

MARCO ANTONIO ZANELLA

**DELIMITAÇÃO DE ZONAS DE MANEJO UTILIZANDO IMAGENS
ORBITAIS E SUA RELAÇÃO COM MAPAS DE PRODUTIVIDADE**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2018

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

Zanella, Marco Antonio, 1990-
Z28d Delimitação de zonas de manejo utilizando imagens orbitais
2018 e sua relação com mapas de produtividade / Marco Antonio
Zanella. – Viçosa, MG, 2018.
xi, 47 f. : il. (algumas color.) ; 29 cm.

Orientador: Daniel Marçal de Queiroz.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 44-47.

1. Agricultura de precisão. 2. Sensoriamento remoto.
3. Vegetação - Índices. 4. Soja. I. Universidade Federal de
Viçosa. Departamento de Engenharia Agrícola. Programa de
Pós-Graduação em Engenharia Agrícola. II. Título.

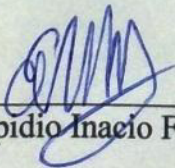
CDD 22. ed. 631.3

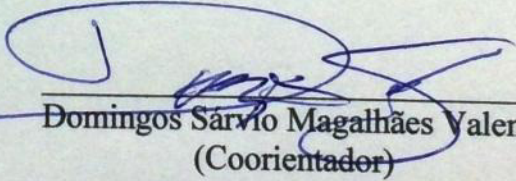
MARCO ANTONIO ZANELLA

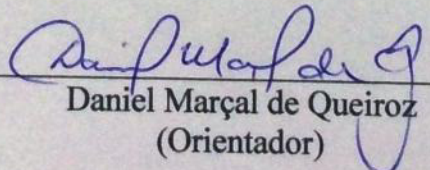
**DELIMITAÇÃO DE ZONAS DE MANEJO UTILIZANDO IMAGENS
ORBITAIS E SUA RELAÇÃO COM MAPAS DE PRODUTIVIDADE**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

APROVADA: 12 de março de 2018.


Elpidio Inacio Fernandes Filho


Domingos Sárvio Magalhães Valente
(Coorientador)


Daniel Marçal de Queiroz
(Orientador)

AGRADECIMENTOS

Aos meus pais, os maiores apoiadores de minhas conquistas, pela minha criação, formação e todo incentivo ao longo de minha vida.

A minha amada noiva Daniele, pelo amor, carinho e conselhos a mim oferecidos

As minhas irmãs pelo incentivo para completar minha formação acadêmica.

Ao professor Daniel pela oportunidade, orientação e confiança nos trabalhos realizados durante a pós-graduação.

Aos professores Sárvio, Francisco e Nerilson pelas orientações e ensinamentos que foram fundamentais para realização deste trabalho.

A todos os colegas do Laboratório de Mecanização, pela amizade, convivência, churrascos e ajuda quando necessária.

A universidade Federal de Viçosa e o Departamento de Engenharia Agrícola pela formação e grandes oportunidades oferecidas. E a Capes pela bolsa de estudos.

SUMÁRIO

LISTA DE FIGURAS	iv
LISTA DE TABELAS	vi
RESUMO	viii
ABSTRACT	x
1. INTRODUÇÃO	1
2. MATERIAL E MÉTODOS	4
2.1. Processamento e geração de mapas de produtividade	5
2.2. Processamento de imagens orbitais e geração de mapas de índice de vegetação	10
2.3. Geração de zonas de manejo a partir de mapas de produtividade e de mapa de índice de vegetação	15
3. RESULTADOS E DISCUSSÃO	16
3.1. Análise dos dados de produtividade de soja nas safras 2015/16 e 2016/2017	16
3.2. Análise de imagens de satélites da área	25
3.3. Delimitação das zonas de manejo utilizando mapas de produtividade e de índice de vegetação	33
4. CONCLUSÕES	43
5. REFERÊNCIAS BIBLIOGRÁFICAS	44

LISTA DE FIGURAS

Figura 1: Imagem de localização da área de estudo.....	4
Figura 2: Precipitação mensal e as temperaturas médias mensais (máxima e mínima) para o período abrangente das duas safras analisadas (julho de 2015 até junho de 2017)	5
Figura 3: Diagrama do sistema para delimitação de zonas de manejo utilizando mapas de produtividade e imagens de satélite.....	6
Figura 4: Mapas de produtividade antes da remoção de valores discrepantes (a) safra 2015/16 e (b) safra 2016/17	16
Figura 5: Localização dos pontos removidos na primeira etapa do processo de filtragem dos dados (a) safra 2015/16 e (b) safra 2016/17	17
Figura 6: Localização dos pontos removidos na segunda etapa do processo de filtragem dos dados (a) safra 2015/16 e (b) safra 2016/17	18
Figura 7: Localização dos pontos removidos na terceira etapa do processo de filtragem dos dados (a) safra 2015/16 e (b) 2016/17	19
Figura 8: Localização dos discrepantes locais identificados na terceira etapa do processo de filtragem (Índice de Moran) sobreposto no mapa de produtividade para a safra 2016/17.....	20
Figura 9: Histogramas dos valores de produtividade antes do processo de filtragem (a) e após o processo de filtragem (b) para as safras analisadas.....	22
Figura 10: Mapas de produtividade de cada safra, resultantes da interpolação dos dados filtrados (a) safra 2015/16 e (b) safra 2016/17.....	23
Figura 11: Variabilidade temporal apresentada pelos índices de vegetação NDVI, MSR e EVI2 a 52 e 92 Dias Após o Plantio (DAP) para a safra 2015/16.....	26
Figura 12: Variabilidade temporal apresentada pelos índices de vegetação GCVI, SAVI e SIWSI a 52 e 92 Dias Após o Plantio (DAP) para a safra 2015/16.....	27
Figura 13: Variabilidade temporal apresentada pelos índices de vegetação NDVI, MSR e EVI2 a 77 e 111 Dias Após o Plantio (DAP) para a safra 2016/17.....	28
Figura 14: Variabilidade temporal apresentada pelos índices de vegetação GCVI, SAVI e SIWSI a 77 e 111 Dias Após o Plantio (DAP) para a safra 2016/17.....	29
Figura 15: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2015/16, (b) utilizando os índices de vegetação com correlação espacial significativa referente a 52 DAP, (c) utilizando os índices de vegetação com	

correlação espacial significativa referente a 92 DAP, e (d) utilizando os índices de vegetação com correlação espacial significativa das duas datas analisadas.....	35
Figure 16: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2016/17, (b) utilizando os índices de vegetação com correlação espacial significativa referente a 111 DAP.....	36
Figure 17: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2015/16, (b) utilizando o índice de vegetação NDVI referente a data 52 DAP, (c) utilizando o índice de vegetação NDVI referente a data 92 DAP, e (d) utilizando o NDVI de ambas as datas.....	38
Figure 18: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2015/16, (b) utilizando o índice de vegetação NDVI referente a data 52 DAP, (c) utilizando o índice de vegetação NDVI referente a data 92 DAP, e (d) utilizando o NDVI de ambas as datas.....	39
Figure 19: Mapas temáticos com duas, três e quatro classes utilizando (a) os mapas de produtividade, (b) utilizando os índices de vegetação com correlação espacial significativa e (c) utilizando o índice NDVI das datas analisadas.....	41

LISTA DE TABELAS

Tabela 1. Características das plataformas de sensoriamento remoto utilizadas no estudo	11
Tabela 2. Números de bandas correspondentes para cada sensor	11
Tabela 3. Datas de plantio, colheita e duração do ciclo dos cultivos de soja analisados.....	12
Tabela 4. Datas das imagens utilizadas nas análises	12
Tabela 5. Equações e referências dos índices de vegetação utilizados.....	13
Tabela 6. Pontos removidos em cada etapa do processo de filtragem dos dados de produtividade das safras analisadas, entre parênteses o percentual em relação ao total de dados brutos.....	21
Tabela 7. Estatística descritiva dos dados antes e após o processo de filtragem.....	21
Tabela 8. Estatística descritiva dos dados após o processo de filtragem e após o processo de interpolação.....	24
Tabela 9. Índice de Moran bivariado para os índices de vegetação obtidos de imagens de satélite de média resolução e mapas de produtividade.....	30
Tabela 10: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 52 dias após o plantio (DAP).....	31
Tabela 11: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 92 dias após o plantio (DAP).....	32
Tabela 12: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 77 dias após o plantio (DAP).....	33
Tabela 13: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 111 dias após o plantio (DAP).....	33
Tabela 14: Índice Kappa entre as classes delineadas utilizando índices de vegetação de duas datas para a safra 2015/16 e as classes delineadas a partir do mapa de produtividade.....	35
Tabela 15: Resultados da análise de concordância para as classes delineadas utilizando índices de vegetação de duas datas para a safra 2016/17.....	37

Tabela 16: Índice Kappa entre as classes delineadas utilizando NDVI de duas datas para a safra 2015/16 e as classes delineadas a partir do mapa de produtividade.....	39
Tabela 17: Índice Kappa para as classes delineadas utilizando NDVI de duas datas para a safra 2016/17 e o mapa de produtividade obtido.....	40
Tabela 18: Resultados da análise de concordância para as classes delineadas utilizando índices de vegetação de duas datas para as safras analisadas e utilizando o NDVI referente as datas analisadas em ambas as safras.....	41

RESUMO

ZANELLA, Marco Antonio, M.Sc., Universidade Federal de Viçosa, março de 2018. **Delimitação de zonas de manejo utilizando imagens orbitais e sua relação com mapas de produtividade.** Orientador: Daniel Marçal de Queiroz. Coorientadores: Domingos Sárvio Magalhães Valente, Francisco de Assis de Carvalho Pinto e Nerilson Terra Santos.

A agricultura brasileira enfrenta o grande desafio de disseminação de tecnologias e seus usos apropriados para continuar aumentando a produtividade e conservar recursos. Para melhorar a eficiência dos sistemas de produção agrícola, a agricultura de precisão pressupõe que os campos e as culturas não são uniformes. Assim é necessário avaliar as variabilidades espaciais e temporais dos fatores de produção para otimizar a dosagem de insumos visando o retorno financeiro. Sendo assim, o objetivo deste trabalho foi explorar a utilização de imagens orbitais de média resolução para estimar a variabilidade espacial da produtividade de soja, delimitando zonas de manejo utilizando índices de vegetação provenientes de imagens orbitais e mapas de produtividade. A área de estudo possui área de 95 hectares e está localizada em uma fazenda situada no município de Iepê no estado de São Paulo. Foram utilizados dados de produtividade adquiridos de monitores instalados em duas máquinas colhedoras. Os dados são referentes as safras de 2015/2016 e 2016/2017 do cultivo de soja. Foi estabelecido um procedimento para filtragem dos dados de produtividade que consiste em três etapas: a primeira é a remoção de dados com valores fora da realidade utilizando limiares de produtividade de soja. A segunda etapa é a remoção de dados discrepantes globais, que foram identificados utilizando os limiares de 2,5 desvio padrão \pm média. Os pontos localizados fora destes limiares foram submetidos a um filtro local e removidos quando diferiram em 25% da média dos vizinhos. Na terceira etapa foi implementado o índice de Moran para remoção dos discrepantes locais. O processamento dos dados permitiu a remoção de discrepantes elevando a qualidade dos mapas de produtividade, removendo um percentual de pontos 5,9% e 6,8% do conjunto de dados de cada safra. Os dados de produtividade filtrados foram interpolados pelo método de krigagem por blocos utilizando variogramas locais. Os mapas de produtividade obtidos da interpolação foram utilizados nas análises de correlação entre seis índices de vegetação e também foram utilizados para delinear zonas de manejo. As imagens orbitais foram adquiridas em duas datas para cada safra,

e assim foram gerados índices de vegetação. A correlação espacial dos índices de vegetação foi obtida com o índice de Moran bivariado. Para isso, foram retiradas 30 amostras de 50 pontos aleatórios, com o objetivo de evitar interpretação errônea do p-valor. Foram utilizados os índices de vegetação com correlação espacial significativa com a produtividade, assim permitindo agregar informações para delineamento de zonas de manejo. As zonas de manejo delineadas foram comparadas com as zonas de manejo obtidas de mapas de produtividade utilizando o índice Kappa. Os índices de vegetação estudados foram capazes de inferir as diferenças na variabilidade da soja, e assim podem ser utilizados para delinear zonas de manejo. Classes de manejo delineadas com o NDVI (Índice de Vegetação da Diferença Normalizada) apresentaram valores similares de Kappa aos obtidos pela combinação de índices. No entanto, é provável que a saturação do NDVI afete os resultados obtidos pelo índice no meio do ciclo do cultivo. Imagens orbitais de média resolução espacial podem ser utilizadas para detectar a variabilidade do cultivo de soja. A utilização de índices de ambas as datas, tende a apresentar valores do índice Kappa similares aos maiores valores observados em datas individualmente. Sendo uma fonte de informações de boa qualidade e baixo custo. Este estudo demonstrou que o grau de concordância com a variabilidade captada pelos mapas de produtividade varia de 5% a 67% dependendo do número de zonas delineadas. Os índices de vegetação MSR e GCVI obtidos no meio do ciclo da cultura foram significativos apenas em uma safra. Já os índices obtidos próximos a colheita, apenas o SIWSI apresentou correlação significativa para as duas safras analisadas. Este estudo demonstrou que o grau de concordância com a variabilidade captada pelos mapas de produtividade variou de 5% a 67% dependendo do número de zonas delineadas. Os maiores valores de Kappa foram observados quando a área foi delineada em até três zonas.

ABSTRACT

ZANELLA, Marco Antonio, M.Sc., Universidade Federal de Viçosa, March, 2018. **Delineation of management zones using orbital images and its relation with yield maps.** Adviser: Daniel Marçal de Queiroz. Co-advisers: Domingos Sárvio Magalhães Valente, Francisco de Assis de Carvalho Pinto e Nerilson Terra Santos.

Brazilian agriculture faces the great challenge of disseminating technologies and their appropriate uses to continue to increase productivity and conserve resources. To improve the efficiency of agricultural production systems, precision agriculture assumes that fields and crops are not uniform. Thus, it is necessary to evaluate the spatial and temporal variability of the factors of production to optimize the input dosage aiming financial returns. The objective of this work was to develop a low cost system for the delimitation of management zones using yield maps and vegetation indices from orbital images. The study area covers an area of 95 hectares and is located at a farm situated in the municipality of Iepê in the state of São Paulo. Yield data acquired from monitor installed on a combine harvester were used. Data refer to the 2015/2016 and 2016/2017 soybean crop seasons. A filtering procedure has been established that consists of three steps: the first step is the removal of data with values out of reality using soybean yield thresholds. The second step is the removal of global discrepant data, which were identified using the mean \pm 2.5 standard deviation thresholds. The points located from these thresholds were submitted to a local filter and removed when they differed by 25% from the median of the neighbors. In the third step Moran index was implemented to remove the local discrepancies. The processing allowed the removal of discrepant data improving the quality of the yield maps, the percentage of removed points were 5.9% and 6.8% of the data set of each crop season. The filtered yield data were interpolated by the block kriging method using local variograms. The yield maps obtained from the interpolation were used in the spatial correlation analysis between vegetation indexes and were also used to delineate management zones. The orbital images were acquired in two dates for each crop season, and thus vegetation indices were generated. Spatial correlation of vegetation indices was obtained with the bivariate Moran index. For this, 30 samples of 50 random points were taken, in order to avoid erroneous interpretation of the p-value. Vegetation indexes were used with significant spatial correlation with yield, thus allowing the addition of information for delineating of management areas. The

delineated management zones were compared to the management zones obtained from yield maps using the Kappa index. The vegetation indices studied were able to infer the differences in soybean variability, and thus can be used to delineate management areas. Management classes delineated with the NDVI (Normalized Difference Vegetation Index) showed similar values of Kappa to those obtained by the index combination. However, saturation of NDVI is likely to affect the results obtained by the index in the middle of the crop cycle. Orbital images of medium spatial resolution can be used to detect the variability of the soybean crop. The use of indices from both dates tends to present Kappa index values similar to the higher values observed on individual dates. Orbital images are a source of quality and low cost information. The vegetation indexes MSR and GCVI obtained in the middle of the crop cycle were significant only in one crop. The indexes obtained near the harvest date, only the SIWSI showed a significant correlation for the two crop seasons analyzed. This study demonstrated that the degree of agreement with the variability captured by the productivity maps ranged from 5% to 67% depending on the number of delineated areas. The highest kappa values were observed when the area was delineated in up to three zones.

1. INTRODUÇÃO

A produção de grãos no país tem um papel de destaque no agronegócio brasileiro e mundial. Soja e milho são as principais culturas, correspondendo a mais de 80% da produção total de grãos e da área plantada. A soja é o produto de maior produção entre os grãos do país, atingiu 114 milhões de toneladas na safra 2016/17 (CONAB, 2017). A produção de grãos brasileira vem aumentando de forma muito mais acelerada que a expansão da área plantada (CONAB, 2017). Ou seja, parte do crescimento da produção está associada ao aumento de produtividade. Sendo que este incremento na produtividade provavelmente ocorreu devido à intensificação do uso da mecanização agrícola e ao desenvolvimento de pesquisa e novas tecnologias dentre outros fatores (SENTELHAS et al., 2015).

