) e com as imagens Sentinel-2 (B).

O algoritmo TWDTW utiliza de uma função para definir uma penalização na definição do alinhamento das séries temporais, e no presente estudo foi utilizada a função logística onde os parâmetros de ajuste foram $\alpha = -0,1$ e $\beta = 100$. Isso significa que à medida que o alinhamento acontece com alguns dias de diferença da data original dos padrões temporais, a penalização para o cálculo da matriz de distância do algoritmo aumenta de acordo com uma função logística. Para os parâmetros utilizados, a diferença de 100 dias das datas do padrão original implica em 0,5 de penalização no cálculo da distância.

A classificação foi feita separadamente para os dois anos de observação, sendo calculada a matriz de distância separadamente para cada ano e obtendo como resultado uma classificação para o período “2016-2017” e “2017-2018”. A avaliação das classificações obtidas a nível de fazenda foi feita com auxílio das informações de manejo dos talhões, como também por meio da acurácia global obtida a partir da matriz de confusão. O algoritmo TWDTW constrói a matriz de confusão com base no resultado alcançado na classificação à qual a amostra foi designada. Portanto, a amostra de teste pode ser avaliada na classificação obtida para 2016-2017 ou para 2017-2018, respeitando o período designado de ocorrência deste padrão pelos dados de entrada do algoritmo.

A matriz de confusão para classificação com as imagens do sensor MODIS foi obtida utilizando os pontos de teste designados nas fazendas. A classificação e sua matriz de confusão foram obtidas utilizando a área completa englobando todas as fazendas. A classificação utilizando as imagens Sentinel-2 foi feita separadamente em cada fazenda utilizando os mesmos padrões temporais, pois a classificação da região inteira de estudo teria um custo computacional muito elevado. As fazendas foram então avaliadas separadamente, e os pontos de teste para avaliar a acurácia global foram amostras que pertenciam exclusivamente à fazenda em questão. Além dos pontos de teste dos padrões temporais, outras amostras de teste pertencentes às fazendas foram utilizadas no cálculo da acurácia global de cada área. Isto se deveu ao fato de nem todas as amostras de todas as classes de manejo das fazendas terem sido selecionadas para utilização dentro do conjunto designado para construção dos padrões temporais. Assim, foi também construída uma matriz de confusão para cada fazenda para avaliar a acurácia das classificações das imagens Sentinel-2. O número de pontos de teste para cada um dos tipos de imagem é indicado na Tabela 3.

Tabela 3. Número de pontos de teste utilizados para matriz de confusão das classificações.

Fazenda	Fonte	Nº de pontos de teste
1, 2, 3 e 4	MODIS	50
1	Sentinel-2	347
2	Sentinel-2	110
3	Sentinel-2	309
4	Sentinel-2	312

A avaliação visual de acordo com as informações de visitas juntamente às acurácias globais obtidas nas fazendas foi utilizada para avaliar o desempenho do algoritmo.

3.4 Segmentação utilizando técnica de superpixel - SLIC

A técnica de segmentação de imagens de satélite é normalmente utilizada como uma pré-etapa à classificação de imagens. Entretanto, a abordagem de segmentação utilizada neste trabalho foi posterior à classificação das séries temporais de NDVI, de forma a identificar o padrão regional de distribuição dos manejos de pastagem ao redor da área de estudo e ampliar a análise para áreas onde não são conhecidos os limites das propriedades agrícolas. Desta forma, utilizou-se como dados de entrada desta segmentação as imagens classificadas com as três classes de manejo de pastagem obtidas do método TWDTW. Ao aplicar essa segmentação, buscou-se implicitamente preservar a característica espaço-temporal da abordagem utilizada no mapeamento resultante do método com o TWDTW.

A técnica de segmentação foi aplicada utilizando o pacote *scipy* (Virtanen et al., 2020) da linguagem de programação Python, onde a função aplicada foi a função *slic*. Esta função exige como entradas o número inicial de clusters que o algoritmo deve inicializar e a proporção de importância do valor do pixel e sua distância em relação a todos os outros pixels nos cálculos para formação dos clusters, chamado parâmetro *compactness*. No presente estudo foram testados diversos valores de inicialização de segmentos mantendo-se um valor fixo de *compactness* de 0,001. Após alguns testes preliminares este valor de *compactness* foi o valor que melhor pôde captar a distribuição espacial dos clusters sem formar regiões com bordas retas e quadradas, que teriam um aspecto artificial e não condizente com a realidade.

Para a segmentação com as imagens MODIS, a técnica foi aplicada na região das fazendas, abrangendo boa parte da região no entorno das fazendas em estudo. Para isto, foram testados diferentes faixas de valores para segmentos criados pelo algoritmo, onde a avaliação da distribuição espacial destes segmentos foi feita visualmente e levando em consideração as fazendas nessa avaliação. O número final de segmentos utilizados foi avaliado visualmente para então decisão de que seria uma segmentação suficiente para descrever as diversas regiões no entorno das fazendas de forma a não formar segmentos pequenos demais e que não fossem representativos. As faixas avaliadas em testes preliminares para definir o número representativo para a área foram segmentações de 4, 5, 9 e 20 superpixels, e também de 29,50,92 e 173 superpixels. Adicionalmente, foi realizada uma avaliação dos segmentos criados para as classificações de 2016-2017 e 2018-2018 com imagens do sensor MODIS onde foram identificados os segmentos que continham mais da metade de seus pixels na mesma classe de pastagem. Esta abordagem foi feita com o objetivo de proporcionar uma visão geral das regiões, e se existiu coerência na formação dos segmentos de forma a serem percebidas regiões com maiores ocorrência de uma classe de pastagem.

Para a segmentação com as imagens Sentinel-2, buscou-se alcançar segmentação que fosse capaz de descrever uma separação de talhões semelhante ao que ocorre nas fazendas. Para isto, a segmentação foi feita somente com a classificação de 2017-2018, a qual obteve resultado mais próximo do esperado com o método TWDTW. Para alcançar esta segmentação com limites semelhantes aos limites dos talhões das fazendas, foi utilizado o valor de *compactness* de 0,001, e variou-se os valores de número inicial de segmentos no algoritmo. Este número de segmentos foi então avaliado com a métrica chamada de coeficiente *Dice*. Este coeficiente é calculado a partir da comparação do segmento criado com o segmento que seria esperado. Neste caso, o limite das fazendas é conhecido, e assim é esperado que os segmentos criados estejam o mais próximo possível destes limites conhecidos das fazendas. O coeficiente *Dice* foi calculado de acordo com a Equação 5 (descrita no item 2.4) em linguagem Python para avaliação do número ótimo de segmentos para cada fazenda avaliada, onde o valor para cada talhão deveria respeitar um valor mínimo desse coeficiente. Foram testados os valores desse coeficiente de 0,5, 0,6 e 0,8 para avaliar qual desses valores obteve a melhor convergência em identificar e obter intersecção com os talhões.

Ao utilizar a segmentação com superpixel nas classificações das imagens do satélite Sentinel-2 e do sensor MODIS, pretendeu-se obter padrões de classificação generalistas que representassem as regiões com diferentes manejos de pastagem na região oeste do estado de São Paulo.

4. Resultados

Os dados adquiridos do sensor MODIS e do sensor MSI do Sentinel-2 tiveram distribuição de ocorrência de datas diferentes ao longo de todo o período analisado (Figura 7). As imagens MODIS têm distribuição homogênea por se tratar de uma imagem de composições, porém as imagens Sentinel-2 não tiveram a mesma homogeneidade de disponibilidade no período estudado. Isso se deve ao fato de as imagens Sentinel-2B terem sido disponibilizadas somente a partir de março de 2017, e ao fato dos dados do Sentinel-2 ao longo de todo o período terem sido filtrados de forma a respeitar um limite de ocorrência de nuvens de até 30% nas cenas analisadas, tornando sua distribuição de imagens não-homogênea.

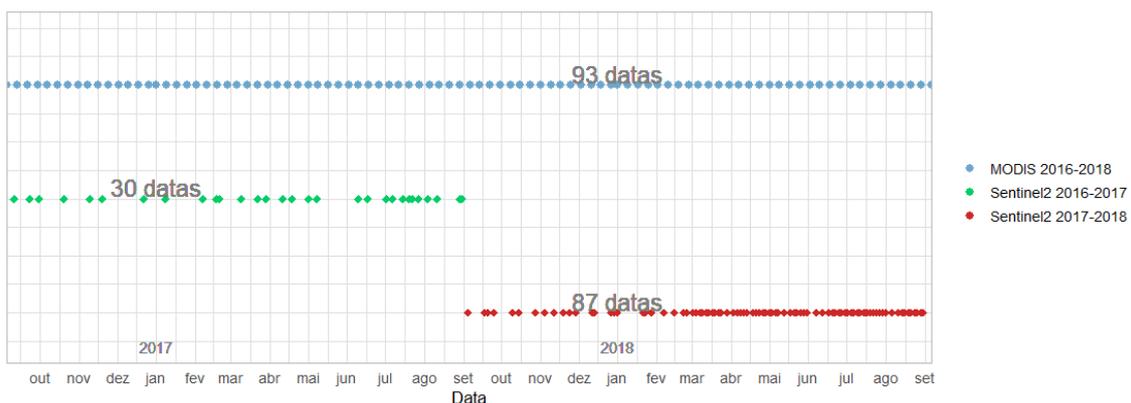


Figura 7. Distribuição temporal das imagens de cada um dos sensores utilizados.