Contudo, o maior desafio no país é a disseminação de tecnologias e seus usos apropriados para continuar aumentando a produtividade (SENTELHAS et al., 2015). Dentre as tecnologias que podem contribuir para melhorar a eficiência dos sistemas de produção agrícola está a agricultura de precisão. Na agricultura de precisão parte-se do pressuposto que os campos e as culturas não são uniformes, e que a dosagem de insumos deve ser aplicada de forma variável de acordo com as variabilidades espaciais e temporais dos fatores de produção para que se possa otimizar o retorno financeiro. Como os insumos são aplicados de acordo com a dosagem correta e no momento mais adequado, evita-se o desperdício e reduz-se o impacto ambiental das práticas agrícolas.

Zona de manejo (ZM) é uma área espacialmente contígua cuja variabilidade espacial dos atributos limitadores da produtividade é baixa de tal forma que as dosagens de insumos podem ser aplicadas de forma uniforme (PEDROSO et al., 2010). Em uma área de produção pode haver várias zonas de manejo, entretanto, o mais comum é dividir as áreas de produção em duas a cinco zonas de manejo. A utilização do manejo por zonas facilita os tratamentos culturais, pois possibilita o manejo uniforme dentro de cada ZM (BAZZI et al., 2013). Uma vez definidas, reduz-se a quantidade de amostras que necessitam ser coletadas para caracterizar as variáveis do sistema de produção, visto que é necessário coletar apenas uma amostra (geralmente amostra composta) por zona de manejo (VALENTE et al., 2014).

Para a delimitação de subáreas homogêneas dentro da lavoura, existem diversas variáveis que podem ser utilizadas, geralmente recomenda-se a utilização daquelas que

são estáveis, que apresentam dependência espacial e que sejam correlacionadas com a produtividade (GAVIOLI et al., 2016). A delimitação de zonas de manejo tem sido feita utilizando diferentes informações, geralmente utilizando atributos físicos do solo ou condutividade elétrica aparente do solo (MOLIN; DE CASTRO, 2008; VALENTE et al., 2012) e dados de produtividade (BAZZI et al., 2013). Pode-se utilizar também mapas de índices de vegetação provenientes de sensoriamento remoto (PEDROSO et al., 2010).

A obtenção de mapas de produtividade pode ser considerada como o primeiro passo na adoção da agricultura de precisão (ROSS; MORRIS; JOHANNSEN, 2008). Os mapas de produtividade fornecem informações a respeito da variabilidade espacial e temporal. Essas informações podem ser utilizados para medir a resposta que as práticas de manejo localizado estão produzindo (SUDDUTH; DRUMMOND; MYERS, 2012). A coleta de dados de produtividade é ferramenta chave para compreender como a produção é afetada pelos fatores limitadores de produtividade (TAYLOR; MCBRATNEY; WHELAN, 2007).

Os dados de produtividade coletados pelos monitores das colhedoras possuem erros sistemáticos que devem ser identificados e eliminados. Lyle; Bryan e Ostendorf (2014) categorizaram os erros presentes em dados de produtividade em quatro causas principais: (i) dinâmica de colheita da colhedora, (ii) medição contínua da umidade e produtividade, (iii) precisão da informação de posicionamento e, (iv) erros induzidos pelo operador da colhedora. Para a utilização destes dados é necessário que os mesmos apresentem o mínimo de erros possível (LEE et al., 2016). No entanto, a eliminação desses erros não é tarefa fácil e são poucas as ferramentas disponíveis para essa finalidade (SUN et al., 2013). Além disso, são necessárias calibrações nos sensores que compõe o sistema de coleta de dados de produtividade para garantir a qualidade dos dados, uma vez que a produtividade não é medida diretamente pelo monitor (volume ou massa de grãos são medidos) (MOLIN; AMARAL; COLAÇO, 2015).

Imagens orbitais cobrem maiores áreas e avanços significativos têm ocorridos nos últimos anos melhorando a as resoluções espaciais e temporais quando se utiliza o sensoriamento remoto por satélites. Entre as plataformas existentes e que disponibilizam imagens sem custos, destaca-se o Programa Landsat (Land Remote Sensing Satellite) que foi iniciado em 1972, a última plataforma lançada é o Landsat 8 capaz de cobrir toda a Terra a cada 16 dias e gerar imagens coloridas por fusão digital com resolução de 15-30 metros. Existe ainda a possibilidade de utilizar imagens do

Landsat 7 apesar de apresentar um defeito que compromete 22% de cada imagem. Li et al. (2014) realizaram a comparação do desempenho de diferentes índices de vegetação entre imagens do Landsat 7 e Landsat 8, determinando que as diferenças entre eles são sutis e que existe alta correlação entre os índices de vegetação gerados a partir das imagens produzidas por essas duas plataformas.

Mais recente, a Comunidade Europeia passou a disponibilizar imagens gratuitas do Programa Copernicus, o qual utiliza o conjunto de satélites Sentinel. O Sentinel-2 capta imagens multiespectrais que podem ser utilizadas na agricultura. Essas imagens apresentam resolução espacial de 10-20 metros. O tempo de revisita é de 5 dias e tem cobertura global. Os programas Landsat e Copernicus disponibilizam imagens sem custos e são equipados com diferentes sensores capazes de oferecer uma variada quantidade de bandas espectrais que podem ser traduzidas em índices de vegetação. Estes índices geralmente podem ser utilizados para avaliar certos atributos do dossel de plantas, tais como o índice de área foliar, biomassa, teor de clorofila ou teor de nitrogênio (MULLA, 2013).

O produtor de grãos necessita aumentar a eficiência do sistema de produção para se manter competitivo e enfrentar os problemas acarretados pela variação do preço das commodities. A distribuição de insumos variando-se a dosagem por zonas de manejo é uma forma de se fazer isso sem necessidade de realizar muito investimento, uma vez que se pode delimitar zonas de manejo utilizando imagens de satélites e programas de computador disponibilizados gratuitamente. O objetivo deste trabalho foi explorar a utilização de imagens orbitais de média resolução para estimar a variabilidade espacial da produtividade de soja, delimitando zonas de manejo.

Os objetivos específicos desse estudo foram:

- Desenvolver um sistema para processamento e filtragem de dados de produtividade de soja e geração de mapas de produtividade;
- Analisar a variabilidade espacial captada por índices de vegetação em duas datas do ciclo de cultivo da soja durante as safras 2015/16 e 2016/17;
- Avaliar a correlação espacial entre mapas de produtividade de soja e índices de vegetação provenientes de imagens orbitais;
- Delimitar zonas de manejo com base em índices de vegetação e avaliar sua concordância com zonas de manejo delimitadas com mapas de produtividade.

2. MATERIAL E MÉTODOS

A área de estudo pertence a uma fazenda localizada no município de Iepê ao sudoeste do estado de São Paulo, a cerca de 530 quilômetros da capital São Paulo, situada entre as coordenadas geográficas de latitude $22^{\circ}39'28.33''$ S a $22^{\circ}40'3.5''$ S e longitude $51^{\circ}02'21.15''$ O a $51^{\circ}02'35.23''$ O. A precipitação média anual da área é de 1300 mm e a média mensal de 110 mm. A máxima temperatura média mensal é de 29°C e mínima média mensal de 18°C .

A fazenda possui 748 hectares divididos em oito talhões que são destinados a produção de grãos em sistema de plantio direto em regime de sequeiro, com rotação das culturas de milho e soja. Neste estudo foi utilizado um talhão para as análises, que possui área de 95 hectares (Figura 1).




Figura 1: Imagem de localização da área de estudo.

A Figura 2 mostra os dados de precipitação mensal e as temperaturas médias mensais (máxima e mínima) foram obtidas de uma estação meteorológica do Instituto Nacional de Meteorologia (INMET) localizada próximo a área de estudo. Os dados são referentes aos meses de julho de 2015 até junho de 2017, período que abrange as duas safras analisadas.

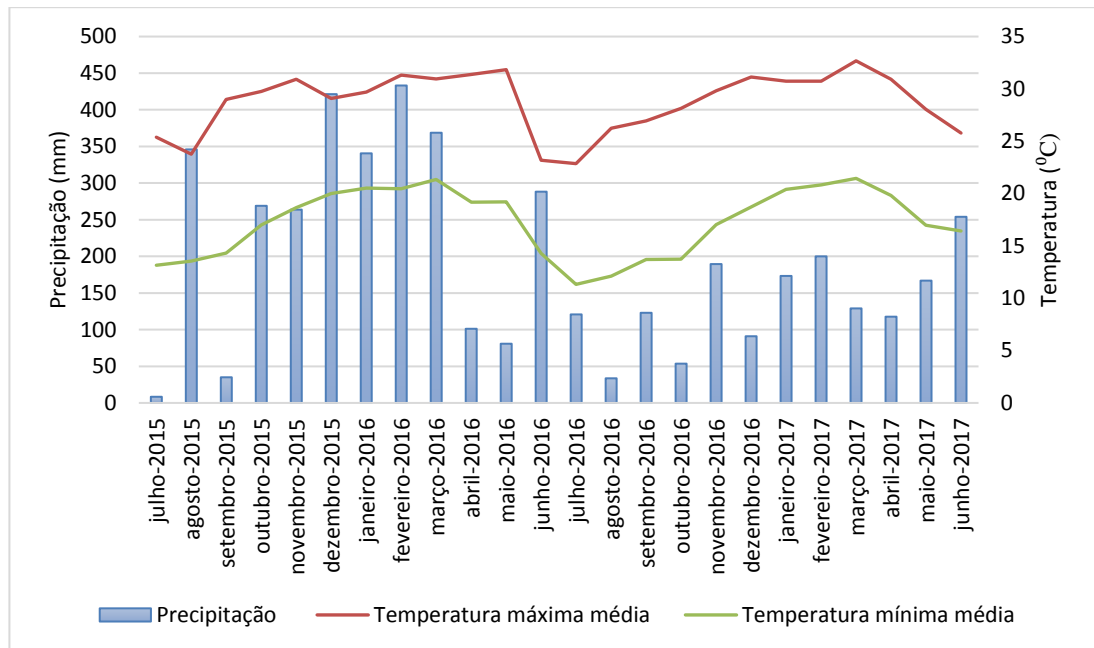


Figura 2: Precipitação mensal e as temperaturas médias mensais (máxima e mínima) para o período abrangente das duas safras analisadas (julho de 2015 até junho de 2017).

Durante a safra 2015/16 (outubro de 2015 a março de 2016) o acumulado de precipitação foi de 2096,7 mm, enquanto para a safra 2016/17 (outubro de 2016 a março de 2017) foi de 836,4 mm. O acumulado na primeira safra foi superior em relação a segunda safra, segundo EMBRAPA (2013) a necessidade total de água varia entre 450 a 800 mm/ciclo para que a cultura da soja obtenha o máximo rendimento, essa necessidade pode variar de acordo com as condições climáticas, duração do ciclo e manejo da cultura. No entanto, o excesso de chuva pode causar danos a produtividade de soja em áreas mal drenadas. Além disso, as temperaturas máximas e mínimas não variaram consideravelmente durante as safras.

2.1. Processamento e geração de mapas de produtividade

Foram utilizados dados de produtividade adquiridos de monitor instalado em uma máquina colhedora. Os dados são referentes as safras de 2015/2016 e 2016/2017 do cultivo de soja, e foram georreferenciados utilizando um monitor de produtividade equipado com GNSS que registra um ponto medido a cada um segundo. O processamento dos dados de produtividade foi realizado utilizando o programa computacional R versão 3.3.4 (R Core Team, 2015).

O presente estudo propõe um sistema de baixo custo capaz de implementar o delineamento de zonas de manejo, utilizando como variáveis de entrada índices de vegetação obtidos a partir de imagens de satélites gratuitas. Na Figura 3 é mostrado o diagrama do sistema utilizado para o processamento dos dados de produtividade.

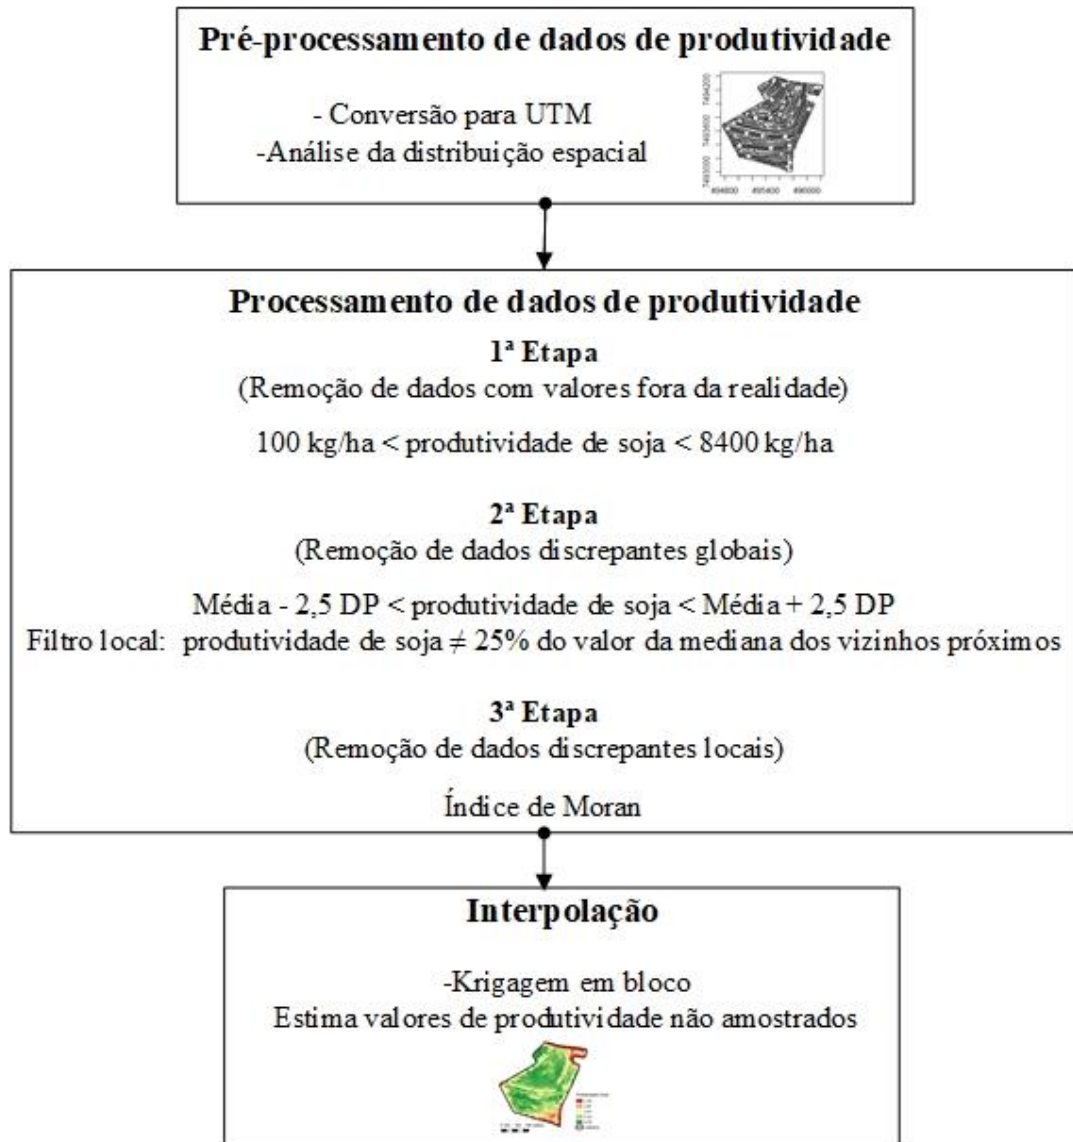


Figura 3: Diagrama do sistema para processamento dos dados de produtividade.

Dispositivos GNSS (Global Navigation Satellite System, Sistema Global de Navegação por Satélite) comerciais comumente utilizam o datum WGS84 (World Geodetic System 84, Sistema Geodésico Mundial 84) como padrão para coordenadas, por isso esse datum foi adotado nesse trabalho. Com a finalidade de facilitar o processamento e a interpretação dos dados foi realizado o pré-processamento de dados, no qual as coordenadas geográficas foram transformadas para UTM (Universal

Mercator Transversal). Assim, as distâncias no campo e tamanho da grade puderam ser expressas em coordenadas cartesianas.

A filtragem de dados de produtividade é uma etapa essencial para que estes forneçam informações corretas que irão servir de suporte para as decisões agronômicas de manejo (SUDDUTH; DRUMMOND; MYERS, 2012). A identificação e remoção em dados de produtividade de valores discrepantes foi realizada com a aplicação de um processo de filtragem dividido em três etapas principais (TAYLOR; MCBRATNEY; WHELAN, 2007), sendo as duas primeiras para a remoção de discrepantes globais e a última para a remoção de discrepantes locais.

A primeira etapa foi a remoção de dados com valores fora da realidade para os padrões do cultivo de soja, em que envolveu o estabelecimento de um limiar inferior e um superior. Todos os valores que não estavam situados entre os limiares foram considerados valores fora da realidade, valores muito elevados ou muito pequenos, pois provavelmente são resultantes de erros do monitor de produtividade. Os limiares diferem dependendo do tipo de cultura e da localização, sendo assim, para a soja foram adotados como limiares inferior e superior os valores de 100 e 8400 kg/ha, respectivamente.

Após a remoção dos dados com valores fora da realidade, foi estabelecido os limiares inferior e superior baseados na estatística descritiva do conjunto de dados, esta foi a segunda etapa do processo de filtragem. Obtendo os valores da média e do desvio padrão (DP), estes valores foram utilizados para realizar a filtragem dos dados seguindo as recomendações de Taylor, McBratney e Whelan (2007). Em que os pontos do conjunto de dados que são mais de 2,5 DP acima e abaixo da média de produtividade são candidatos a dados discrepantes globais. Para a remoção destes pontos, foi aplicado um filtro local com raio de busca de 20 metros para identificar os pontos vizinhos próximos. A largura da plataforma de corte da colhedora é de 9,4 metros, sendo assim a distância entre linhas de pontos registrados é de 10 metros e distância entre pontos de aproximadamente 1,5 metros. O critério para remoção do ponto candidato a discrepante global foi baseado na comparação do valor da mediana dos pontos vizinhos. O ponto analisado que apresentou valor superior a 125% do valor da mediana ou inferior a 75% do valor da mediana dos vizinhos foi considerado dado discrepante global e removido do conjunto de dados.

Taylor, McBratney e Whelan (2007) indicaram a utilização do índice de Moran como ferramenta para identificação de discrepantes locais. Essa foi a terceira e última

etapa do processo de filtragem. Estes são os pontos do conjunto de dados, que estão entre os limiares utilizados nas etapas anteriores, mas são pontos que ao serem comparados com seus vizinhos diferem em magnitude. O índice de correlação espacial de Moran univariado (I_i) (ANSELIN, 1995) foi utilizado como ferramenta para a identificação de discrepantes locais seguindo as recomendações de Córdoba et al. (2016). Este índice compara o valor de um ponto com sua vizinhança e calcula o grau de similaridade do valor do ponto analisado com o valor dos pontos vizinhos. Uma matriz espacial de pesos é definida para obter medidas de associação espacial. O critério utilizado para definir a vizinhança foi a distância de 20 metros. A equação 1 descreve o cálculo do índice de Moran que foi utilizado nesta etapa do processo de filtragem.

$$I_i = \frac{(x_i - \bar{x})}{\sum_{k=1}^n (x_k - \bar{x})^2 / (n-1)} \sum_{j=1}^n w_{ij} (x_j - \bar{x}) \quad (1)$$

em que:

I_i = Índice de Moran univariado;

$(x_i - \bar{x})$ = valor observado centrado na média da variável;

n = número de pontos observados;

w_{ij} = é o elemento da matriz proximidade espacial W que foi calculado utilizando o critério da distância euclidiana de 20 metros;

$\sum_{k=1}^n (x_k - \bar{x})^2 / (n - 1)$ = é a variância da variável;

As funções utilizadas para a obtenção do índice de Moran pertenciam ao pacote “spdep” (BIVAND et al., 2017) do programa estatístico R versão 3.4.3. Para obter a vizinhança de cada ponto para uma distância estabelecida foi utilizado a função “*dnearneigh*”, esta função retorna uma lista de vetores inteiros com identificação da vizinhança. Em seguida, foi utilizada a função “*nb2listw*” que complementava a função anterior com pesos espaciais de acordo o esquema de codificação escolhido, neste estudo foi usada a distância euclidiana, resultando na matriz de proximidade espacial W . Com a lista de vizinhança e pesos espaciais, foi calculado o I_i utilizando a função “*localmoran*”. Como resultados do cálculo de I_i , além do valor do índice de Moran (I_i), foram obtidos o valor esperado (E. I_i), a variância (Var. I_i), o valor padronizado (Z. I_i) e o p-valor (Pr ($z < 0$)). Para que um ponto seja considerado discrepante local, o p-valor deve ser pequeno o suficiente para o determinado índice.

Pontos que apresentaram autocorrelação espacial negativa significativa (p-valor <0,05) com os seus vizinhos foram excluídos da base de dados.

Uma vez calculado o valor do índice de Moran é importante estabelecer a validade do teste (CÂMARA et al., 2004). Sendo assim, o p-valor foi ajustado segundo o critério de Bonferroni devido à multiplicidade nos testes de hipóteses (CÓRDOBA et al., 2016). Onde a hipótese nula (H0) é de independência espacial e desta forma o índice de Moran assume o valor zero. E a hipótese alternativa (H1) é de dependência espacial, sendo valores do índice maiores do que o valor esperado indica autocorrelação direta e valores menores que o esperado indica autocorrelação inversa. Este método de ajuste faz com que o erro do estudo permaneça em 0,05 ($\alpha = 0,05$), uma vez que o critério de Bonferroni estabelece que os p-valores sejam multiplicados pelo número de comparações (BIVAND et al., 2017). Se o valor do ponto analisado é um valor elevado de produtividade, mas seus vizinhos apresentam valores baixos de produtividade, isto resultará em autocorrelação negativa. De forma análoga, quando o valor de produtividade do ponto analisado for similar aos seus vizinhos, isto resultará em correlação espacial positiva. Ao fim do processo de filtragem dos dados, foi realizada a análise dos histogramas e da estatística descritiva dos conjuntos de dados brutos e dos dados filtrados.

A interpolação dos dados de produtividade após a remoção dos valores discrepantes foi realizada com o auxílio do programa de computador Vesper 1.6 (MINASNY et al., 2005) pelo método de krigagem por blocos utilizando semivariogramas locais. Esta modalidade de interpolação foi utilizada por ser a mais recomendada para dados com altas densidades de pontos. Além disso, o erro da estimativa associado a krigagem em bloco é menor que aquele associado à krigagem ordinária (OLIVEIRA; GREGO; BRANDÃO, 2015).

A interpolação pela krigagem de bloco foi realizada utilizando variograma local gerado a partir de no mínimo 90 vizinhos e no máximo 100 vizinhos do ponto a ser interpolado. O tamanho do bloco adotado foi de 5,00 x 5,00 metros, para evitar a suavização demasiada do mapa resultante, uma vez que o aumento do tamanho do bloco resulta em maior suavização do resultado. E para que posteriormente fosse possível associar informações coletadas por diferentes sensores em uma mesma área (mapas de produtividade e imagens orbitais), os dados foram interpolados numa grade uniforme de 30,00 x 30,00 metros. Este valor de grade foi escolhido por ser

correspondente a menor resolução espacial das imagens orbitais os quais possuem tamanho de pixel 30,00 x 30,00 metros.

Além do mapa resultante da krigagem, o Vesper 1.6 gerou um mapa dos desvios padrão dos valores estimados pela krigagem que fornecia uma indicação do erro associado a cada valor interpolado. Na etapa final do sistema de geração de zonas de manejo, estes valores foram utilizados para analisar se havia diferença estatística entre as zonas, pelo método do intervalo de confiança que será descrito no subitem 2.3.

Os arquivos resultantes da krigagem gerados no formato texto (txt) foram convertidos no próprio Vesper para o formato ASCII (American Standard Code for Information Interchange, Código Padrão Americano para Intercâmbio de Informação). Estes arquivos foram importados para o *software* SIG (Sistema de Informação Geográfico) QGIS 2.16 (QGIS DEVELOPMENT TEAM, 2016) “Nødebo”, nele foram gerados todos os mapas temáticos apresentados neste trabalho.

2.2. Processamento de imagens orbitais e geração de mapas de índice de vegetação

Foram utilizadas as imagens de sensoriamento remoto adquiridas pelo instrumento *Operative Land Imager* (OLI) a bordo do satélite Landsat-8, pelo sensor *Enhanced Thematic Mapper* (ETM+) do Landsat-7 e pelo *Multi-Spectral Instrument* (MSI) presente do satélite Sentinel-2A. Foram adquiridas imagens de diferentes plataformas devido à falta de imagens de qualidade de um único sensor, disponíveis no período de cultivo. Os principais fatores que afetaram a disponibilidade de imagens foram a presença de nuvens e o tempo de revisita dos satélites.

As imagens dos satélites Landsat foram obtidas no catálogo de imagens *EarthExplorer* do USGS (United States Geological Survey, Serviço Geológico dos Estados Unidos) e fazem parte do conjunto de dados Landsat Collection 1 Level-2. O nível 2 de processamento consiste em imagens que apresentam os números digitais convertidos para reflectância de superfície, sendo realizado a correção dos efeitos atmosféricos além das correções geométricas antes de serem disponibilizadas (USGS, 2017).

As imagens do satélite Sentinel-2A foram obtidas na plataforma *Copernicus Open Access Hub* (SciHub) da Agencia Espacial Europeia (European Space Agency – ESA). As imagens orbitais obtidas da plataforma Sentinel-2A (produto: Level-1C) são

fornecidas em reflectância (ESA, 2015) e não necessitam de correção atmosférica, uma vez que esta correção é realizada antes da disponibilização das imagens para os usuários. A Tabela 1 apresenta as características das imagens obtidas pelos sensores de cada plataforma utilizada no estudo.

Tabela 1: Características das plataformas de sensoriamento remoto utilizadas.

Característica	Plataforma		
	Landsat-7	Landsat-8	Sentinel-2
Altitude	705 km	705 km	786 km
Largura da Faixa Imaginada	183 km	185 km	290 km
Resolução Temporal	16 dias	16 dias	5 dias*
Resolução Espacial	30 m	30 m	10 e 20 m
Resolução Radiométrica	8 bits	12 bits	12 bits

*Com dois satélites idênticos em órbita.

As bandas do infravermelho próximo, azul, verde, vermelha e SWIR foram utilizadas para geração dos índices de vegetação selecionados para a avaliação. Na Tabela 2 são apresentadas as características de cada banda dos satélites utilizados. A banda 8A do Sentinel-2A foi selecionada em vez da banda 8, tendo em vista que a resposta espectral para banda 8A é similar à banda 5 do Landsat-8 (SKAKUN et al., 2017). A utilização da banda 8A permitiu uma maior uniformidade dos índices de vegetação calculados, mesmo utilizando imagens geradas a partir de diferentes sensores.

Tabela 2: Números de bandas correspondentes para cada sensor.

Nome Genérico	Plataforma		
	Landsat-7	Landsat-8	Sentinel-2
Verde	2 (520-600)	3 (530-590)	3 (543-578)
Vermelho	3 (630-690)	4 (640-670)	4 (650-680)
Infravermelho próximo (NIR)	4 (770-900)	5 (850-880)	8A (849-882)
Infravermelho de onda curta (SWIR)	5 (1550-1750)	6 (1570-1650)	11 (1565-1655)

* Os valores entre parênteses (em nanômetros) correspondem à largura espectral de cada banda do sensor.

A Tabela 3 apresenta as informações do plantio e colheita de cada safra. Nas safras analisadas foram utilizadas cultivares diferentes de soja, uma precoce com ciclo curto de 120 dias e outra tardia com o ciclo de 140 dias. Esta seleção de cultivares pode ser

explicada devido ao manejo contra o ataque de pragas e/ou doenças, além disso, esta prática também permite que as datas de colheita dos diferentes talhões da propriedade não coincidam. As cultivares foram semeadas em datas semelhantes do ano, ao fim de outubro, pois a fazenda realiza o plantio do milho logo após a colheita da soja.

Tabela 3: Datas de plantio, colheita e duração do ciclo dos cultivos de soja analisados.

Safra	Plantio	Colheita	Ciclo
2015/16	26/10/2015	02-04/03/16	120 dias
2016/17	29/10/2016	23-24/03/17	140 dias

Como a correlação entre índices de vegetação e a produtividade pode variar com o tempo, foram testados índices obtidos em duas datas no ciclo da cultura para cada safra. Foram selecionadas imagens obtidas no meio do ciclo do cultivo e próximo ao fim do ciclo. Na Tabela 4 são apresentadas as datas de cada imagem e o período correspondente ao ciclo da soja.

Tabela 4: Datas das imagens utilizadas nas análises.

	Plataforma	Data de imageamento	Dias após o plantio
Safra 2015/16	Landsat-8	17/12/2015	52
	Landsat-7	26/01/2016	92
Safra 2016/17	Santinel-2	08/01/2017	77
	Sentinel-2	17/02/2017	111

O processamento das imagens utilizadas consistiu em realizar a reamostragem de cada banda para pixels de 30 metros utilizando o método do vizinho mais próximo, a fim de se ter a mesma resolução espacial para as imagens e os mapas de produtividade. Este procedimento não melhora a resolução da imagem, apenas redefine o tamanho dos pixels. Após a reamostragem as bandas foram alinhadas, para que a amostragem da área de interesse (talhão) não fosse afetada pelo deslocamento da grade.

A utilização de índices de vegetação permite captar melhor diferentes características das plantas, uma vez que estes podem ser sensíveis a determinados fatores que podem interferir na produtividade. O emprego de vários índices permite explorar o potencial de imagens orbitais na identificação da variabilidade espacial da vegetação. Foram utilizadas 4 bandas multiespectrais para gerar os índices de

vegetação que tem como características não saturar facilmente ou podem compensar a interferência por solo exposto. E também aqueles índices que se relacionam com certas características como déficit hídrico ou parâmetros biofísicos das plantas.

A Tabela 5 apresenta os índices que foram utilizados neste estudo, assim como as equações que definem cada índice utilizado: GCVI (Green Chlorophyll Vegetation Index), SIWSI (Shortwave Infrared Water Stress Index), EVI2 (Enhanced Vegetation Index), NDVI (Normalized Difference Vegetation Index), SAVI (Soil-adjusted vegetation index) e MSR (Modified Simple Ratio).

Tabela 5: Equações e referências dos índices de vegetação utilizados.

Índice	Fórmula	Autor
GCVI	$\frac{\rho_{NIR}}{\rho_{green}} - 1$	(GITELSON et al., 2003)
SIWSI	$\frac{\rho_{SWIR} - \rho_{NIR}}{\rho_{SWIR} + \rho_{NIR}}$	(FENSHOLT; SANDHOLT, 2003)
EVI2	$2,5 \left(\frac{\rho_{NIR} - \rho_{red}}{1 + \rho_{NIR} + 2,4\rho_{red}} \right)$	(JIANG et al., 2008)
NDVI	$\frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}}$	(TUCKER, 1979)
SAVI	$\frac{(\rho_{NIR} - \rho_{red})}{(\rho_{NIR} + \rho_{red} + L)} (1 - L)$	(HUETE, 1988)
MSR	$\frac{\left(\frac{\rho_{NIR}}{\rho_{red}} \right) - 1}{\sqrt{\left(\frac{\rho_{NIR}}{\rho_{red}} \right) + 1}}$	(CHEN, 1996)

Em que ρ_{SWIR} , ρ_{NIR} , ρ_{green} e ρ_{red} são as reflectâncias nos comprimentos de onda das bandas do infravermelho de onda curta, infravermelho próximo, banda verde e da banda vermelha, respectivamente. $L = 0,5$. Os comprimentos de ondas variaram de acordo com o sensor conforme apresentados na Tabela 2.

Estes índices foram escolhidos por terem aplicação mais comum em trabalhos de análise de variabilidade espacial de desenvolvimento das culturas. Na delimitação das zonas de manejo foram empregados os índices de vegetação separadamente para cada data analisada, afim de inferir para qual data os índices melhor relacionam-se com a produtividade. Os índices que apresentaram correlação espacial significativa com a

produtividade de cada safra foram utilizados para delimitação das zonas de manejo. O Índice Bivariado Global de Moran (I_{xy}) (ANSELIN, 1995) quantifica o grau de correlação espacial entre duas variáveis em toda a área. A avaliação da correlação espacial dos índices de vegetação com os mapas de produtividade foi obtida calculando o índice I_{xy} de Moran dado pela Equação (2).

$$I_{xy} = \frac{\sum_i \sum_j (x_i - \bar{x}) W_{ij} (y_j - \bar{y})}{\sum_{i=1}^n \sum_{j=1}^n W_{ij} \sqrt{\frac{\sum_{i=1}^n (y_j - \bar{y})^2}{n} \frac{\sum_{j=1}^n (x_i - \bar{x})^2}{n}}} \quad (2)$$

em que:

I_{xy} = Índice de Moran bivariado;

n = número de pontos observados;

$(x_i - \bar{x})$ e $(y_j - \bar{y})$ = valores observados centrados nas médias das variáveis x e y , respectivamente;

w_{ij} = elemento da matriz proximidade espacial W que foi calculada utilizando o critério de contiguidade;

$$\frac{\sum_{i=1}^n (y_j - \bar{y})^2}{n} \text{ e } \frac{\sum_{j=1}^n (x_i - \bar{x})^2}{n} = \text{variâncias das variáveis } y \text{ e } x, \text{ respectivamente.}$$

O índice I_{xy} de Moran bivariado estima a magnitude da autocorrelação espacial entre áreas comparando o valor do ponto observado com a média dos valores da vizinhança, ponderada pela distância entre locais próximos no espaço. Os valores do índice I_{xy} de Moran próximos de 1 e -1 indicam autocorrelação positiva e negativa, respectivamente. Valores de I_{xy} igual a 0 suportam a hipótese nula, de que não há autocorrelação espacial. A análise de significância do índice é obtida por meio do teste de pseudossignificância, em que são realizadas permutações aleatórias dos valores dos pontos a fim de obter uma distribuição empírica de I_{xy} . Desta forma, o valor medido originalmente tem significância estatística se corresponder a um “extremo” da distribuição simulada (CÂMARA et al., 2004). Com base na equação 2 os padrões espaciais entre produtividade e índices de vegetação foram construídos a partir de 999 permutações aleatórias utilizando o programa computacional GeoDA 1.6.2 (ANSELIN; SYABRI; KHO, 2006).