A partir das séries temporais filtradas, o algoritmo TWDTW foi utilizado para a classificação das áreas com as duas resoluções espaciais diferentes. Os resultados obtidos para cada uma das fazendas da área de estudo puderam ser analisados de forma a comparar as classificações das áreas em pastagem tradicional, degradada e com manejo de integração lavoura-pecuária. A Figura 8 mostra o resultado do mapeamento nos anos de 2017 e 2018 para a fazenda 1 com as imagens MODIS e Sentinel-2.

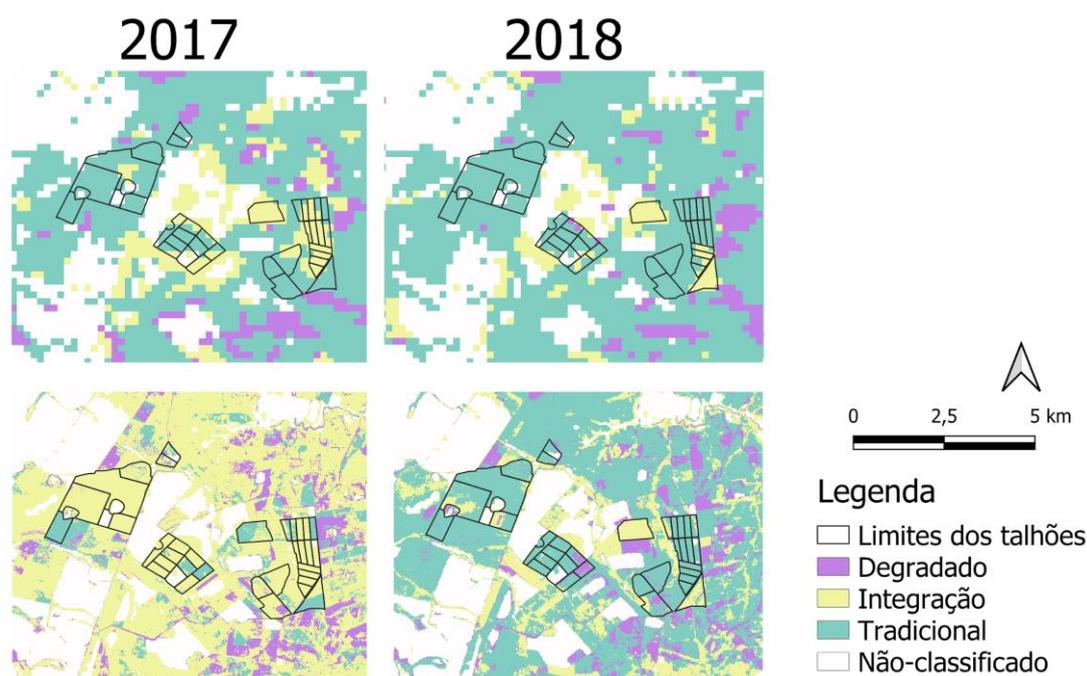


Figura 8. Classificação da área da fazenda 1 utilizando imagens do sensor MODIS para os anos de 2016-2017 (superior esquerda) e 2017-2018 (superior direita), e imagens do satélite Sentinel-2 para os anos de 2016-2017 (inferior esquerda) e 2017-2018 (inferior direita).

A classificação obtida para esta fazenda com imagens do sensor MODIS teve uma boa performance em ambos os períodos, sendo capaz de identificar dois talhões que tiveram integração com a utilização da soja no período de dezembro de 2016, e em um talhão em dezembro de 2017. De forma geral, a classificação com o MODIS nos dois períodos foi capaz de identificar que a maioria dos talhões dessa fazenda possui manejo tradicional do pasto. Para as imagens do satélite Sentinel-2 a classificação do período de 2016-2017 não foi satisfatória, onde houve excesso de áreas identificadas com integração lavoura-pecuária. A classificação obtida para 2017-2018 foi mais condizente com a realidade da área da fazenda 1, com maior parte dos talhões com característica de pastagem tradicional ou com sinais de degradação. Para este período, o algoritmo identificou corretamente um dos talhões da fazenda que teve manejo de integração-lavoura pecuária utilizando cultura anual em dezembro de 2017.

Para a fazenda 2, os resultados obtidos são apresentados na Figura 9. Pode-se observar que as classificações para o sensor MODIS nesta área também foram coerentes entre si nos períodos de análise.

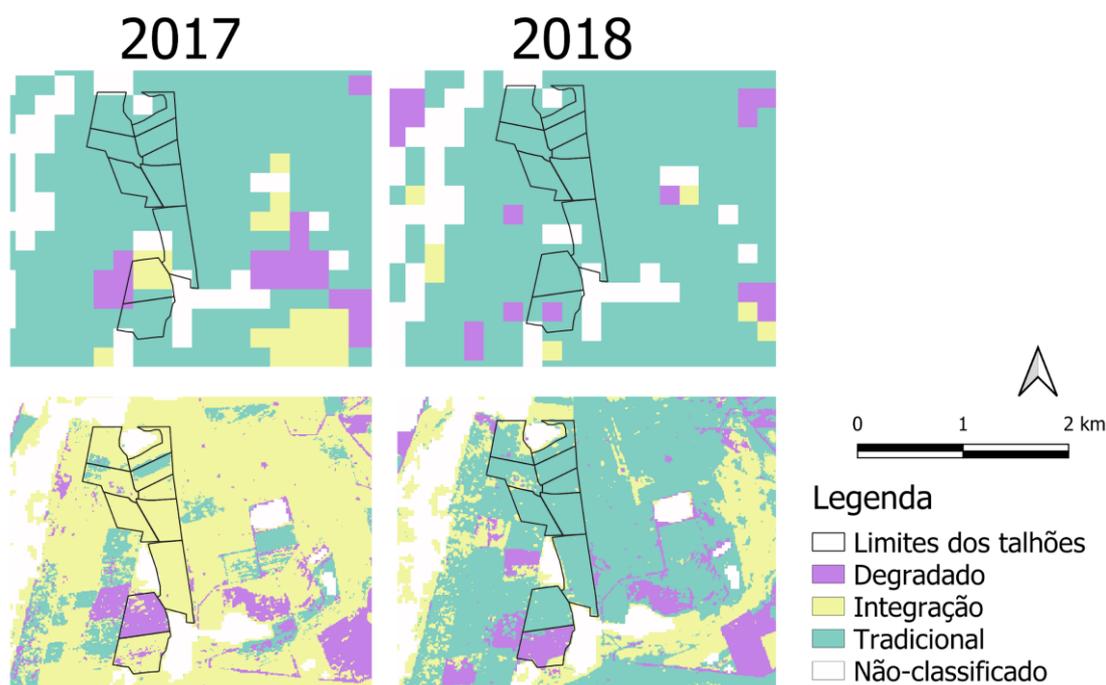


Figura 9. Classificação da área da fazenda 2 utilizando imagens do sensor MODIS para os anos de 2016-2017 (superior esquerda) e 2017-2018 (superior direita), e imagens do satélite Sentinel-2 para os anos de 2016-2017 (inferior esquerda) e 2017-2018 (inferior direita).

A maior parte da fazenda 2 possui pastagem com manejo tradicional, que foi corretamente identificado pelo classificador com o sensor MODIS. A classificação com as imagens Sentinel-2 foi coerente com a classificação do sensor MODIS para o período de 2017-2018, onde em sua maior parte os talhões tiveram classificações semelhantes, porém com um maior nível de detalhamento. O período de 2016-2017 não teve uma boa performance para as imagens Sentinel-2, onde ocorreu excesso de localidades que foram classificadas como integradas dentro da fazenda.

A Figura 10 mostra o resultado obtido de classificação para a fazenda 3. Esta fazenda possui a grande maioria de seus talhões com manejo tradicional e também alguns talhões que apresentam sinais de degradação, os quais foram bem identificados pela classificação com imagens MODIS para os dois períodos de classificação. O classificador com as imagens do satélite Sentinel-2 conseguiu captar a característica destes dois tipos de manejo na área para o período de 2017-2018, sendo interessante observar que teve performance semelhante ao sensor MODIS neste período. O mesmo não ocorreu para o período de 2016-2017, onde o classificador apresentou confusão na maior parte das áreas com a classe de integração lavoura-pecuária.