A significância do teste de correlação espacial pode ser influenciada pelo tamanho da amostra, o p-valor mede a distância entre os dados e a hipótese nula usando uma estimativa do parâmetro de interesse. Em grandes amostras o p-valor se aproxima de

zero rapidamente (LIN; LUCAS; SHMUELI, 2013). Sendo assim, "pequenas" diferenças matemáticas entre o valor suposto na hipótese de nulidade (índice de autocorrelação igual a zero) e o valor estimado do índice de Moran passam a ser significativos. Para evitar este problema foi retiradas 30 amostras aleatórias de 50 pontos do conjunto de dados para testar a significância do índice Moran. Com um menor tamanho amostral somente diferenças "expressivas" foram significativas. Os índices de vegetação que apresentaram correlação espacial significativa em 90% dos testes, foram utilizados nas análises de agrupamentos.

2.3. Geração de zonas de manejo a partir de mapas de produtividade e de mapa de índice de vegetação

A análise de agrupamento *fuzzy k-means* foi realizada utilizando o programa de computador FUZME 3.0 (MINASNY e McBRATNEY, 2002). Foram feitos agrupamentos com até quatro classes e posteriormente estas classes submetidas a análise estatística para avaliar se a diferença entre elas era significativa. Foram empregados os mapas de produtividade de cada safra separadamente, os índices que apresentaram correlação espacial significativa em cada data, e para ambas as datas analisadas de cada safra também. Também foi realizada a análise de agrupamentos de ambos os mapas de produtividade das safras juntas de todos os índices que apresentaram correlação significativa com a produtividade.

Como o NDVI é um dos índices mais utilizados em pesquisas e consultorias agrônomicas, foi realizada a análise de agrupamentos utilizando apenas este índice de vegetação e comparada às zonas de manejo delineadas apenas com a utilização de mapas de produtividade.

Para avaliar o grau de concordância entre as zonas de manejo delimitadas com os mapas de produtividade e as zonas delimitadas utilizando os índices de vegetação foi utilizado o teste de concordância Kappa (COHEN, 1960).

3. RESULTADOS E DISCUSSÃO

3.1. Análise dos dados de produtividade de soja nas safras 2015/16 e 2016/2017

A avaliação de mapas de produtividade é importante para a gestão da produção de grãos em uma propriedade agrícola. A análise dos dados de produtividade iniciou com a conversão das coordenadas geográficas para coordenadas UTM, e a geração de mapas temáticos com os dados experimentais de produtividade (Figura 4) para as safras 2015/2016 e 2016/2017.

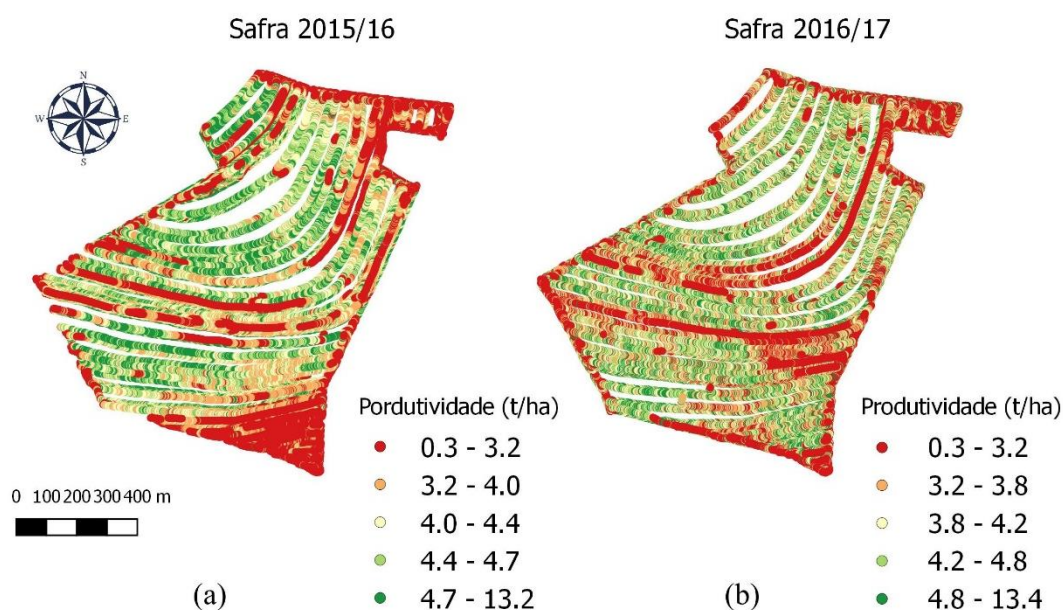


Figura 4: Mapas de produtividade antes da remoção de valores discrepantes (a) safra 2015/16 e (b) safra 2016/17.

Na Figura 4a é apresentado os dados brutos da safra 2015/16, onde é possível observar uma área ao sudoeste do talhão com grande quantidade de pontos com baixos valores de produtividade. Enquanto que na Figura 4b não é possível observar faixas extensas com baixos valores como é observado na Figura 4a.

O processamento dos dados de produtividade consistiu em realizar a filtragem destes em três etapas conforme apresentado no diagrama da Figura 3. A filtragem realizada por meio de técnicas estatísticas é de fácil aplicação, porém pode ser considerada subjetiva e portanto é aconselhável analisar a distribuição dos pontos candidatos a remoção (MOLIN; AMARAL; COLAÇO, 2015). A primeira etapa da filtragem dos dados foi a aplicação dos limiares para remover os pontos incoerentes. Nesta etapa, objetivou-se eliminar os pontos com valores muito elevados ou muito

baixos de produtividade, os quais certamente foram originados por falha nos sensores do monitor de produtividade. Na Figura 5 é apresentado a localização dos pontos removidos na primeira etapa.




Figura 5: Localização dos pontos removidos na primeira etapa do processo de filtragem dos dados (a) safra 2015/16 e (b) safra 2016/17.

Na primeira etapa de filtragem foram removidos 0,1% e 0,4% dos pontos do conjunto de dados da primeira e da segunda safra, respectivamente. A grande maioria dos pontos removidos na primeira etapa apresentaram valores de produtividade superiores a 8 t/ha. Sendo a média de produtividade para as duas safras em torno de 4 t/ha. Valores de produtividades acima de 8 t/ha são superiores à produtividade máxima esperada para a soja. Pontos com valores que extrapolam em muito o que pode ser encontrado em campo, se não removidos, interferem nos resultados de interpolação para toda a área (MOLIN; AMARAL; COLAÇO, 2015). Portanto, esses dados devem ser removidos do conjunto para não afetar as próximas etapas da análise dos dados.

A segunda etapa do processamento foi a remoção de discrepantes globais com base na estatística descritiva e filtro local. Nesta etapa foram utilizados como limiares a média $\pm 2,5$ DP, calculados após a remoção dos pontos com valores fora da realidade na primeira etapa. Os pontos candidatos a discrepantes globais foram submetidos a análise dos vizinhos locais. Para a determinação da vizinhança dos pontos foi utilizada uma distância de 20 metros. Foram removidos os pontos que diferiram em 25% do valor da mediana dos vizinhos próximos. O resultado deste processo é apresentado na

Figura 6, sendo que os pontos em verde foram removidos nesta etapa do processamento.

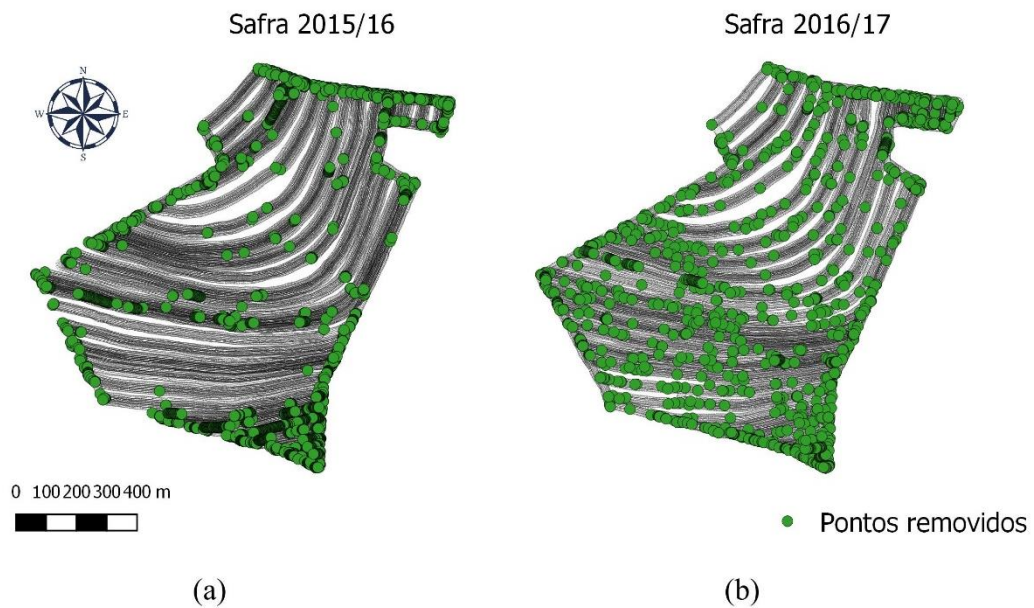


Figura 6: Localização dos pontos removidos na segunda etapa do processo de filtragem dos dados (a) safra 2015/16 e (b) safra 2016/17.

Embora visualmente possa parecer que na safra 2016/17 (Figura 6b) o número de pontos removidos foi maior que na safra 2015/16 (Figura 6a), houve uma grande concentração de pontos discrepantes na região sudoeste da área na safra 2015/16. O total de pontos removidos foi de 3,6% e 2,7% nas safras 2015/16 e 2016/17, respectivamente. É possível observar uma tendência de os pontos removidos nesta etapa estarem localizados nas extremidades do talhão. Esta tendência é mais evidente ao observar os pontos removidos na safra 2015/16, apesar de a maior parte dos pontos removidos estarem concentrados na região sudeste do talhão (Figura 6a). Na safra 2016/17, os pontos removidos tiveram uma distribuição espacial mais uniforme (Figura 6b).

Constantes manobras e variações de velocidade da colhedora podem resultar em maior quantidade de pontos com informações imprecisas (TAYLOR; MCBRATNEY; WHELAN, 2007). A área de estudo apresenta formato irregular, desta forma, a maior parte dos pontos removidos durante a segunda etapa do processo de filtragem estava localizada próxima as bordas e em áreas onde a colhedora necessita realizar passadas curtas e com maior número de manobras. Isso se deve ao fato de que ao entrar no talhão, após uma manobra, a colhedora requer um tempo para que o fluxo de material

recolhido se estabilize. Este tempo é de aproximadamente 15 a 20 segundos, para que os sistemas de trilha separação e limpeza atinjam um fluxo de trabalho (MOLIN; AMARAL; COLAÇO, 2015). Durante esse intervalo de tempo, os pontos registrados não refletem a real produtividade do local, pois os sensores estarão registrando um fluxo menor e crescente. De forma similar, este fenômeno também ocorre ao encerrar a entrada de material nos sistemas da colhedora ao final de cada passada. Os pontos coletados nestas condições de início e final da passada da colhedora, são considerados estimativas de produtividade não confiáveis e apresentam baixos valores (SUDDUTH; DRUMMOND; MYERS, 2012), portanto devem ser removidos do conjunto de dados.

A terceira etapa do processo de filtragem dos dados de produtividade removeu os valores discrepantes locais presentes no conjunto dados e que foram identificados pelo índice de Moran. Nesta etapa foram removidos os pontos com valores do índice de Moran negativos e estatisticamente significativos. Este procedimento removeu 2,2% dos pontos na primeira safra e 3,7% dos pontos nos dados da segunda safra. Na Figura 7 estão apresentados os pontos removidos.

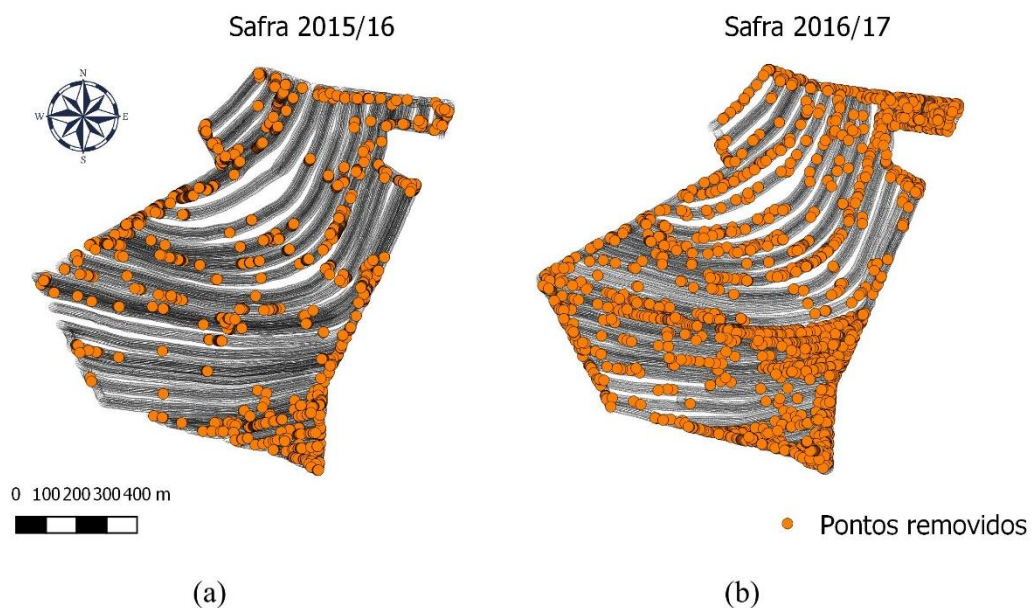


Figura 7: Localização dos pontos removidos na terceira etapa do processo de filtragem dos dados (a) safra 2015/16 e (b) 2016/17.

A identificação e remoção de discrepantes locais é a etapa mais complicada do processo de filtragem. Discrepantes locais foram identificados em áreas onde os pontos não apresentaram valores de produtividade similares aos seus vizinhos. Para ilustrar a operacionalidade deste processo, na Figura 8 os pontos removidos durante a terceira etapa foram plotados no mapa de produtividade interpolado da safra 2016/17 (somente

os dados filtrados foram interpolados). Desta forma, é possível analisar visualmente se os pontos removidos são de fato discrepantes locais.

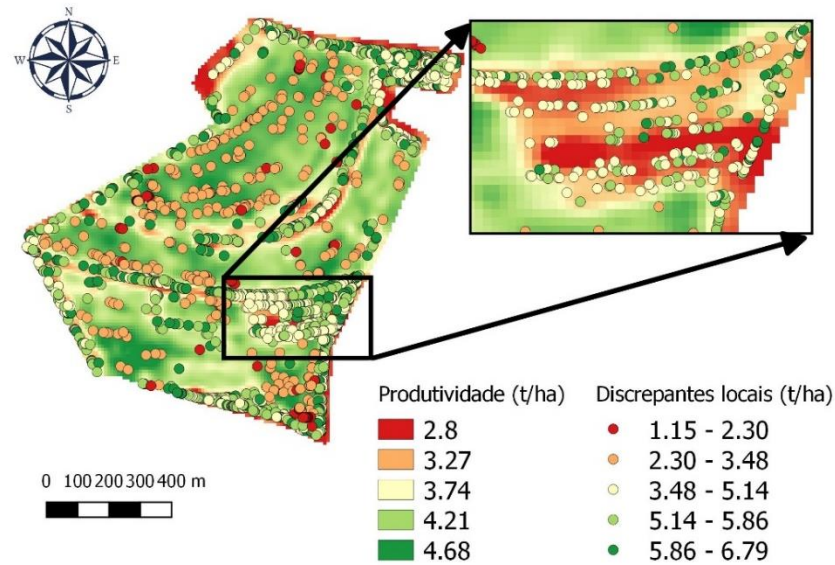


Figura 8: Localização dos discrepantes locais identificados na terceira etapa do processo de filtragem (Índice de Moran) sobreposto no mapa de produtividade para a safra 2016/17.

Na Figura 8 observa-se que os pontos removidos na terceira etapa estão localizados nas bordas de onde há transição de magnitudes de valores de produtividade. Entretanto, as áreas de baixa e alta produtividade não foram removidas, isto agrega maior confiabilidade aos mapas e aos resultados obtidos. Se não removidos, discrepantes locais podem influenciar na magnitude das “manchas” presentes em mapas de produtividade. Podendo afetar na análise da variabilidade da lavoura e necessita de intervenção.

Uma das etapas do processo de filtragem proposto por Ping e Dobermann (2005), foi a realização de um teste de vizinhança local para remover erros em dados de produtividade. Os autores atribuíram que a causa de pontos identificados como discrepantes locais foi devido a problemas de manejos locais ou em mudanças repentinas de velocidade da colhedora. Neste estudo, os pontos removidos na terceira etapa geralmente estão localizados em “manchas” de alta ou baixa produtividade do mapa (Figura 8).

Para sintetizar os resultados do processo de filtragem é apresentado a quantidade de pontos removidos em cada etapa na Tabela 6. O processo de filtragem removeu 5,9% (2888 pontos) dos pontos do conjunto de dados da primeira safra e 6,8% (2884 pontos) da segunda safra. Estudos reportaram remoção de 10% até 30% de pontos do

conjunto (PING; DOBERMANN, 2005; SUDDUTH; DRUMMOND, 2007; SUN et al., 2013), dependendo da técnica de filtragem aplicada. Foram removidos mais pontos do conjunto de dados da safra 2015/16, mas que corresponde a um percentual menor do total de pontos.

Tabela 6: Pontos removidos em cada etapa do processo de filtragem dos dados de produtividade das safras analisadas, entre parênteses o percentual em relação ao total de dados brutos.

	Safra 2015/16	Safra 2016/17
Dados brutos	49190	42190
Etapa 1	36 (0,1%)	163 (0,4%)
Etapa 2	1790 (3,6%)	1156 (2,7%)
Etapa 3	1062 (2,2%)	1565 (3,7%)
Total removido	2888 (5,9%)	2884 (6,8%)

Conforme a Tabela 6, a etapa 2 do processo de filtragem foi a etapa que removeu mais pontos na safra 2015/16, provavelmente devido a distribuição dos valores de produtividade em que a concentração de valores que se afastam da média. Enquanto que para os dados da safra 2016/17, foi a etapa 3 que mais removeu pontos possivelmente devido a problemas de manejos locais conforme detalhado na Figura 7. Ao término da filtragem dos dados de produtividade, para avaliar os resultados, foi realizada a análise da estatística descritiva dos dados antes do processo de filtragem (dados brutos resultantes do pré-processamento) e após a filtragem. O resultado dessa análise é apresentado na Tabela 7.

Tabela 7. Estatística descritiva dos dados antes e após o processo de filtragem.

Parâmetros	Safra 2015/16		Safra 2016/17	
	Dados brutos	Dados filtrados	Dados brutos	Dados filtrados
Média (t/ha)	3,929	4,024	3,987	3,940
Máximo (t/ha)	13,25	6,625	13,42	6,784
Mínimo (t/ha)	0,338	0,869	0,336	1,143
Amplitude (t/ha)	12,912	5,756	13,084	5,641
Alcance interquartil (t/ha)	1,09	0,99	1,27	1,17
Variância	1,20	0,82	1,41	0,95
Desvio padrão	1,09	0,91	1,19	0,97
Coefficiente de variação (%)	27,9	22,5	29,8	24,7
Assimetria	-1,07	-1,14	0,41	-0,18
Curtose	4,92	3,94	6,51	3,32

Ao observar os valores da estatística descritiva da Tabela 7, pode-se destacar a redução dos desvios padrão dos dois conjuntos de dados filtrados em relação aos dados não filtrados para cada safra, resultando na redução dos coeficientes de variação de 5,5% para os dados da safra 2015/12 e 5,1% para os dados da safra 2016/17, respectivamente. Sun et al. (2013) também observaram redução no coeficiente de variação de dados de produtividade filtrados em relação aos dados brutos (não filtrados). Os resultados do processo de filtragem também apresentaram redução da variância dos dados. Em outros estudos, geralmente são observados que dados de produtividade processados tendem a apresentar maior média (LYLE; BRYAN; OSTENDORF, 2014; PING; DOBERMANN, 2005; SUDDUTH; DRUMMOND, 2007).

Outra forma de avaliar o resultado do processo de filtragem é por meio da análise das mudanças no histograma dos valores de produtividade e os valores de assimetria e curtose (LYLE; BRYAN; OSTENDORF, 2014). Na Figura 9 são apresentados os histogramas dos valores de produtividade dos dados após o processo de filtragem realizado para cada safra.

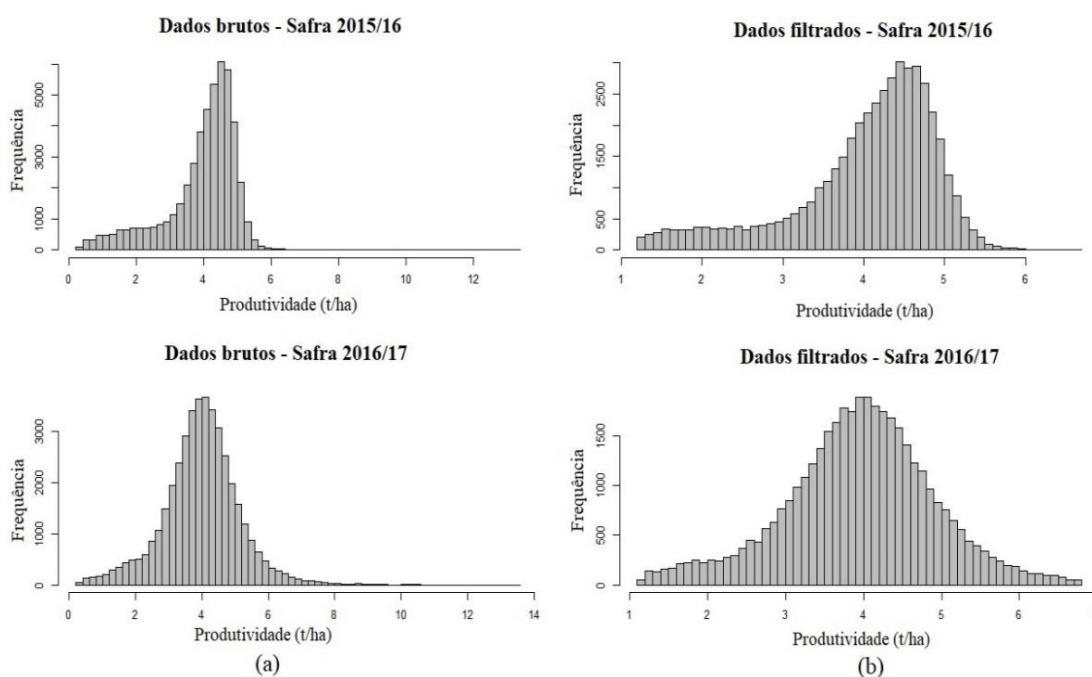


Figura 9: Histogramas dos valores de produtividade: (a) antes do processo de filtragem e (b) após o processo de filtragem, para as safras analisadas.

O histograma dos dados brutos da safra 2015/16 (Figura 9a) apresentou uma cauda mais alongada para os valores de produtividade de 0 a 2,5 t/ha. Esta forma de histograma se afasta do formato da distribuição normal, indicando tendência de

assimetria negativa. Esse histograma alongado à esquerda pode ser resultado de dois fatores: primeiro pode ser que nos limites do talhão a produtividade tenha sido menor devido ao manejo da área, por exemplo, o solo poderia estar mais compactado devido à manobra das máquinas. O segundo fator pode ser erro nos dados de produtividade provocado por incorreção no tempo de enchimento da colhedora. Já o histograma dos dados da safra 2016/17 (Figura 9b) apresentaram distribuição semelhante à distribuição normal. O processo de filtragem fez com que a forma das distribuições (Figura 9b) fossem mais simétricas quando comparadas à distribuição de dados brutos (Figura 9a).

Com os dados filtrados, o próximo procedimento foi realizar a interpolação dos pontos para gerar os mapas de produtividade. A interpolação foi realizada utilizando o programa de computador Vesper, gerando mapas de produtividade com tamanho de pixel de 30 metros. Os resultados da interpolação da produtividade para as safras 2015/16 e 2016/17 são apresentados na Figura 10.

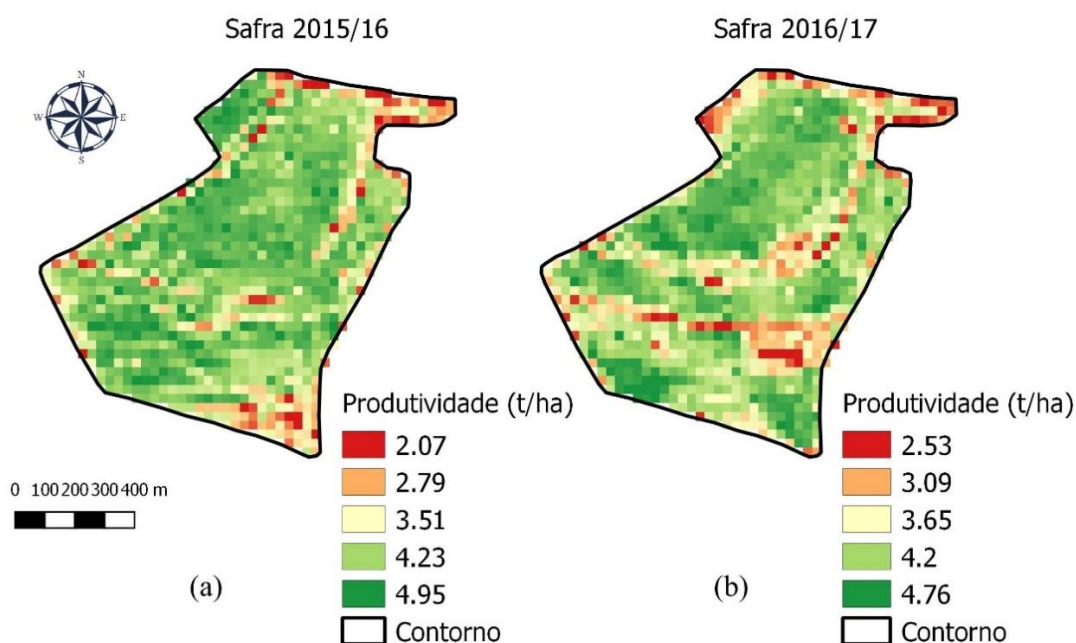


Figura 10: Mapas de produtividade de cada safra, resultantes da interpolação dos dados filtrados (a) safra 2015/16 e (b) safra 2016/17.

Os parâmetros utilizados na interpolação permitiram obter mapas de produtividade consistentes e suavizados, e que podem ser utilizados para análise da variabilidade encontrada na lavoura. A análise visual dos mapas (Figura 10) permite observar que há áreas de baixa produtividade localizadas nas bordas. Isto pode ser consequência de erros em dados de produtividade, causados pelo tempo de enchimento e de retardo das

colhedoras (MOLIN; AMARAL; COLAÇO, 2015). Entretanto, o processo de filtragem dos dados foi conduzido cuidadosamente para remover erros existentes no conjunto de dados e ao observar a distribuição dos pontos removidos, percebe-se que muitos deles estavam localizados nas bordas. Podendo indicar que o processo de filtragem apresentou efetividade para detectar este tipo de erro em dados de produtividade. Sendo que manobras realizadas pela colhedora no início e término das passadas é uma das principais fontes de erro (LYLE; BRYAN; OSTENDORF, 2014). Investigações a campo devem ser conduzidas para averiguar se essa tendência de baixa produtividade nas bordas do talhão é autêntica.

Existem áreas que apresentaram baixa produtividade em um ano e não apresentaram a mesma tendência na safra seguinte. Isto demonstra a variabilidade temporal da produtividade em um mesmo talhão, evidenciando a importância de analisar mais de um mapa de produtividade. Ping e Dobermann (2005), ao estudar a variabilidade em mapas de produtividade de vários anos em cultivo irrigado, destacaram que variações no manejo da irrigação, mudanças de plantio, direção da linha provavelmente influenciaram os padrões de produtividade. Áreas que tendem a manter baixa produtividade ao longo de duas ou mais safras, podem representar áreas com baixo potencial de produtividade ou que necessitam de um manejo diferenciado.

A interpolação tendeu a suavizar os valores, desta forma foi realizada a análise da estatística descritiva dos dados filtrados e dos pixels da imagem resultante do processo de interpolação, os resultados são apresentados na Tabela 8.

Tabela 8: Estatística descritiva dos dados após o processo de filtragem e após o processo de interpolação.

Parâmetros	Safra 2015/16		Safra 2016/17	
	Dados filtrados	Dados interpolados	Dados filtrados	Dados interpolados
Média (t/ha)	4,024	4,003	3,940	4,007
Máximo (t/ha)	6,625	5,606	6,784	5,307
Mínimo (t/ha)	0,869	1,090	1,143	1,615
Amplitude (t/ha)	5,756	4,516	5,641	3,692
Desvio padrão	0,91	0,78	0,97	0,67
Coefficiente de variação (%)	22,5	19,6	24,6	14,3

Na análise da estatística descritiva apresentada, pode-se observar que houve uma suavização dos valores de máximo e mínimo dos dados interpolados em relação aos dados filtrados. No entanto, o processo de interpolação refletiu diferentemente para

cada safra neste estudo. Sendo que para a safra 2015/16, o coeficiente de variação dos dados interpolados diminuiu 2,7% em relação aos dados filtrados, e para a safra 2016/17 observa-se a redução do coeficiente de variação em 10,3%.

Áreas de baixa produtividade podem ser ocasionadas por diferentes fatores, desde problemas de fertilidade, compactação do solo e ataques de pragas. Ao analisar os mapas de produtividade obtém-se a resposta final de um ciclo de cultivo, mas maiores investigações devem ser realizadas para entender e tratar a variabilidade observada. Imagens de satélite obtidas durante o ciclo do cultivo podem proporcionar um acréscimo de informações. O sensoriamento remoto demonstra ter grande potencial como ferramenta para incorporar informações para práticas agrícolas (HABOUDANE et al., 2004). Sendo assim a próxima etapa do sistema para delimitação de zonas de manejo foi a obtenção e processamentos de imagens orbitais.

3.2. Análise de imagens de satélites da área

Foi realizada a reamostragem das imagens orbitais para pixels de 30 metros e com as imagens processadas foram calculados os índices de vegetação descritos na Tabela 5. Um dos índices utilizados foi o índice de vegetação que emprega a banda SWIR. Segundo Vescovo et al. (2012), essa banda geralmente está relacionada com o déficit hídrico das plantas e além disso, não apresenta o problema de saturação na predição de variáveis da vegetação. A água presente nas folhas das plantas é onde ocorre a maior absorção da banda de onda curta de infravermelho (SWIR) e portanto a reflectância das plantas é relacionada negativamente ao conteúdo de água foliar (FENSHOLT; SANDHOLT, 2003).

Entre os índices também foi utilizado o GCVI que é calculado com a reflectância da banda verde, uma vantagem deste índice é que não satura em valores elevados de área foliar em comparação com outros índices comuns (LOBELL; AZZARI, 2017). O índice EVI2 tem como característica não saturar em altos valores de área foliar e também por minimizar a influência do solo (ZOU; MÖTTUS, 2017). Este índice foi utilizado para estimar produtividade de milho e soja nos Estados Unidos (BOLTON; FRIEDL, 2013) e de milho na China (PENG; GITELSON, 2011). O índice SAVI também permite a compensação dos efeitos do solo. Enquanto os índices MSR e NDVI apresentam apropriada correlação com parâmetros biofísicos das plantas.

Os resultados dos índices de vegetação calculados são apresentados em falsa-cor nas duas datas analisadas da safra 2015/16 (Figuras 11 e 12) e na safra 2016/17 (Figuras 13 e 14).