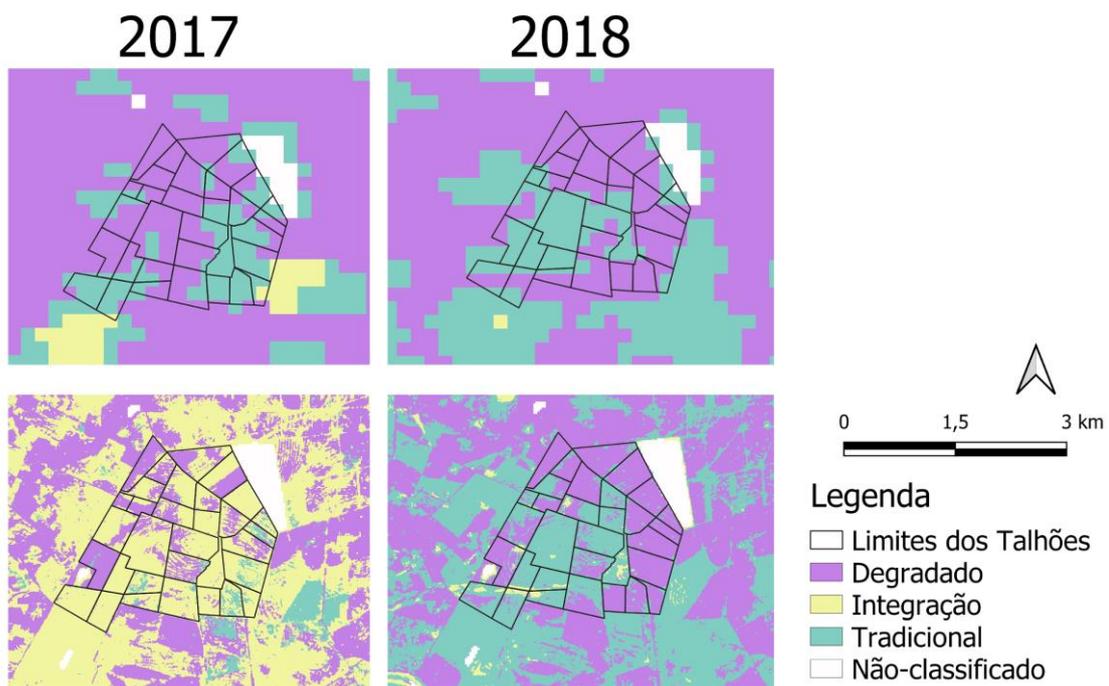


Figura 10. Classificação da área da fazenda 3 utilizando imagens do sensor MODIS para os anos de 2016-2017 (superior esquerdo) e 2017-2018 (superior direito), e imagens do satélite Sentinel-2 para os anos de 2016-2017 (inferior esquerdo) e 2017-2018 (inferior direito).

A Figura 11 apresenta os resultados obtidos para a fazenda 4, a qual possui talhões com os três tipos de manejo de pastagem utilizados no presente estudo.

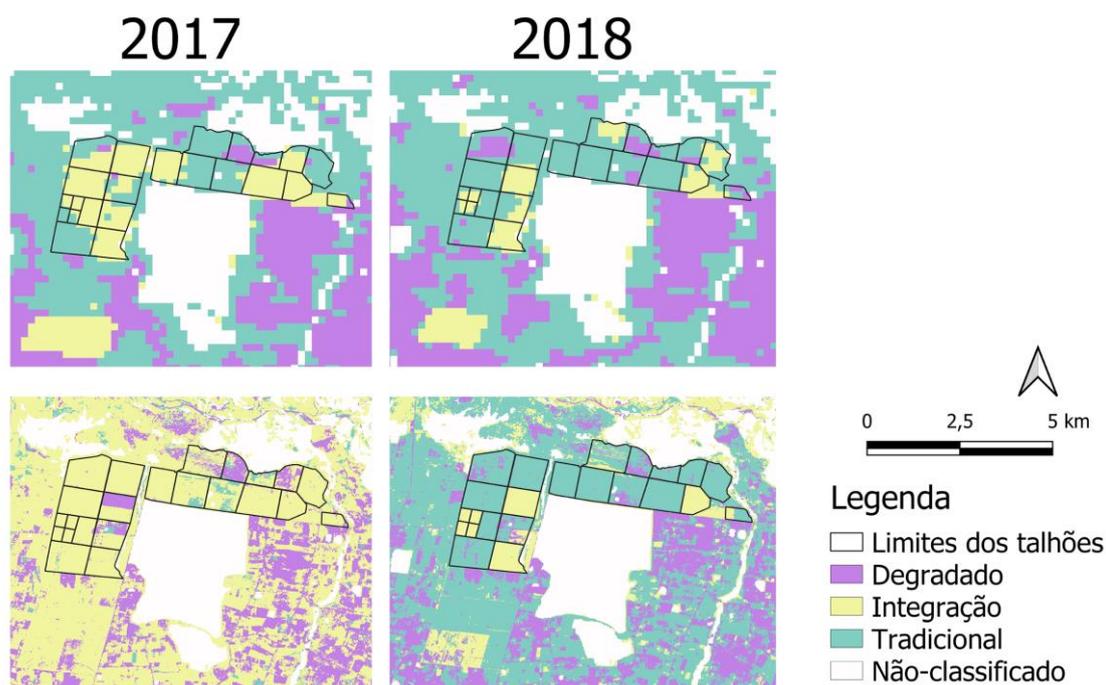


Figura 11. Classificação da área da fazenda 4 utilizando imagens do sensor MODIS para os anos de 2016-2017 (superior esquerdo) e 2017-2018 (superior direito), e imagens do satélite Sentinel-2 para os anos de 2016-2017 (inferior esquerdo) e 2017-2018 (inferior direito).

A classificação obtida com as imagens MODIS tiveram uma boa performance para os dois anos de análise, obtendo correta identificação de talhões com manejo de integração lavoura-pecuária em ambos os períodos, e de forma geral identificar corretamente grande parte de fazenda com manejo tradicional da pastagem para os períodos. A fazenda também possui talhões localizados em sua porção ao norte que apresentam solo arenoso e que tem histórico de ser uma área com pasto de menor qualidade de biomassa, que foi identificado pelo sensor MODIS e nas imagens Sentinel-2 no período de 2017-2018 corretamente como área de pasto com perfil de degradação. A classificação das imagens Sentinel-2 teve uma boa performance no período de 2017-2018 de forma geral, onde teve boa capacidade de identificar limites de talhões, devido a sua maior resolução espacial que foi capaz de chegar até as bordas dos talhões da fazenda. A classificação para o período de 2016-2017 com as imagens Sentinel-2 não conseguiu atingir classificação satisfatória, apresentando grande parte da região como pasto com manejo integrado com outra cultura.

Para as classificações obtidas, puderam ser construídas as matrizes de confusão das classes consideradas. As matrizes de confusão para as classificações das imagens MODIS e Sentinel-2 foram descritas na Tabela 4. As acurácias globais foram calculadas a partir das matrizes de confusão das classificações e os resultados de acurácia são apresentados na Tabela 5.

Tabela 4. Matrizes de confusão obtidas nas classificações.

MODIS				
Fazendas 1,2,3 e 4		Degradado	Integração	Tradicional
	Degradado	4	1	3
	Integração	0	13	1
	Tradicional	1	5	22
Sentinel-2				
Fazenda 1	Degradado	0	0	1
	Integração	0	36	220
	Tradicional	0	3	87
Sentinel-2				
Fazenda 2	Degradado	0	0	0
	Integração	23	0	32
	Tradicional	0	0	55
Sentinel-2				
Fazenda 3	Degradado	91	0	73
	Integração	1	0	61
	Tradicional	83	0	0
Sentinel-2				
Fazenda 4	Degradado	9	1	23
	Integração	11	111	54
	Tradicional	6	33	64

Tabela 5. Acurácias globais calculadas para as classificações nas fazendas.

Fazenda	Fonte	Acurácia Global
1,2,3 e 4	MODIS	78%
1	Sentinel-2	35%
2	Sentinel-2	50%
3	Sentinel-2	29%
4	Sentinel-2	58%

A matriz de confusão para as imagens MODIS mostrada na Tabela 4 mostra que a classificação teve boa performance, onde a maior parte dos pontos de treino foi classificada de forma correta. Para esta classificação, também foi possível notar confusão entre as classes de pastagem degradada e tradicional em alguns pontos de teste. Para as classificações obtidas para as quatro fazendas com as imagens Sentinel-2, as matrizes de confusão apontaram erros dentro da classe de pastagem tradicional, onde em todas as fazendas houve áreas que foram classificadas como manejo de integração. Além disso, as matrizes de confusão das fazendas 3 e 4 também demonstraram confusão entre as classes de pastagem degradada e tradicional em diversos pontos de teste. De acordo com as acurácias globais mostradas na Tabela 5, foi possível observar que houve desempenho inferior das classificações com imagens Sentinel-2 em relação às imagens MODIS.