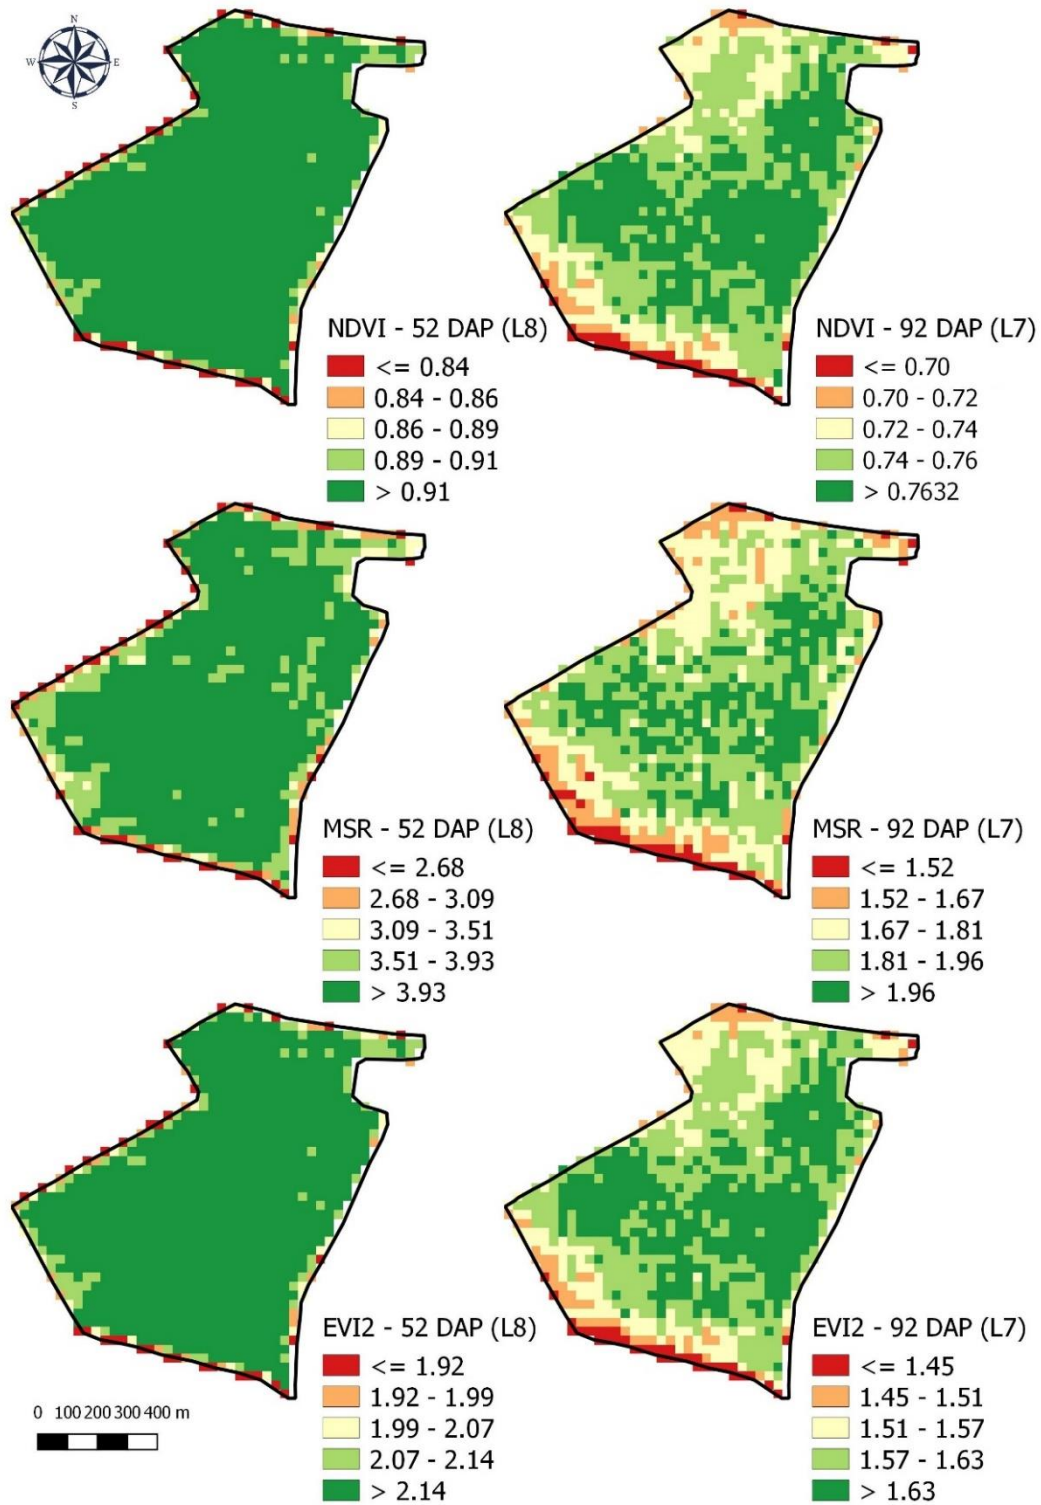


Figura 11: Variabilidade temporal apresentada pelos índices de vegetação NDVI, MSR e EVI2 a 52 e 92 Dias Após o Plantio (DAP) para a safra 2015/16.

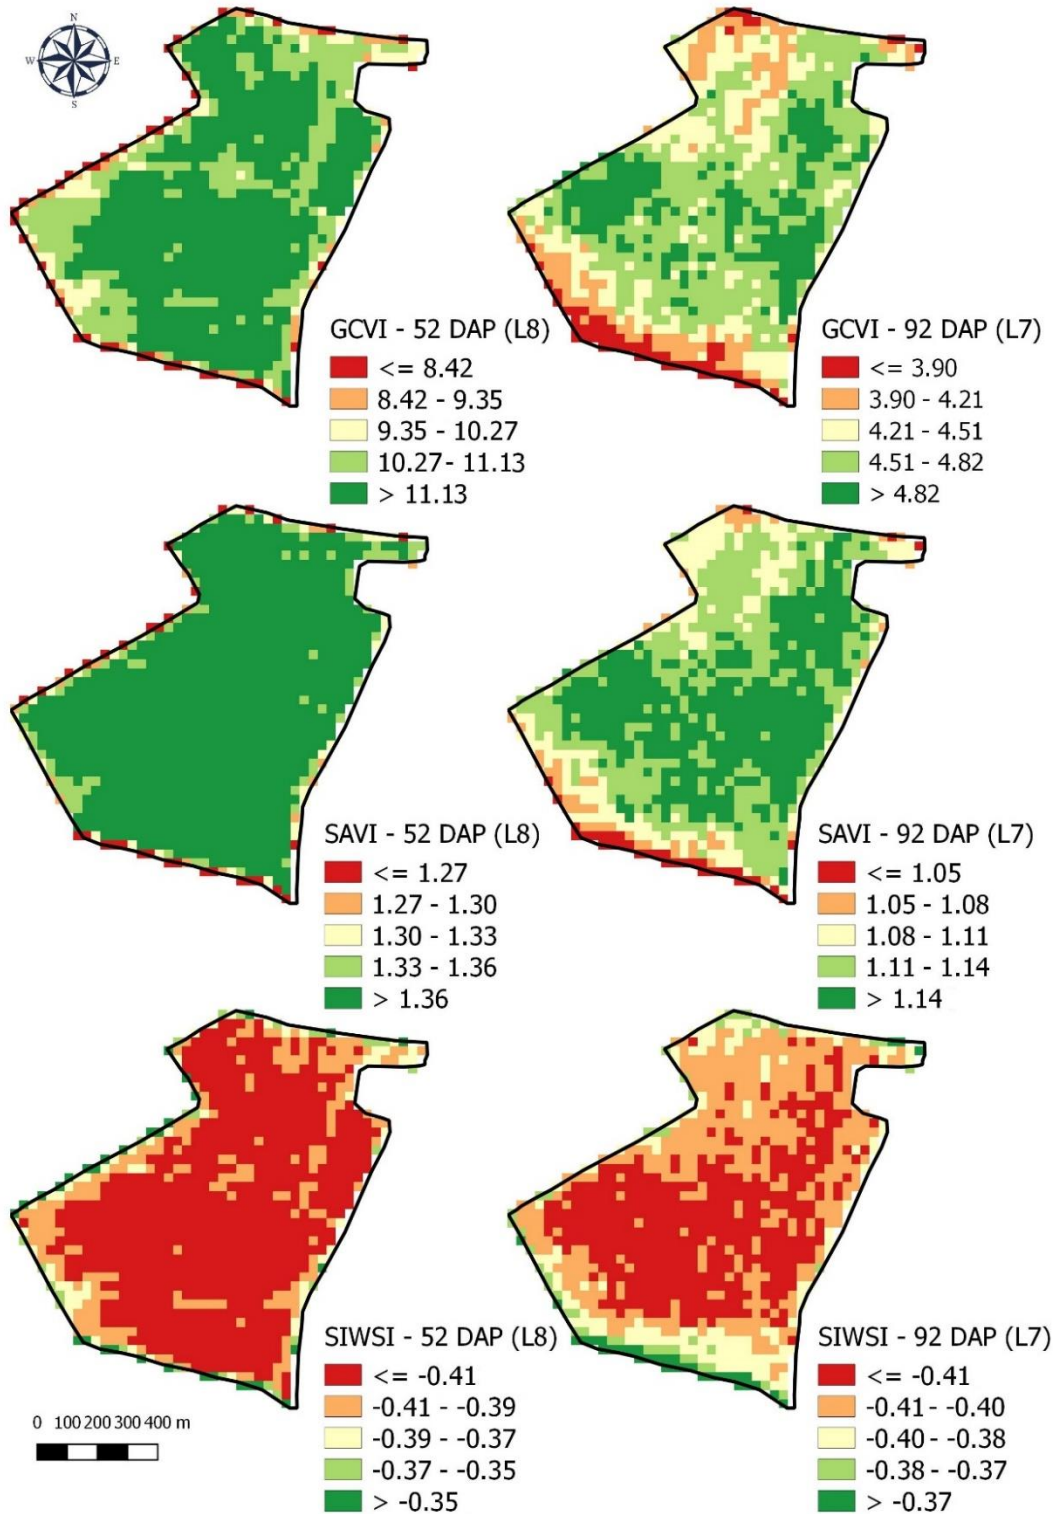


Figura 12: Variabilidade temporal apresentada pelos índices de vegetação GCVI, SAVI e SIWSI a 52 e 92 Dias Após o Plantio (DAP) para a safra 2015/16.

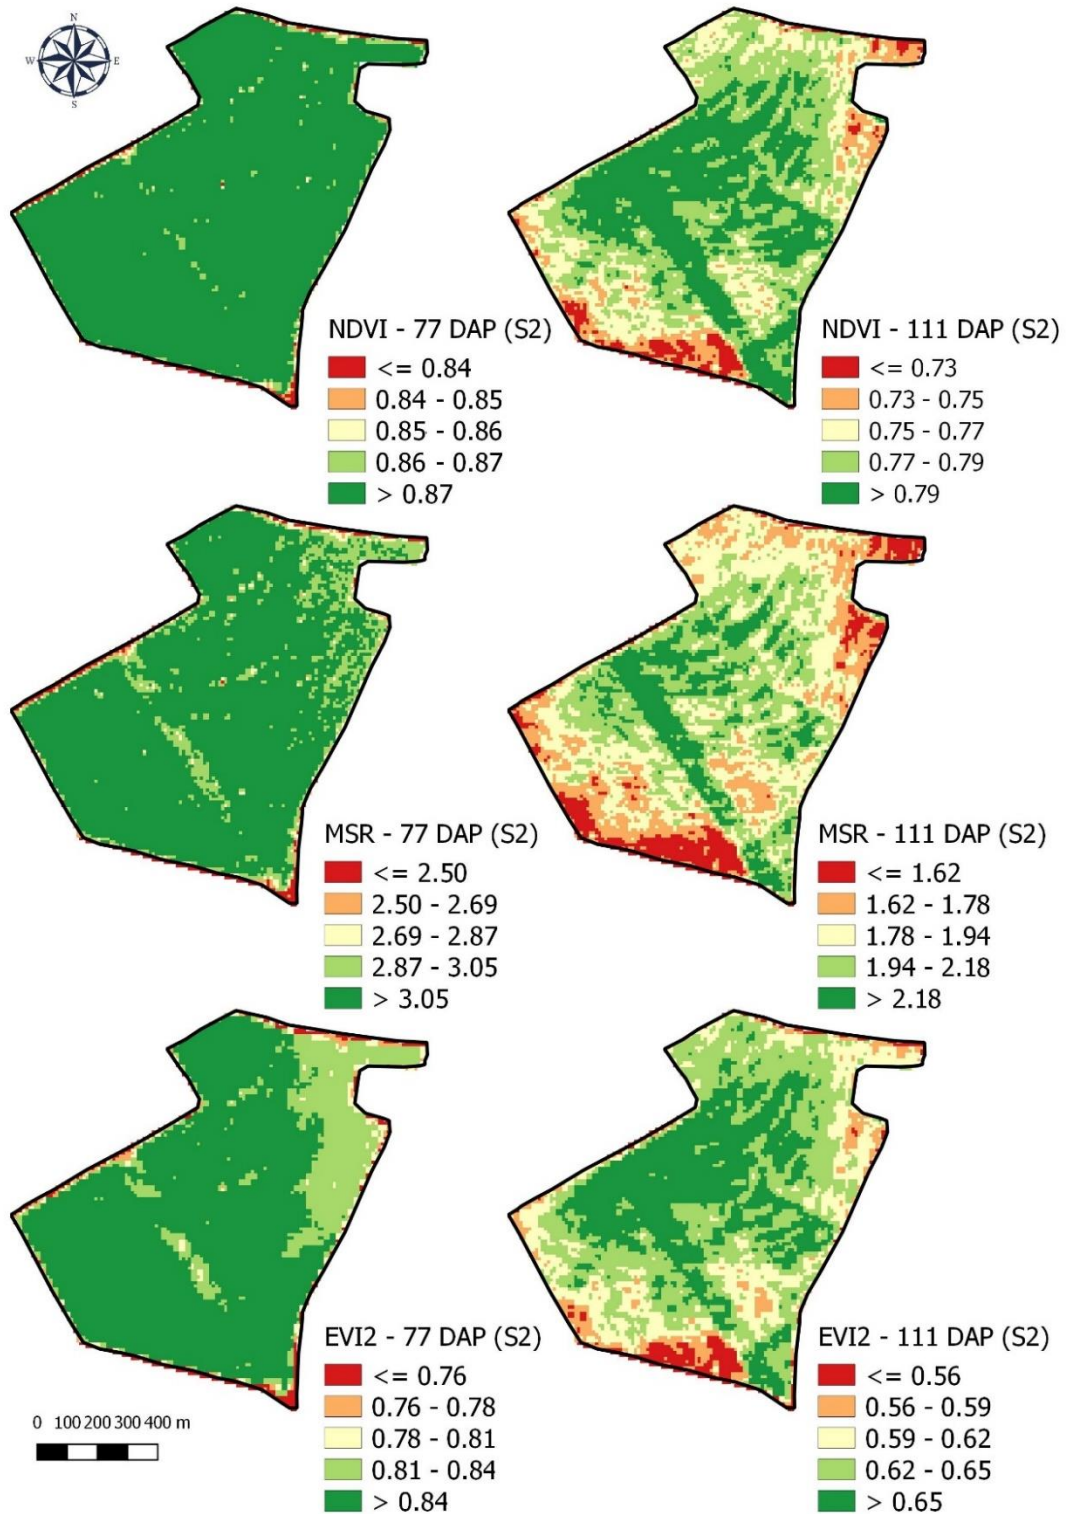


Figura 13: Variabilidade temporal apresentada pelos índices de vegetação NDVI, MSR e EVI2 a 77 e 111 Dias Após o Plantio (DAP) para a safra 2016/17.