A partir das classificações obtidas para ambos os sensores, foi possível obter as segmentações com o método SLIC. Para as imagens MODIS, foram avaliadas duas faixas de valores para criação de segmentos, e a faixa que melhor se encaixou com os objetivos propostos com esta abordagem de segmentação foi a faixa de 29 a 173 segmentos criados, e esta foi utilizada para avaliação final do número mais representativo de segmentos para a área. Dentro desta faixa, os resultados obtidos que representaram de forma mais homogênea e dentro do esperado foi a segmentação que criou 50 segmentos para a região na classificação de 2017 e 58 segmentos para a classificação de 2018. A Figura 12 mostra as segmentações obtidas e a representação de alguns segmentos que tiveram uma classe majoritária da pastagem, como forma de visualização da espacialização destas regiões.

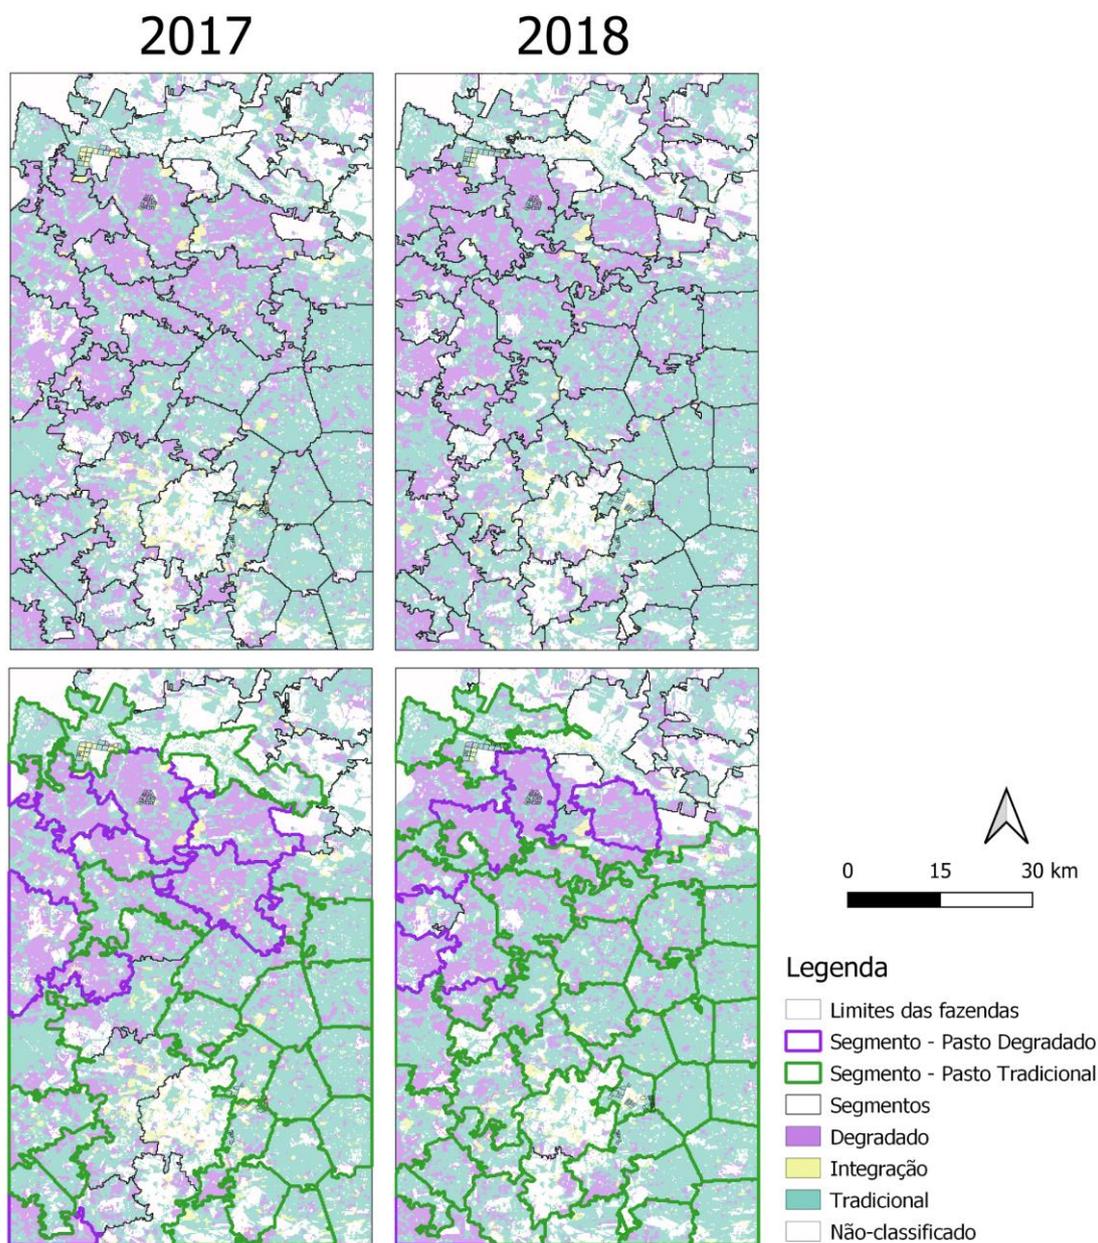


Figura 12. Segmentação da classificação com dados do sensor MODIS para os anos de 2016-2017 (superior esquerda) e 2017-2018 (superior direita), e a representação de segmentos criados que possuem classe majoritária para 2016-2017 (inferior esquerdo) e 2017-2018 (inferior direito).

O resultado obtido com a segmentação da região oeste do estado de São Paulo mostrou-se consistente do ponto de vista das áreas no entorno das fazendas, onde o método pôde identificar uma região homogênea com pastagem de menor produtividade e com sinais de degradação no entorno da fazenda 3 para ambos os períodos de análise. Este resultado é condizente com a realidade dos talhões da fazenda e traduziu-se na segmentação como uma região homogênea. A segmentação em regiões pôde também identificar a fazenda 1 inserida numa região de pastagem tradicional, o que já era esperado para as pastagens desta região. Além disso, foi possível compreender que grande parte

dos segmentos criados teve uma classe majoritária em seus segmentos, e que para ambos os períodos foram identificadas duas grandes regiões compostas por diversos segmentos. A região a noroeste teve diversos segmentos de pastagem degradada como classe majoritária, demonstrando que a região pode conter grande área ocupada por pastagens com baixa produtividade. A região central e a região sudeste da área analisada apresentaram boa parte de seus segmentos criados contendo a classe de pastagem tradicional como maior parte de seus pixels. O resultado obtido a partir da análise de classe majoritária dentro da segmentação com imagens MODIS demonstrou grande conectividade entre os segmentos de mesma classe majoritária reforçando o resultado satisfatório obtido na segmentação por macrorregiões de manejo das pastagens.

A segmentação foi também feita com objetivo de verificar o potencial do algoritmo em identificar os talhões das fazendas. O algoritmo foi aplicado às imagens Sentinel-2 classificadas para o período 2017-2018, as quais obtiveram melhor performance na classificação dos talhões em relação ao período 2016-2017 e que, dessa forma, poderiam ser fontes de informação mais coerentes para a segmentação. Os diversos valores para o coeficiente Dice foram avaliados e o valor que convergiu para as fazendas, ou seja, que melhor conseguiu captar todos os talhões de todas as fazendas, foi o valor de coeficiente Dice de 0,5. Assim, com o valor de 0,5 para todos os talhões das fazendas, obteve-se o valor ótimo de segmentos para cada fazenda.

As Figuras 13 a 16 mostram o resultado da segmentação das imagens Sentinel-2 classificadas para cada uma das quatro fazendas do estudo. O número de segmentos obtido na região de cada fazenda é apresentado na Tabela 6.

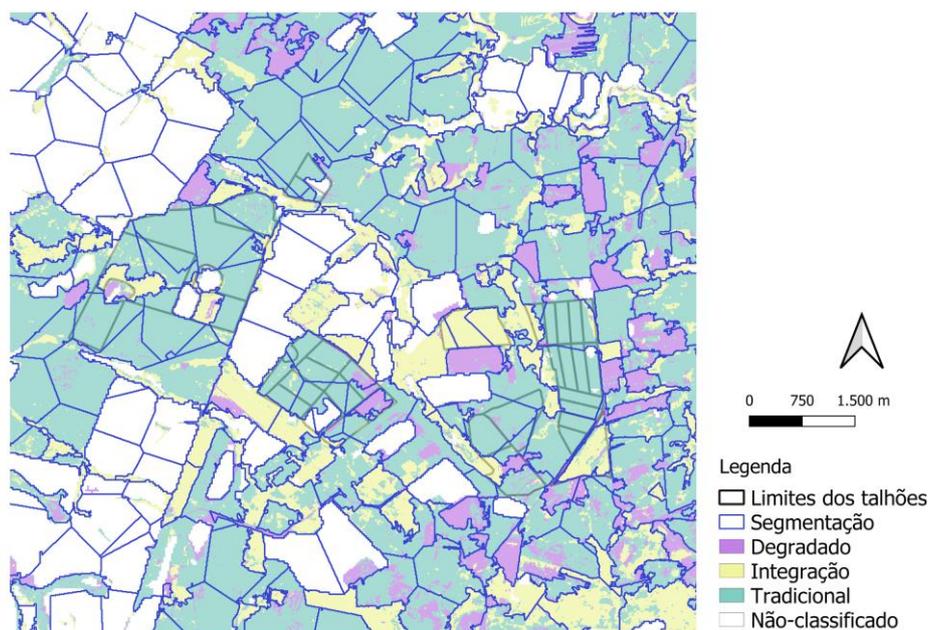


Figura 13. Segmentação da classificação com os dados Sentinel-2 na região da fazenda 1 para o período de 2017-2018.

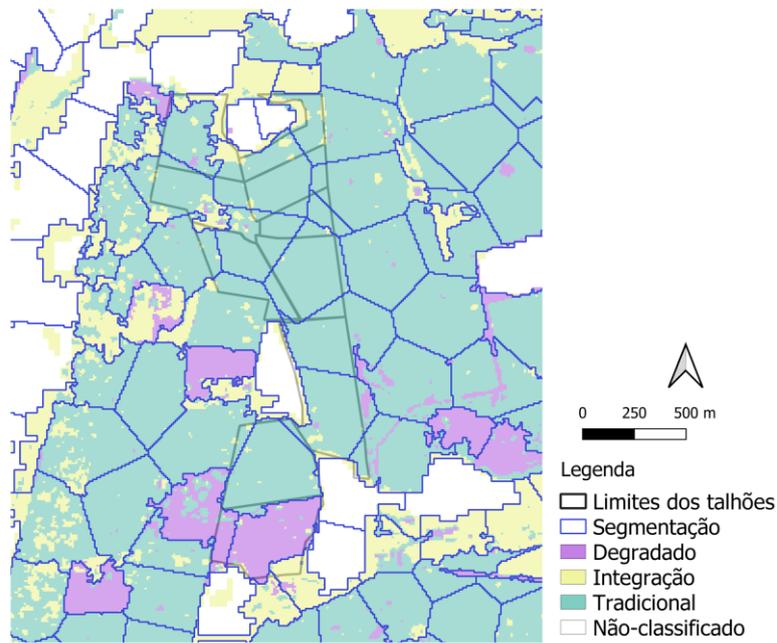


Figura 14. Segmentação da classificação com os dados Sentinel-2 na região da fazenda 2 para o período de 2017-2018.



Figura 15. Segmentação da classificação com os dados Sentinel-2 na região da fazenda 3 para o período de 2017-2018.

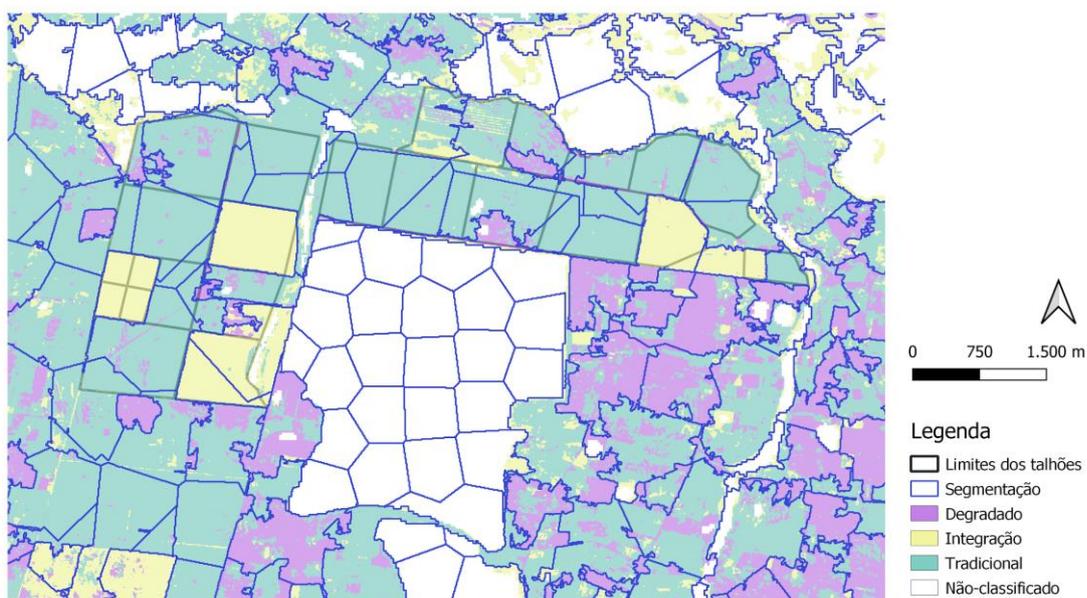


Figura 16. Segmentação da classificação com dados do Sentinel-2 na região da fazenda 4 para o período de 2017-2018.

Tabela 6. Número de segmentos criados com a aplicação do método de segmentação SLIC para as imagens Sentinel-2 na área das fazendas.

Região	Número de segmentos
Fazenda 1	259
Fazenda 2	162
Fazenda 3	266
Fazenda 4	262

Os resultados obtidos com as segmentações das classificações com imagens Sentinel-2 demonstraram-se satisfatórios em alguns casos, como a divisão correta de talhões com pastagem degradada e talhões com pastagem tradicional na fazenda 3. Em outros a divisão não teve boa acurácia como na fazenda 1 que possui diversos talhões adjacentes com o mesmo manejo, sendo a maioria desses talhões com manejo tradicional. Um aspecto que pôde se observar em todas as fazendas foi a suscetibilidade do algoritmo em separar regiões de classes iguais, que podem ou não coincidir com os talhões das fazendas.

Adicionalmente, foi possível perceber em talhões da fazenda 1 e 4 que a diferença de tamanho dos talhões que compõe cada uma dessas fazendas foi um entrave para a maior acurácia de separação do algoritmo, onde diversos talhões de menor tamanho foram separados corretamente e em contrapartida talhões mais extensos nas mesmas fazendas

foram separados em dois por causa do próprio espaçamento inicial que o algoritmo introduz ao inicializar o método.

O número de segmentos criados também foi um aspecto interessante. As regiões de análise das fazendas 1 e 4 foram cortadas com dimensões parecidas em número de pixels, e as fazendas 2 e 3 foram cortadas em regiões menores, também devido ao fato de serem fazendas de menor dimensão. Apesar disso, a fazenda 3 teve o número de segmentos ajustados semelhante ao número de segmentos de fazendas que possuem praticamente o dobro de seu tamanho em área, e onde a região de análise também possuía dimensões maiores. A fazenda 2 estava inserida dentro de uma região menor de análise e teve o menor número de segmentos criados.

5. Discussão

De forma geral as classificações obtidas a partir das imagens do sensor MODIS tiveram uma boa performance em ambos os períodos nas fazendas da área de estudo. Em diversos casos, as classificações obtidas foram condizentes com a realidade do manejo praticado na fazenda, e é possível afirmar que em todas as fazendas as classificações foram capazes de captar a dinâmica de manejo na maior parte dos talhões. Porém, devido a sua resolução espacial de 250 m, em alguns talhões das fazendas o resultado pode ter extrapolado os limites desses talhões, ou mesmo um pixel por estar perto da região de divisa entre dois talhões, ter agregado uma classe diferente da esperada em áreas de borda. Além disso, em alguns talhões pequenos não foi possível obter pixel puro da imagem MODIS.