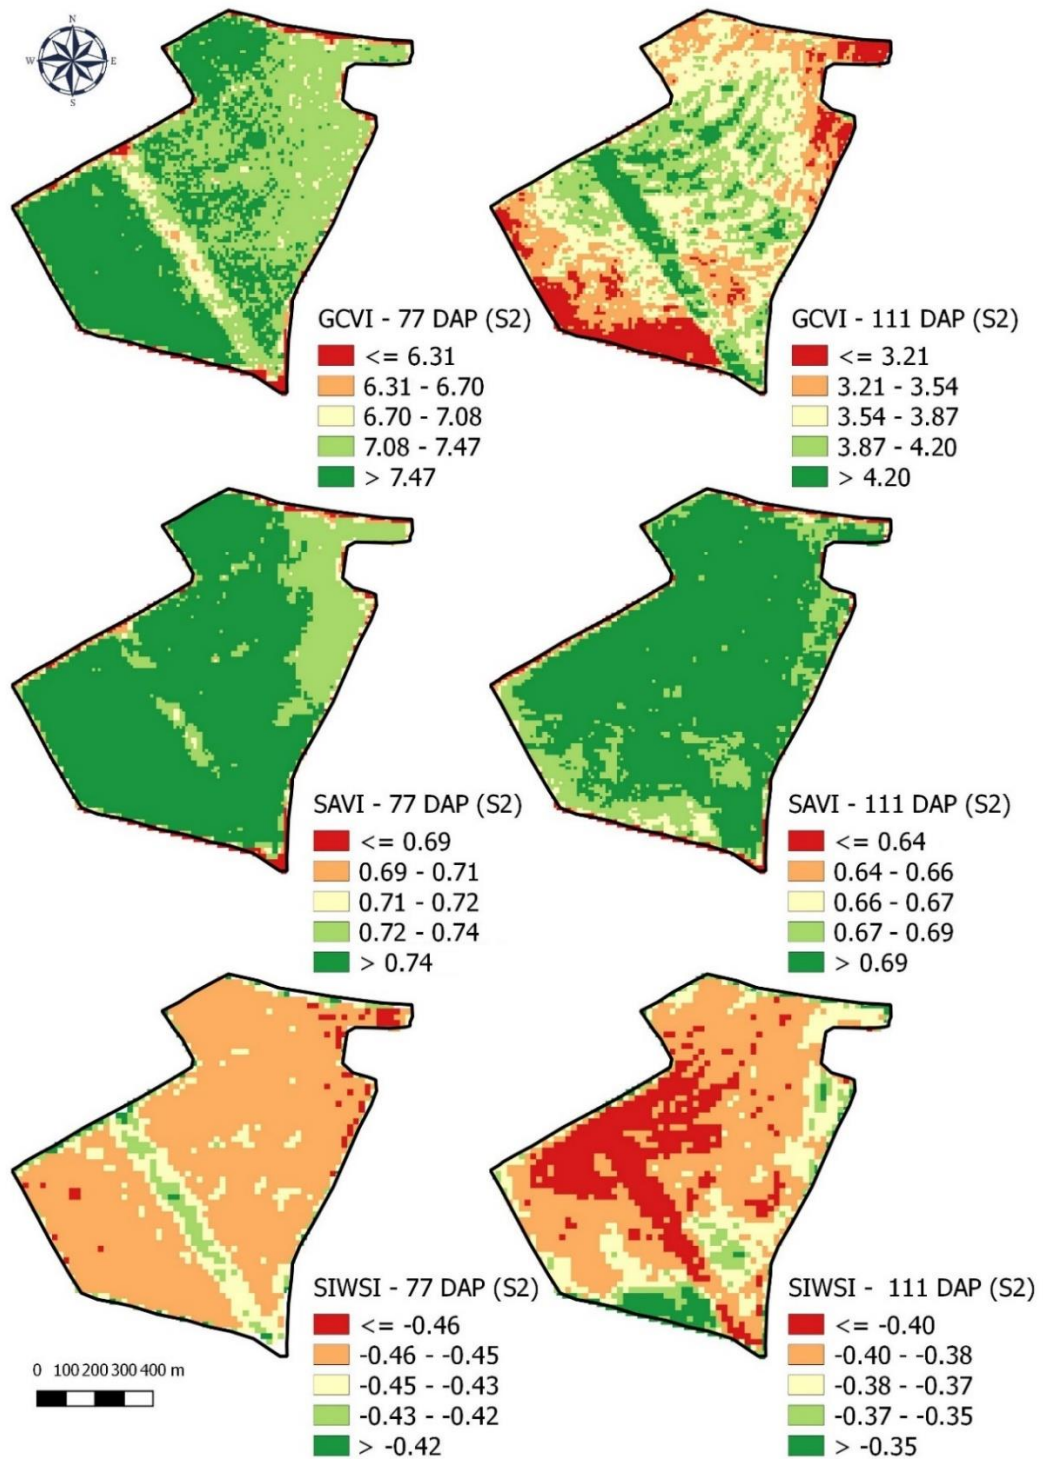


Figura 14: Variabilidade temporal apresentada pelos índices de vegetação GCVI, SAVI e SIWSI a 77 e 111 Dias Após o Plantio (DAP) para a safra 2016/17.

Práticas de manejo podem ser mais bem compreendidas com a utilização de índices de vegetação, além disso, imagens de diferentes datas podem agregar informações para decisões de manejo mais precisas (HATFIELD; PRUEGER, 2010). Cada índice foi obtido em uma data aproximada do meio do ciclo da cultura e também

aproximadamente a 30 dias antes da colheita. Provavelmente a 30 dias antes da colheita as plantas já haviam iniciado o processo de maturação e assim refletindo em menores valores dos índices, evitando problemas de saturação dos índices de vegetação para esta data. Xiao et al. (2014) utilizaram modelagens para estudar a sensibilidade da atividade de reflectância sobre a variação nas variáveis bioquímicas e biofísicas de plantas em diferentes escalas, concluíram que em escala de dossel a variação das reflectâncias na região do visível, NIR e SWIR, são controladas pela clorofila a + b, matéria seca e o teor de água, respectivamente.

O índice global bivariado de Moran foi aplicado para obter o grau de correlação espacial entre os mapas de produtividade e índices de vegetação apresentados nas Figuras 11 a 14. A Tabela 9 apresenta o resultado da significância da estatística de Moran para os índices de vegetação analisados e os mapas de produtividade. Foram utilizados nos agrupamentos os índices de vegetação que resultaram em correlação espacial significativa em pelo menos 90% dos testes de hipóteses, os quais foram aplicados individualmente em cada uma das 30 amostras aleatórias retiradas da grade de amostragem.

Tabela 9: Índice de Moran bivariado para os índices de vegetação obtidos de imagens de satélite de média resolução e mapas de produtividade.

Índice de vegetação	Safrá 2015/16		Safrá 2016/17	
	52 DAP* (L8)	92 DAP (L7)	77 DAP (S2)	111 DAP (S2)
NDVI	NS	NS	NS	NS
MSR	*	NS	NS	NS
EVI2	NS	NS	NS	NS
GCVI	*	NS	NS	NS
SAVI	NS	NS	NS	NS
SIWSI	NS	*	NS	*

*Significante ao nível 0,05 pelo teste de pseudossignificância (999 permutações). NS: Não significativo. DAP: dias após o plantio, L7: Landsat-7, L8: Landsat-8 e S2: Sentinel-2A.

Hatfield e Prueger (2010) encontraram diferenças entre índices de vegetação para variedades de milho e soja durante o ciclo dos cultivos, sendo estas diferenças em função do estágio de crescimento e índice de vegetação utilizado. Os autores recomendaram para cada fase do cultivo um índice diferente. No entanto, os autores alertam que os índices de vegetação podem ser efetivos em certos períodos de crescimento das plantas. Como objetivo deste estudo foi o delineamento de zonas de manejos, buscou-se o índice que foi capaz de detectar a variabilidade da lavoura que está correlacionada com a produtividade. Além disso, uma maior resolução não

beneficiaria necessariamente na obtenção das zonas, uma vez que zonas muito pequenas ou com formato acentuadamente irregular tornaria seu manejo mais difícil.

Já para as datas de meio de ciclo, na primeira safra os índices GCVI e MSR foram significativos para esta data e na segunda safra não houve índices com correlação significativa. Estes índices estão relacionados com mudanças no teor de clorofila nas folhas e com as características biofísicas das plantas, respectivamente. Os diferentes de estágios de desenvolvimento das plantas de cada safra refletem na variabilidade detectada, uma vez que os índices variam em características que são sensíveis. Apesar de as datas de imageamento serem no meio do ciclo de cada safra, sendo as cultivares diferentes, é possível as características agrônômicas diferir.

O índice de vegetação SIWSI apresentou correlação espacial significativa para as duas safras nas datas mais próximas a colheita. O índice utiliza a banda de onda curta de infravermelho (SWIR) e sua absorção mais expressiva ocorre onde a água é presente nas folhas das plantas. Próximo a colheita a senescência da plantas provavelmente tenha iniciado e tenha colaborado para que a correlação do índice fosse significativa. Uma vez que nas áreas onde a produtividade foi menor, é possível que as plantas tenham atingido o fim do ciclo produtivo antes que as plantas localizadas em áreas de maior produtividade, explicando o resultado de significância da Tabela 9 para esse índice.

A correlação espacial entre índices de vegetação de mesma data também foi testada. Os resultados da estatística de Moran para os índices de vegetação de mesma data são apresentados nas Tabelas 10 e 11 para os índices da safra 2015/16 referentes as datas de 52 e 92 dias após o plantio, respectivamente.

Tabela 10: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 52 dias após o plantio (DAP).

Safra 2015/16 - 52 DAP						
	NDVI	MSR	EVI2	GCVI	SIWSI	SAVI
NDVI	-					
MSR	*	-				
EVI2	*	*	-			
GCVI	*	*	*	-		
SIWSI	*	*	*	*	-	
SAVI	*	*	*	*	*	-

*Significante ao nível 0,05 pelo teste de pseudossignificância (999 permutações). NS: Não significativo.

Entre os índices de vegetação da safra 2015/16 referente a data 52 DAP a correlação espacial foi significativa em todas as análises. Apesar de os índices utilizados neste estudo apresentarem sensibilidade a diferentes características das plantas. A variabilidade existente na área de estudos não foi suficiente para resultar em diferenças das respostas dos índices.

Tabela 11: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 92 dias após o plantio (DAP).

Safra 2015/16 - 92 DAP						
	NDVI	MSR	EVI2	GCVI	SIWSI	SAVI
NDVI	-					
MSR	*	-				
EVI2	*	*	-			
GCVI	*	NS	*	-		
SIWSI	*	*	*	*	-	
SAVI	*	*	*	*	*	-

*Significante ao nível 0,05 pelo teste de pseudossignificância (999 permutações). NS: Não significativo.

Para os índices da data 92 DAP foi observado a não existência de correlação significativa entre os índices GCVI e MSR. O índice GCVI é mais resistente a saturação que o NDVI por utilizar a banda verde e é indicado para estimar biomassa. Enquanto o MSR que é utilizado para parâmetros biofísicos das plantas. Em uma data mais próxima a colheita, em que dificilmente os índices atingem valores próximos a saturação, é possível que a variabilidade presente na lavoura seja mais facilmente detectada. Diferentemente do que ocorreu na data de meio do ciclo, onde os valores dos índices foram próximos ao valor máximo e a lavoura apresentou uniformidade. Nas Tabelas 12 e 13 são apresentados os resultados dos testes de correlação espacial para os índices da safra 2016/17 nas datas 77 e 111 dias após o plantio, respectivamente.

Tabela 12: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 77 dias após o plantio (DAP).

Safrá 2016/17 - 77 DAP						
	NDVI	MSR	EVI2	GCVI	SIWSI	SAVI
NDVI	-					
MSR	*	-				
EVI2	*	*	-			
GCVI	*	*	*	-		
SIWSI	*	*	NS	NS	-	
SAVI	*	*	*	*	NS	-

*Significante ao nível 0,05 pelo teste de pseudossignificância (999 permutações). NS: Não significativo.

Os resultados da correlação espacial entre os índices de vegetação para a data 77 DAP, apenas a correlação entre SIWSI e os índices EVI2, GCVI e SAVI não foi significativa. Entre as diferenças destes índices pode-se destacar que o SIWSI é sensível ao conteúdo de água presente nas folhas, enquanto os índices EVI2, GCVI e SAVI são mais sensíveis a biomassa. Sendo regime de chuvas observado para esta safra foi muito menor quando comparado com a safra anterior (Figura 2), o índice SIWSI apresentou menores valores para toda a área, enquanto os outros índices que não foram significativos detectaram variabilidade no talhão de estudo. Já para a data 111 DAP todas as correlações foram significativas.

Tabela 13: Índice de Moran bivariado para os índices de vegetação obtidos de imagens orbitais de média resolução para a data de 111 dias após o plantio (DAP).

Safrá 2016/17 - 111 DAP						
	NDVI	MSR	EVI2	GCVI	SIWSI	SAVI
NDVI	-					
MSR	*	-				
EVI2	*	*	-			
GCVI	*	*	*	-		
SIWSI	*	*	*	*	-	
SAVI	*	*	*	*	*	-

*Significante ao nível 0,05 pelo teste de pseudossignificância (999 permutações). NS: Não significativo.

A grande maioria dos testes de correlação espacial entre os índices de vegetação foram significativas. Os índices de vegetação utilizados neste estudo foram obtidos da combinação linear ou proporções de bandas espectrais de vermelho e infravermelho

próximo, com exceção dos índices GCVI e SIWSI que utilizam as bandas verdes e infravermelho de onda curta, respectivamente. Apesar de os índices variarem em características de alvo a que evidenciam, a uniformidade observada na lavoura pode ter influenciado de maneira geral nos resultados da correlação entre índices de mesma data. No entanto, índices que são mais resistentes a saturação apresentaram maior capacidade de detectar a variabilidade para as datas de meio do ciclo em ambas as safras. Nas datas próximas a colheita, todos os índices foram capazes de detectar maior variabilidade da lavoura, mesmo que esta variabilidade não esteja correlacionada significativamente com a produtividade. Isto demonstra a importância de entender a qual característica é sensível ao índice utilizado.

3.3. Delimitação das zonas de manejo utilizando mapas de produtividade e índices de vegetação

Após a análise da correlação espacial entre índices de vegetação e mapas de produtividade, foram selecionados os índices com correlações significativas (significante ao pseudo p-valor = 0,05) em cada data analisada de cada safra para realizar a delimitação de zonas de manejo. Os índices MSR e GCVI obtidos a 52 dias após o plantio na safra 2015/16 apresentaram correlação significativa com a produtividade. Já para a data de 92 dias após o plantio apenas o índice SIWSI apresentou correlação significativa com a produtividade. Em relação à safra 2016/17, os índices de vegetação que foram obtidos a 77 dias após o plantio nenhum índice apresentou correlação significativa. E para a data de 111 dias após o plantio o índice SIWSI apresentou correlação significativa com a produtividade.

Nas Figuras 15 e 16 são apresentados os mapas temáticos das classes de manejo derivados de análise de agrupamentos fuzzy k-means utilizando o programa de computador FuzME. Foram delimitadas as classes de manejo utilizando somente os mapas de produtividade de cada safra separadamente e delimitadas classes de manejo utilizando os mapas de índices que apresentaram correlação espacial significativa em cada data e para ambas as datas analisadas de cada safra também.

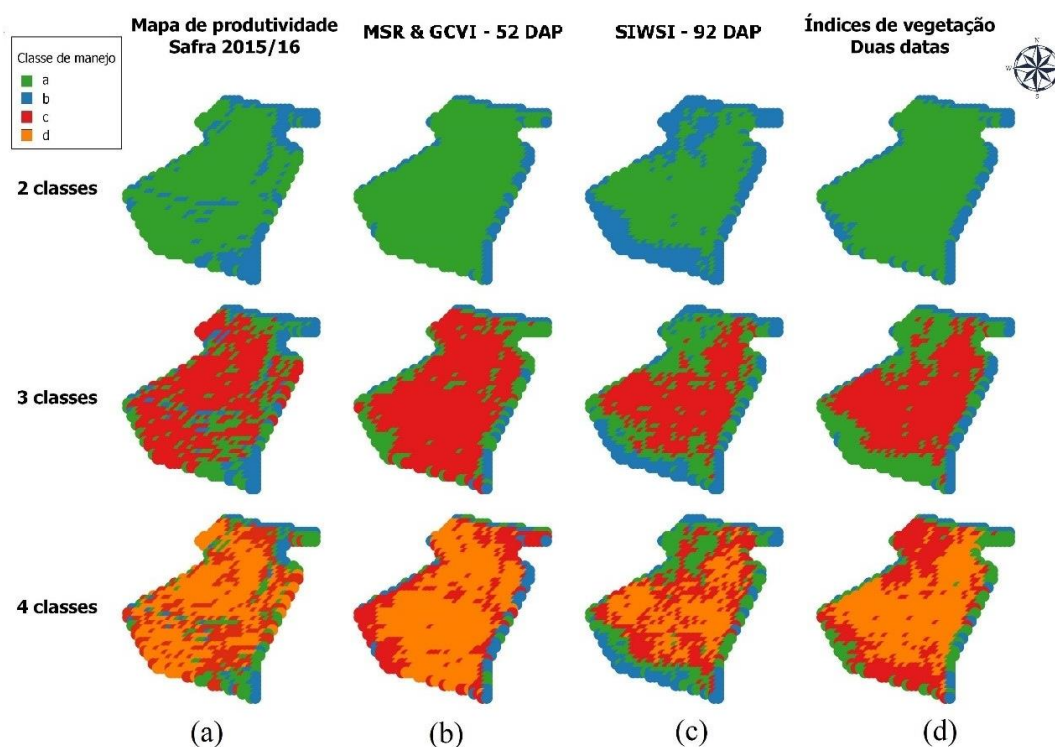


Figura 15: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2015/16, (b) utilizando os índices de vegetação com correlação espacial significativa referente a 52 DAP, (c) utilizando os índices de vegetação com correlação espacial significativa referente a 92 DAP, e (d) utilizando os índices de vegetação com correlação espacial significativa das duas datas analisadas.

Realizando-se uma análise visual da Figura 15 pode-se verificar que não há grandes diferenças entre os mapas de classes de com índices de vegetação em relação aos agrupamentos realizados apenas com a produtividade. A avaliação da similaridade das classes de manejo delineadas foi realizada utilizando o teste de concordância Kappa (COHEN, 1960). O resultado do índice Kappa para as classes de manejo delineadas para a safra 2015/16 são apresentados na Tabela 14.

Tabela 14: Índice Kappa entre as classes delineadas utilizando índices de vegetação de duas datas para a safra 2015/16 e as classes delineadas a partir do mapa de produtividade.

	Índices de vegetação (52 DAP)	Índices de vegetação (92 DAP)	Índices de vegetação (Duas datas)
2 classes	60,6 %	21,3 %	67,3 %
3 classes	60,8 %	47,5 %	35,5 %
4 classes	9,5 %	8,2 %	11,9 %

Na análise da safra 2015/16, observa-se que os índices de Kappa obtidos para a data de 52 dias após o plantio foram capazes de gerar classes de manejos com maior concordância que os obtidos para a data de 92 dias após o plantio (Tabela 14). Ao utilizar os índices obtidos nas duas datas analisadas, observa-se maiores valores do índice Kappa que os obtidos utilizando apenas índices de uma data, para o delineamento de duas e quatro classes.