Para as classificações com as imagens do sensor MSI do Sentinel-2, foi possível observar grande diferença de performance entre as classificações do período de 2016-2017 em relação àquela do período de 2017-2018. De forma recorrente a classificação de 2016-2017 obteve uma grande parte da área das fazendas com classe do manejo de integração lavoura-pecuária, em detrimento de outros manejos. Por outro lado, as classificações obtidas para o período de 2017-2018 tiveram performance satisfatória em grande parte das áreas das fazendas, sendo em alguns casos semelhante ao manejo identificado nas imagens MODIS, como ocorreu nas fazendas 3 e 4. Cabe salientar que a forma de condução da metodologia para ambas as fontes de dados de satélite buscou no presente estudo estar resiliente às diferenças existentes entre os dois tipos de resolução de imagens, porém alguns pontos podem ser destacados como influenciadores da diferença de resultado entre os diferentes sensores.

No presente estudo, os padrões temporais foram construídos com o período de um ano, de forma que o modelo pôde utilizar estes padrões para identificar os tipos de manejo para os dois anos do período estudado separadamente. Para os resultados obtidos com as imagens Sentinel-2, a boa performance na classificação do período 2017-2018 em todas as fazendas, e ao mesmo tempo uma classificação com resultado longe do esperado para o período de 2016-2017 pode ser interpretada com duas conclusões importantes: as séries de padrão temporal construídas e inseridas no algoritmo a partir das imagens Sentinel-2 podem ser consideradas representativas por terem boa performance em todas as fazendas

em 2017-2018; e as séries temporais do período de 2016-2017 das imagens Sentinel-2 podem estar ainda com certos ruídos que implicam numa classificação que não é condizente com a realidade. A menor disponibilidade de imagens para o período de 2016-2017 pode ter sido fator mais impactante na construção das séries temporais e que teve reflexo na acurácia da classificação final dos manejos de pastagem das fazendas.

As imagens MODIS possuem dados com 8 dias de resolução utilizando suas duas plataformas em órbita, e estes dados estão disponíveis desde o ano 2000. Já os dados do Sentinel-2 apresentam-se como de lançamento recente (2015) se comparado aos dados provenientes do programa do Landsat (1972) e do MODIS (2000). Devido a este lançamento recente, no período de estudo analisado existiu uma janela de sete meses onde somente as imagens do satélite Sentinel-2A estavam disponíveis, trazendo assim um maior espaçamento de datas disponíveis com até 30% de nuvem, como pôde ser observado na Figura 7. A série temporal pode trazer certas diferenças de comportamento quando existem períodos prolongados sem informação, como por exemplo um mês, e o filtro suavizador nesses casos pode não desempenhar o efeito desejado. Foi possível perceber fenômeno semelhante na distribuição de datas das imagens utilizadas no estudo de Belgiu e Csilik (2018), onde foi conduzida classificação com o algoritmo TWDTW com as imagens Sentinel-2. No estudo, a distribuição de datas se mostrou desuniforme, com alguns períodos sem disponibilidade de imagens sem nuvem. Belgiu e Csilik (2018) discutem que mesmo esta falta de datas com boa visibilidade, a criação dos padrões temporais não foi penalizado, mas que para futuras aplicações das imagens Sentinel-2 a melhor resolução temporal oferecida com as imagens adicionais do satélite Sentinel-2B, pode melhorar ainda mais os resultados de classificações com o algoritmo TWDTW.

Os dados de precipitação do período de análise mostrados na Figura 4 demonstraram variação de comportamento entre os anos 2016, 2017 e 2018. É possível observar que no ano de 2016 ocorreram chuvas de verão tardias e concentradas nos meses de dezembro e janeiro, se comparado com o mesmo período do ano de 2017. A variabilidade na curva temporal observada nas imagens Sentinel-2 pode também ter sido influenciadas por este fator climático no ano de 2016, onde as chuvas tardias associadas ao menor volume de informação temporal podem ter inserido ruídos e também menor precisão na informação do comportamento da pastagem. Analogamente, para o período de 2017 a 2018 as chuvas na região mostraram-se bem distribuídas na estação chuvosa, o que pode ter contribuído com a boa performance da identificação do comportamento da pastagem nas áreas das fazendas.

As classificações com as imagens MODIS tiveram uma boa performance em ambos os períodos e os resultados dos manejos dos talhões foram, em grande parte, condizentes com a realidade de campo. Este fato se confirma com a acurácia de 78%. Já para as imagens Sentinel-2, concluiu-se que a classificação não foi satisfatória no período de 2016-2017 e, em contrapartida, teve boa performance no período 2017-2018. As acurácias globais baixas para as classificações com as imagens Sentinel-2, podem ter sido fortemente influenciadas pela classificação ruim obtida em um dos períodos. A forma de avaliação dos pontos de teste do algoritmo TWDTW leva em consideração a classificação obtida para o período que ocorre o padrão naquele local, e por isso pode ser penalizada se uma das

classificações não tiver boa performance. As matrizes de confusão para as áreas das fazendas 1 e 3 tiveram maior número pontos de manejo tradicional classificados erroneamente como manejo integrado, e este fato relacionou-se diretamente à acurácia global dessas fazendas ter sido mais baixa do que as demais. A fazenda 4 teve um resultado com acurácia maior que as outras fazendas por ter diversos talhões que de fato possuíam sistema de integração lavoura-pecuária em 2016-2017.

De forma geral, a análise das matrizes de confusão pôde traduzir a classificação para os dois períodos nas imagens MODIS e Sentinel-2, onde a classificação que não foi satisfatória ficou evidente ao analisar as amostras que foram classificadas erroneamente, o que acabou penalizando a acurácia global. Este resultado ressalta também a importância do balanceamento do número de amostras de classes em ambos os períodos de estudo, uma vez que se mostra necessário avaliar de forma conjunta a performance da classificação nos dois períodos.

Além disso, ao observar os erros de classificação que ocorreram entre as classes de pastagem tradicional e degradada nas imagens MODIS e Sentinel-2 é possível relacionar à grande variabilidade que pode ocorrer em uma mesma área de manejo durante o período de produção, e que não necessariamente pode seguir um padrão temporal de NDVI bem definido. As áreas de pastagem possuem grande dinamismo, e podem ter pequenas variações devido ao manejo diferenciado em uma época específica que reflete em sua série de NDVI. Aspectos como a rotação de animais dentro da fazenda podem diminuir a biomassa de um local de pastejo até certo nível que pode ser então confundido com uma pastagem já com sinais de degradação. Da mesma forma, um pasto já considerado degradado que permaneça sem animais por um período pode ter uma recuperação de biomassa podendo haver então confusão com o nível de biomassa de uma pastagem considerada tradicional.

A partir da observação dos resultados obtidos, foi possível constatar que um mesmo manejo ainda pode trazer variabilidade, e que a construção das séries temporais padrão consideradas representativas possivelmente não serão capazes de abranger todas as variações possíveis dentro de um mesmo manejo. Manabe et al. (2018) demonstraram a utilização do algoritmo TWDTW no mapeamento de áreas de integração lavoura-pecuária, e um dos aspectos destacados pelo estudo foi o potencial de utilização desse algoritmo com imagens de alta resolução como as do Sentinel-2, com 10 m de resolução espacial. Dentro desse contexto, o presente estudo pôde contribuir com o uso desse algoritmo em áreas de integração lavoura-pecuária, e também em áreas de manejo tradicional e de pastagem com sinais de degradação. Assim, pôde-se destacar que mesmo a utilização de imagens de resoluções espaciais distintas ainda está sujeita ao dinamismo das áreas de pastagem tradicional e outros manejos, o qual deve ser levado em consideração ao analisar a classificação das pastagens.

A segmentação a nível dos talhões das fazendas teve aspectos interessantes a serem ressaltados. Um deles é a dificuldade deste método em lidar com fazendas que possuem tamanhos de talhões distintos, onde o próprio funcionamento do algoritmo pode ter inserido esta dificuldade ao resultado. Fica evidente que o uso de técnicas como esta devem ter maior cuidado ao serem utilizadas em regiões maiores e com maior variabilidade de

tamanho das áreas agricultáveis. Outro aspecto importante foi a quantidade de segmentos criados em cada uma das regiões das fazendas. O número grande de segmentos em uma região relativamente pequena, como foi o caso da fazenda 3, que obteve número de segmentos semelhante a uma região que é o dobro de seu tamanho (região da fazenda 4), pode ser relacionado ao nível de manejo da área; onde a baixa produtividade pode ser reflexo de uma região com agricultura mais voltada ao âmbito familiar e de menor disposição de recurso. Da mesma forma, a segmentação obtida para a fazenda 4 revela divisões em talhões que são extensos dentro da fazenda. Esta fazenda é uma propriedade com dimensões grandes relativamente à área em seu entorno e isto pode ter levado a uma segmentação com divisões além do necessário. Estes aspectos observados em relação às fazendas e o entorno destas revelam a importância da diferenciação em regiões ao fazer a análise de talhões, e que impactam diretamente no resultado final que se obtém com método de clusterização como o SLIC.

O estudo proposto de segmentação SLIC com imagens de alta resolução como em Csilik et al. (2017) também foi aplicado em regiões pequenas, onde foi observado que existiu influência na criação dos superpixels em regiões onde a heterogeneidade da área é menor ou maior. Nas regiões mais homogêneas, foi reportado que os superpixels formaram-se mais coerentemente e influenciou no uso dos segmentos formados na classificação final da área do estudo.

A segmentação com as imagens MODIS demonstraram uma certa separação dos níveis de manejo de pastagem dentro da região de análise de forma geral. Pôde-se constatar que a região mais a Noroeste possui grande área de pastagens com baixa produtividade, consideradas da classe de pasto degradado, e a região central e sudeste possui maior parte de suas pastagens em nível de manejo com produtividade intermediária, considerada da classe tradicional. Sabe-se pelas visitas feitas à fazenda 3 que esta é uma propriedade de pouca tecnificação do manejo. O mesmo se refletiu no entorno dessa fazenda, onde pode-se considerar que se insere numa região de baixa tecnologia empregada na produção bovina e com pastagens com menor produtividade e com níveis de degradação. Já a fazenda 1 está inserida em uma macrorregião de pastagens com produtividade intermediária, onde a própria fazenda 1 se encaixa como uma fazenda de certo nível de tecnificação e que implementou em 2016 talhões com manejo de integração com lavouras de soja.

A avaliação das classes dentro dos segmentos auxiliou na percepção de homogeneidade deste superpixel, e também a determinação espacial de quais superpixels obtiveram quais classes majoritárias auxiliou na percepção das macrorregiões de manejo. Esta forma de avaliação dos superpixels utilizando a homogeneidade intra-regiões também foi utilizada no estudo desenvolvido em Ortiz-Toro et al. (2015). No estudo é proposto um parâmetro de avaliação intra-regiões e inter-regiões. O estudo aqui desenvolvido optou pela avaliação dos segmentos criados baseando-se numa coerência intra-regiões somente, e não avaliação inter-regiões, além da avaliação visual do resultado. Porém, Ortiz-Toro et al. (2015) destacam no estudo a importância de se avaliar esta homogeneidade dentro dos segmentos criados quando não se sabe as separações reais da área de estudo, e esta

também foi uma das premissas para avaliação dos segmentos criados na região oeste do estado de São Paulo no presente estudo.

A partir da observação focada nas macrorregiões, foi possível observar um certo crescimento da macrorregião de pastagem tradicional entre os períodos de 2016 a 2018, o que pode indicar um avanço nas tecnologias empregadas nas propriedades de produção bovina da área central da região de análise. No estado de São Paulo, a área de produção de bovinos é de 6,7 milhões de hectares aproximadamente e de 6,4 milhões de cabeças de acordo com dados do Instituto de Economia Agrícola - IEA (IEA, 2019), tendo a maior parte dessa área de pastagem concentrada na região Oeste do estado (Olivette et al., 2011). Por isso, o constante monitoramento desta fronteira entre pastagens de média e alta tecnologia e pastagens de baixa ou nenhuma tecnologia empregada pode ser importante para implementação de políticas públicas de incentivo à melhoria e reforma de pastagens de forma a melhorar a produtividade, sem a necessidade de abertura de novas áreas para uso pecuário.

A utilização das imagens de diferentes resoluções espaciais no mapeamento das áreas de pastagens na região oeste do estado de São Paulo mostrou-se interessante na demonstração das limitações e vantagens da utilização de séries temporais de NDVI. As imagens MODIS demonstraram uma consistência na distribuição temporal de seus dados e, por isso, podem ser consideradas uma fonte interessante de séries temporais de NDVI. As imagens Sentinel-2 utilizadas não possibilitaram uma classificação satisfatória para um dos períodos de estudo. Entretanto, devido ao seu potencial de utilização com o algoritmo TWDTW, ressalta-se a necessidade de se explorar a avaliação das classificações de forma separada por período, podendo assim entender a influência da classificação com má qualidade na acurácia global obtida para as fazendas. Assim, as imagens MODIS demonstraram-se interessantes na aplicação generalista onde é possível comparar a distribuição das pastagens numa grande região entre um ano e outro, bem como pela consistência apresentada nas classificações. As imagens Sentinel-2 são igualmente interessantes no uso em microrregiões, onde tem grande capacidade de traduzir as variabilidades dos manejos de pastagens em sua distribuição espacial rica em detalhes, com potencial de aplicação na identificação de fazendas e talhões de produção bovina e também agrícola.

6. Conclusões

O presente estudo mapeou os diferentes manejos de pastagem (manejo tradicional, manejo com integração lavoura-pecuária e manejo com sinais de degradação) na região Oeste do estado de São Paulo com a metodologia proposta utilizando o algoritmo TWDTW, e com a aplicação da técnica de segmentação foi possível expandir a análise buscando representar a área das fazendas e seu entorno em regiões com comportamento semelhante.

O perfil temporal de NDVI conseguiu demonstrar as diferenças entre as classes de manejo de pastagem com integração, tradicional e com sinais de degradação. As

classificações obtidas com os dois tipos de resolução espacial de imagens de satélite do MODIS e do Sentinel-2 tiveram performances distintas entre si. As imagens do sensor MODIS tiveram em ambos os períodos de análise uma performance satisfatória, sendo capaz de captar de forma correta a maior parte dos manejos nos talhões das fazendas. A classificação obtida com imagens do sensor MSI do satélite Sentinel-2 alcançou boa performance nas classificações do ano de 2018, porém, para o período de 2016 a 2017, a ausência de dados em datas prolongadas levou a uma alta confusão de classes de manejo e, conseqüentemente, a uma performance não foi satisfatória.

A utilização das imagens MODIS com resolução de 250 m podem ter certa dificuldade em regiões que possuem talhões de tamanho reduzido, podendo ter misturas de comportamento em suas bordas. Já as imagens Sentinel-2 demonstraram potencial de captar comportamento de talhões dentro das fazendas, inclusive, as possíveis subdivisões dos talhões onde pode haver manejos diferenciados.

A técnica de segmentação aplicada aos mapas de manejo gerados trouxe aspectos de microrregiões e macrorregiões, abrangendo o Oeste do estado de São Paulo. A segmentação para identificação de talhões mostrou-se sensível aos diferentes sistemas de divisão que podem estar relacionados ao nível de tecnologia da fazenda. Adicionalmente, a análise em macrorregiões revelou regiões de baixa e de alta tecnologia empregadas na produção bovina, que podem ser constantemente monitoradas a fim de prestação de assistência para melhora das condições das pastagens em algumas regiões.

A utilização das imagens de diferentes resoluções espaciais no mapeamento das áreas de pastagens na região Oeste do estado de São Paulo pôde demonstrar as vantagens e limitações de cada uma das aplicações. Como futuras perspectivas, a utilização das segmentações com as imagens Sentinel-2 na área das fazendas pode ser aplicada como passo anterior à classificação TWDTW, como forma de criar segmentos homogêneos, bem como com as imagens MODIS para a região oeste do estado de São Paulo; como forma de monitoramento contínuo ao nível tecnológico das pastagens e de incentivo a ampliação da participação de políticas públicas na região.

7. Referências Bibliográficas

ACHANTA, R. et al. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 34, n. 11, p. 2274 - 2282, 2012.

AGUIAR, D. A. et al. MODIS time series to detect anthropogenic interventions and degradation processes in tropical pasture. **Remote Sensing**, v. 9, n. 1, 2017.

ALEXANDRE, E.B. et al. "IFT-SLIC: A General Framework for Superpixel Generation Based on Simple Linear Iterative Clustering and Image Foresting Transform," *2015 28th SIBGRAP Conference on Graphics, Patterns and Images*, Salvador, 2015, pp. 337-344, doi: 10.1109/SIBGRAP.2015.20

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.

BALBINO, L. C.; BARCELLOS, A. O.; STONE, L. F. (Ed.). **Marco Referencial: integração lavoura-pecuária-floresta**. Brasília, DF: Embrapa, 2011. 130 p.

BALBINO, L.C. et al. Sistemas de Integração: conceitos, considerações, contribuições e desafios. In: BUNGENSTAB, D. J.; ALMEIDA, R. G. de; LAURA, V. A.; BALBINO, L. C.; FERREIRA, A. D. **ILPF: inovação com integração de lavoura, pecuária e floresta**. Inovação com integração de lavoura, pecuária e floresta. Brasília, Df: Embrapa, 2019. Cap. 1. p. 32-48.

BÉGUÉ, A. et al. Remote Sensing and Cropping Practices: A Review. **Remote Sensing**, v. 10, n.1, 2018.

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, p. 509–523, 2018.

BELGIU, M.; DRĂGUȚ, L. Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 96, p. 67–75, 2014.

BIVAND, R.; KEITT, T.; ROWLINGSON; B. rgdal: Bindings for the 'Geospatial' Data Abstraction Library. R package version 1.4-8. <https://CRAN.R-project.org/package=rgdal>. 2019.

BONAMIGO, A. F. C. et al. APLICAÇÃO DE FILTRO EM SÉRIES TEMPORAIS DE IMAGENS MODIS NA ANÁLISE DE MANEJOS DE PASTAGENS. In: ANAIS DO XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2019, Santos. Anais eletrônicos... São José dos Campos, INPE, 2019. Disponível em: <<https://proceedings.science/sbsr-2019/papers/aplicacao-de-filtro-em-series-temporais-de-imagens-modis-na-analise-de-manejos-de-pastagens>>

BUSETTO, L., RANGHETTI, L. MODISrsp: An R package for automatic preprocessing of MODIS Land Products time series, *Computers & Geosciences*, Volume 97, Pages 40-48, ISSN 0098-3004, <http://dx.doi.org/10.1016/j.cageo.2016.08.020>. <https://github.com/ropensci/MODISrsp/>. 2016.

CARVALHO, J. L. et al., Impact of pasture, agriculture and crop-livestock systems on soil C stocks in Brazil. **Soil And Tillage Research**, v. 110, n. 1, p.175-186, set. 2010.

COSTA, H. et al. Combining per-pixel and object-based classifications for mapping land cover over large areas. **International Journal of Remote Sensing**, v. 35, n. 2, p. 738–753, 2014.

CSILLIK, O. Fast segmentation and classification of very high resolution remote sensing data using SLIC superpixels. **Remote Sensing**, v. 9, n. 3, 2017.

DEFOURNY, P. et al. Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. **Remote Sensing of Environment**, v. 221, n. November 2018, p. 551–568, 2019.

DIAS-FILHO, M. B., **Diagnóstico das Pastagens no Brasil**. Embrapa Amazônia Oriental. Documentos, 402. Belém, PA: Embrapa Amazônia Oriental, 36 p., 2014. Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/986147/1 /DOC402.pdf>.

ESTEL, S. et al. Mapping farmland abandonment and recultivation across Europe using MODIS NDVI time series. **Remote Sensing of Environment**, v. 163, p. 312–325, 2015.

GASCON, F. et al. Copernicus Sentinel-2A calibration and products validation status. **Remote Sensing**, v. 9, n. 6, 2017.

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.

Gorelick, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**. 2017.

GREEN, S.; CAWKWELL, F.; DWYER, E. Cattle stocking rates estimated in temperate intensive grasslands with a spring growth model derived from MODIS NDVI time-series. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 166–174, 2016.

HIJMANS, J. R. raster: Geographic Data Analysis and Modeling. R package version 3.0-12. <https://CRAN.R-project.org/package=raster>. 2020.

HOSSAIN, M. D.; CHEN, D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 150, n. November 2018, p. 115–134, 2019.

HOLLOWAY, J.; MENGERSEN, K. Statistical machine learning methods and remote sensing for sustainable development goals: A review. **Remote Sensing**, v. 10, n. 9, 2018.

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

IBGE - Instituto Brasileiro de Geografia e Estatística. Censo agropecuário, Rio de Janeiro, v. 8, p.1-105, 2019.

IEA - Instituto de Economia Agrícola. Análises e Indicadores do Agronegócio, São Paulo, v. 14, n. 3. 2019.

JAKIMOW, B. et al. Mapping pasture management in the Brazilian Amazon from dense Landsat time series. **Remote Sensing of Environment**, v. 205, p. 453–468, 2018.

KUENZER, C.; DECH, S.; WAGNER, W. (Ed.). **Remote Sensing Time Series**. Revealing Land Surface Dynamics: Springer International Publishing, 2015.

LEBOURGEOIS, V. 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, 1 mar. 2017.

MATOS, E. S. et al. Estoques de Carbono e Nitrogênio do Solo Manejado em Sistemas de Integração. In: FARIAS NETO, A. L. et al (ed.). **Embrapa Agrossilvipastoril: primeiras contribuições para o desenvolvimento de uma agropecuária sustentável**. Primeiras contribuições para o desenvolvimento de uma Agropecuária Sustentável. Brasília, Df: Embrapa, 2019. Cap. 28. p. 332-340.

MACEDO, M. C. M.; ARAÚJO, A. R. de., Sistemas de produção em integração: alternativa para a recuperação de pastagens degradadas. In: BUNGENSTAB, D. J.; ALMEIDA, R. G. de; LAURA, V. A.; BALBINO, L. C.; FERREIRA, A. D. **ILPF: inovação com integração de lavoura, pecuária e floresta**. Inovação com integração de lavoura, pecuária e floresta. Brasília, Df: Embrapa, 2019. Cap. 20. p. 295-317.

MACHADO, L. A. Z.; BALBINO, L. C.; CECCON, G. Integração Lavoura-Pecuária-Floresta: 1. Estruturação dos Sistemas de Integração Lavoura-Pecuária. Embrapa Documentos - Embrapa Agropecuária Oeste: Dourados, Ms, n. 110, p. 1-41, 2011.

MANABE, V. D.; MELO, M. R. S.; ROCHA, J. V. Framework for mapping integrated crop-livestock systems in Mato Grosso, Brazil. **Remote Sensing**, v. 10, n. 9, 2018.

MAUS, V. et al. A Time-Weighted Dynamic Time Warping Method for Land-Use and Land-Cover Mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 8, p. 3729–3739, 2016.

MAUS, V. et al. dtwSat: Time-weighted dynamic time warping for satellite image time series analysis in R. **Journal of Statistical Software**, v. 88, n. 1, 2019.

MATHER, P. M.; KOCH, M. **Computer Processing of Remotely-Sensed Images**. 4th Edition: John Wiley & Sons, Ltd, 2011.

NITZE, I.; BARRETT, B.; CAWKWELL, F. Temporal optimisation of image acquisition for land cover classification with random forest and MODIS time-series. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, n. 1, p. 136–146, 2015.

NUMATA, I. et al. Characterization of pasture biophysical properties and the impact of grazing intensity using remotely sensed data. **Remote Sensing of Environment**, v. 109, n. 3, p. 314–327, 2007.

OLIVETTE, M. P. A. et al. EVOLUÇÃO E PROSPECÇÃO DA AGRICULTURA PAULISTA: liberação da área de pastagem para o cultivo da cana-de-açúcar, eucalipto, seringueira e reflexos na pecuária, 1996-2030. **Informações Econômicas - IEA**, São Paulo, v. 41, n. 3, mar. 2011.

PEREIRA, O. J. R. et al. Assessing pasture degradation in the Brazilian Cerrado based on the analysis of MODIS NDVI time-series. **Remote Sensing**, v. 10, n. 11, 2018.

PICOLI, M. C. A. et al. Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, n. October 2017, p. 328–339, 2018.

Projeto MapBiomias. Coleção 4 - Série Anual de Mapas de Cobertura e Uso de Solo do Brasil. URL <http://mapbiomas.org>. 2017.

PITTMAN, K. et al. Estimating global cropland extent with multi-year MODIS data. **Remote Sensing**, v. 2, n. 7, p. 1844–1863, 2010.

PUNALEKAR, S. M. et al. Application of Sentinel-2A data for pasture biomass monitoring using a physically based radiative transfer model. **Remote Sensing of Environment**, v. 218, n. September, p. 207–220, 2018.

R Core Team. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>. 2020.

RODRIGUEZ-GALIANO, V. F. et al. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, n. 1, p. 93–104, jan. 2012.

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

SANTOS, P. M.; CORRÊA, L. de A. Manejo de pastagens tropicais. Embrapa Documentos - Embrapa Pecuária Sudeste: São Carlos, SP, n. 46, p. 1-28, 2009.

Signal developers. signal: Signal processing. URL: <http://r-forge.r-project.org/projects/signal/>. 2013.

TORO, C. A. O. et al. Superpixel-based roughness measure for multispectral satellite image segmentation. **Remote Sensing**, v. 7, n. 11, p. 14620–14645, 2015.

USDA - United States Department of Agriculture. **Livestock and poultry: world markets and trade**. 2019. https://apps.fas.usda.gov/psdonline/circulars/livestock_poultry.pdf. Acesso: 15 Ago. 2019.

VIRTANEN, P. et al. **SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python**. Nature Methods, 17(3), 261-272. 2020.

WARDLOW, B. D.; EGBERT, S. L. A comparison of MODIS 250-m EVI and NDVI data for crop mapping: A case study for southwest Kansas. **International Journal of Remote Sensing**, v. 31, n. 3, p. 805–830, 2010.

ZHANG, A. et al. Mapping of coastal cities using Optimized Spectral-Spatial features based multi-scale superpixel classification. **Remote Sensing**, v. 11, n. 9, 2019.