Na Figura 16 são apresentadas as classes de manejo delineadas utilizando índices de vegetação em duas datas para a safra 2016/17. Aos 77 dias após o plantio nenhum dos índices analisados apresentou correlação significativa.

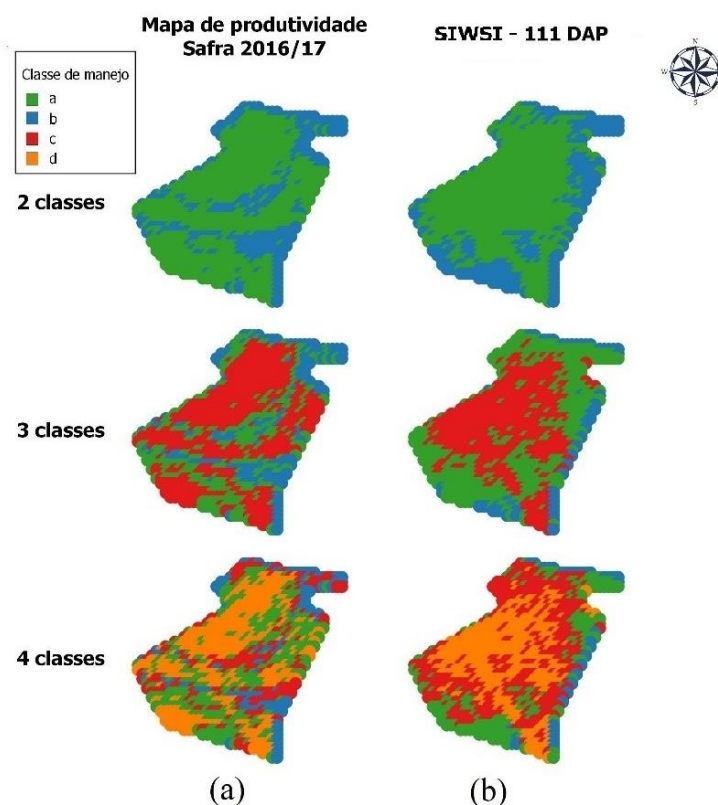


Figure 16: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2016/17, (b) utilizando os índices de vegetação com correlação espacial significativa referente a 111 DAP.

Na Tabela 15 são apresentados os valores do índice Kappa para as classes apresentadas na Figura 16. As classes foram delineadas utilizando o índice SIWSI, que foi o único índice que apresentou correlação espacial significativa com a produtividade.

Tabela 15: Índice Kappa entre as classes delineadas utilizando índices de vegetação de duas datas para a safra 2016/17 e as classes delineadas a partir do mapa de produtividade.

	Índices de vegetação (111 DAP)
2 classes	18,6 %
3 classes	57,9 %
4 classes	15,3 %

As classes de manejo delineadas utilizando os índices obtidos na data 111 dias após o plantio apresentaram maiores valores de índice Kappa que no mesmo período da primeira safra analisada, com exceção do delineamento de duas classes (Tabela 14). Nota-se que os menores valores de Kappa são observados para o delineamento de 4 classes, para todas as datas analisadas. Uma das classes está localizada nas bordas do talhão.

A utilização de índices de vegetação gerou zonas de manejo mais contíguas, em relação as zonas delineadas apenas com os mapas de produtividade. Ortega-Blu e Molina-Roco (2016) para delimitarem zonas de manejo em um vinhedo no Chile utilizaram o índice GVI calibrado obtido por satélite (Quickbird), NDVI não calibrado proveniente de imagens aéreas e condutividade elétrica aparente (CEa) do solo para delimitar as zonas de manejo. O uso do índice GVI permitiu obter zonas de manejo e fazer comparações espaço-temporal entre as áreas e as estações, portanto foi recomendado como ferramenta para delimitação de zonas de manejo. Os autores ainda concluíram que em solos com baixa variabilidade, o uso unicamente da CEa não foi suficiente para estabelecer zonas de manejo. Já o NDVI, em área homogêneas, não foi capaz de estimar padrões de vigor e qualidade dos frutos.

O índice de vegetação NDVI é amplamente utilizado em consultorias agronômicas e em pesquisas de avaliação de vegetação por imagens orbitais. Entretanto, é conhecido que o índice apresenta limitações referente a saturação em vegetações com elevados valores de área foliar. Valores moderados e altos de índice de área foliar verde refletem na saturação do NDVI, pois a reflectância na região vermelha é insensibilidade devido ao alto coeficiente de absorção de clorofila (NGUY-ROBERTSON et al., 2012). Dessa forma, foi avaliado se a utilização apenas de mapa

de NDVI poderia ser utilizado para representar as classes de produtividade. Esses resultados são apresentados nas Figuras 17 e 18.

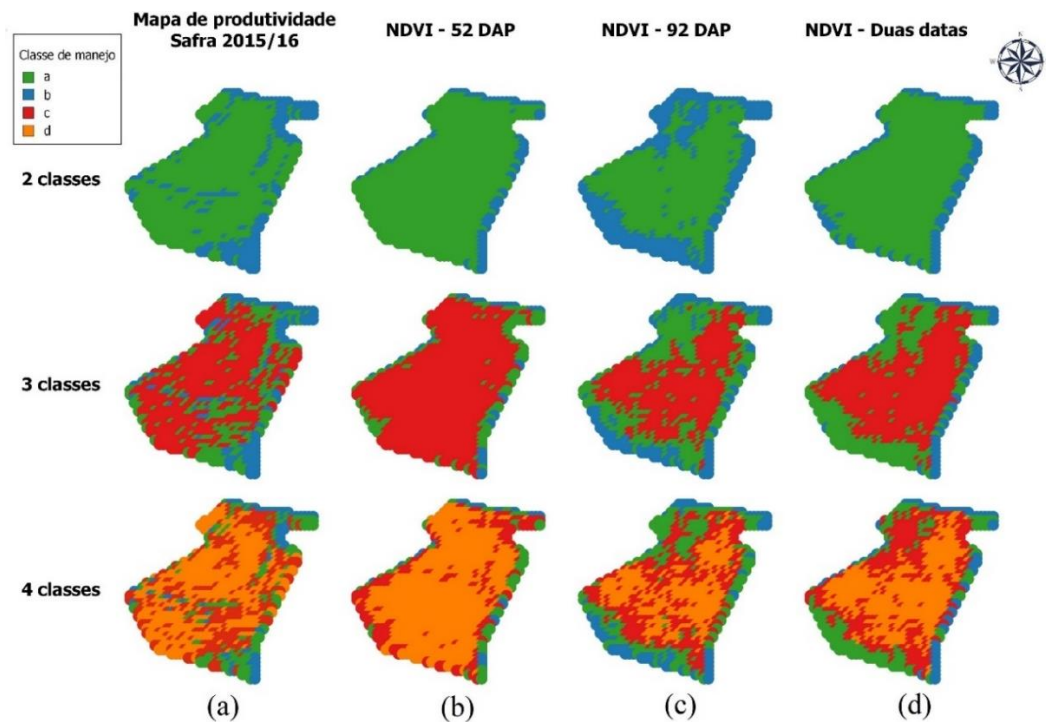


Figure 17: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2015/16, (b) utilizando o índice de vegetação NDVI referente a data 52 DAP, (c) utilizando o índice de vegetação NDVI referente a data 92 DAP, e (d) utilizando o NDVI de ambas as datas.

Os mapas temáticos gerados com o NDVI referente a data 52 DAP (Figura 17b) apresentou classes de manejo mais contíguas que os outros mapas, as duas classes estão apresentaram-se bem definidas, uma localizada nas bordas da área e outra para o interior da área. Mas ao delinear em 4 classes é possível perceber que as classes tornam-se menores e não contíguas. Apesar de o índice não ter atingido o valor máximo que é 1, apresentou valores muito próximos a este valor para esta data (Figura 10). As classes delineadas na data de 52 DAP, tendem a estarem localizadas nas bordas, com apenas uma classe ocupando quase todo o talhão. Isto pode indicar que o índice não foi capaz de detectar variabilidade ao longo do talhão, apenas nas bordas. Enquanto os valores do índice para a data 92 DAP foram inferiores, possivelmente indicando que as plantas de soja estavam iniciando o estágio de maturação. A Tabela 16 apresenta os valores do índice Kappa para os mapas temáticos da Figura 17.

Tabela 16: Índice Kappa entre as classes delineadas utilizando NDVI de duas datas para a safra 2015/16 e as classes delineadas a partir do mapa de produtividade.

	NDVI (52 DAP)	NDVI (92 DAP)	NDVI (Duas datas)
2 classes	29,9%	19,4%	29,7%
3 classes	61,2%	47,1%	42,8%
4 classes	13,7%	6,4%	7,4%

Os maiores valores de índice Kappa observados na Tabela 16 foram para o delineamento de três classes e os menores valores para delimitação de quatro classes. Ao delinear quatro classes de manejo no talhão, percebe-se que algumas classes deixam de ser contíguas ou se tornam muito pequenas o que dificultaria os seus manejos. Na Figura 18 são apresentados os mapas temáticos de classes de manejo delimitadas utilizando o NDVI referentes as datas analisadas na safra 2016/17.

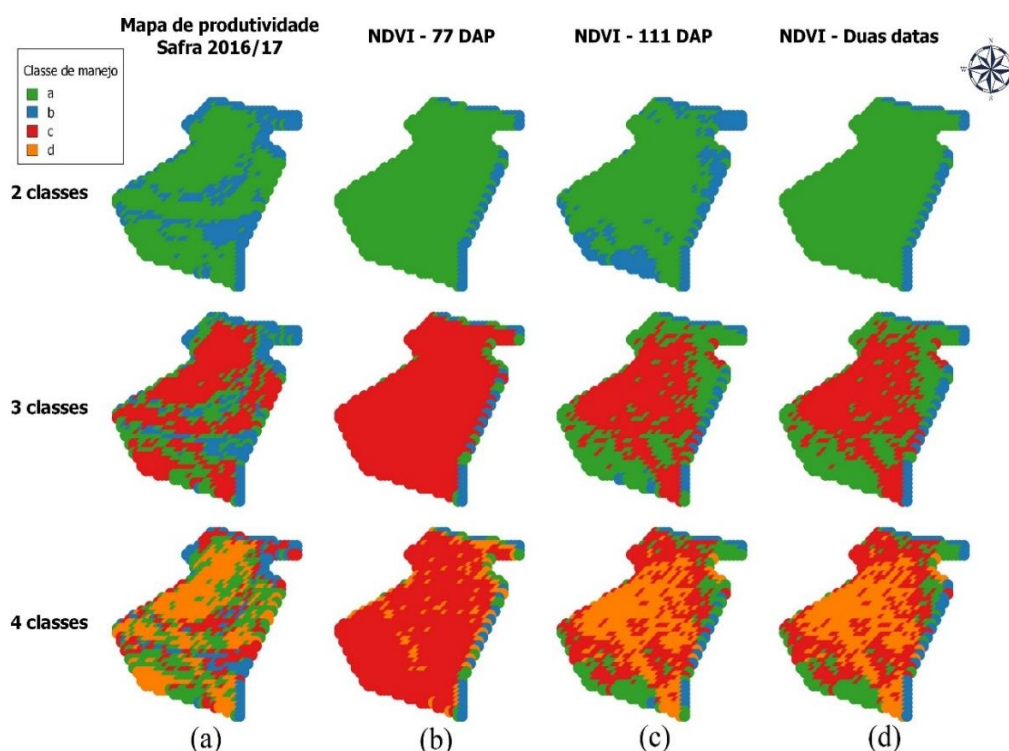


Figure 18: Mapas temáticos com duas, três e quatro classes utilizando (a) o mapa de produtividade da safra 2016/17, (b) utilizando o índice de vegetação NDVI referente a data 77 DAP, (c) utilizando o índice de vegetação NDVI referente a data 111 DAP, e (d) utilizando o NDVI de ambas as datas.

Na Figura 18b se percebe que uma das classes ficou localizada principalmente nas bordas da área, comportamento similar ao da Figura 18b. De maneira similar aos

resultados da safra anterior, o NDVI apresentou elevados valores para a data referente ao meio do ciclo (Figura 11). Isso reforça a tendência deste índice em saturar devido altos valores de área foliar. As classes de manejo delineadas utilizando o NDVI referente a data de 111 DAP (Figura 18c) e a combinação dos índices das duas datas são visualmente muito semelhantes. Sendo possível que o NDVI referente a data 77 DAP não tenha acrescentado informações à análise. Os resultados do índice Kappa para os mapas temáticos da Figura 18 são apresentados na Tabela 17.

Tabela 17: Índice Kappa para as classes delineadas utilizando NDVI de duas datas para a safra 2016/17 e o mapa de produtividade obtido.

	NDVI (77 DAP)	NDVI (111 DAP)	NDVI (Duas datas)
2 classes	14,6%	16,6%	14,6%
3 classes	46,8%	56,2%	47,1%
4 classes	3,3%	16,5%	8,1%

Os valores do índice Kappa apresentados na Tabela 17 demonstram que o delineamento de 3 classes apresentou os maiores valores e o índice obtido na data 111 DAP apresentou o maior valor para as análises realizadas nesta safra. Estes resultados demonstram que o NDVI obtido na data mais próxima a colheita gerou classes de manejo com maior concordância com as classes delineadas apenas com o mapa de produtividade. Sugerindo uma melhor performance do índice nesta data, provavelmente devido menor interferência causadas pela saturação do índice. Na Figura 19 são apresentados os mapas temáticos de classes de manejo delimitadas utilizando mapas de produtividade, índices de vegetação que apresentaram correlação significativa com a produtividade e utilizando o NDVI.

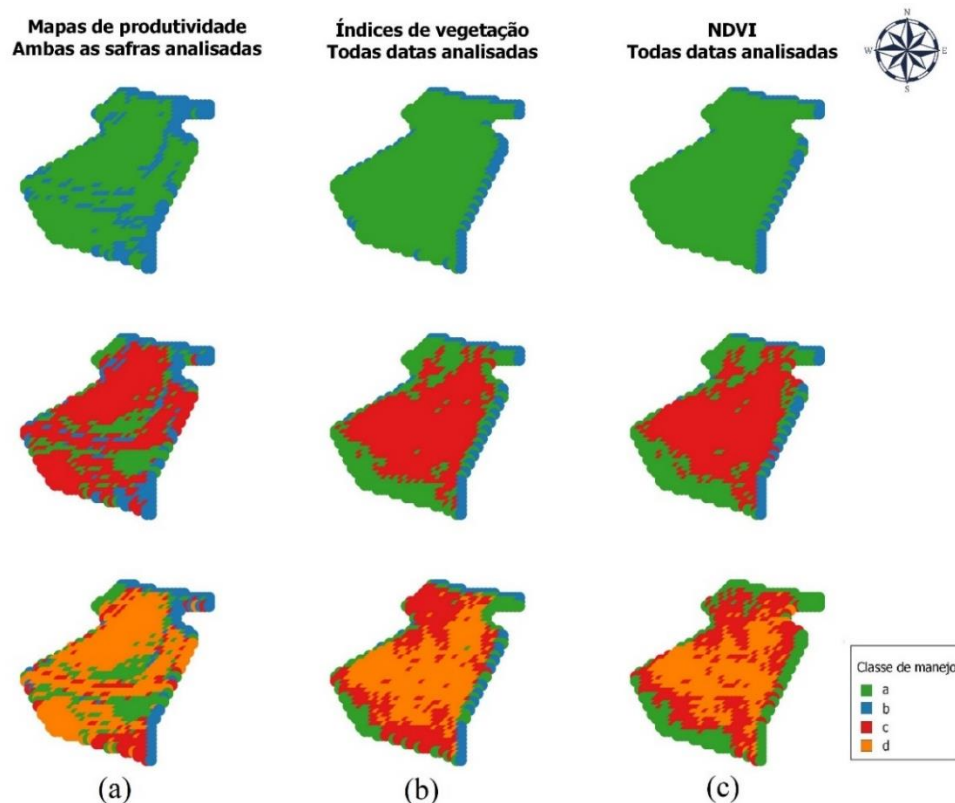


Figure 19: Mapas temáticos com duas, três e quatro classes utilizando (a) os mapas de produtividade, (b) utilizando os índices de vegetação com correlação espacial significativa e (c) utilizando o índice NDVI das datas analisadas.

Na Figura 19 observa-se que as classes de manejo delineadas com os dados de produtividade e os índices de vegetação obtidos em todas as quatro datas avaliadas. É possível verificar que as zonas delineadas com os índices de vegetação apresentaram maior continuidade. Além disso, é possível observar semelhanças entre as zonas delineadas com vários índices de vegetação e utilizando apenas o NDVI.

Tabela 18: Resultados da análise de concordância para as classes delineadas utilizando índices de vegetação de duas datas para as duas safras analisadas e utilizando o NDVI referente as datas analisadas em ambas as safras.

Classes de manejo	Índices de vegetação	NDVI
2 classes	23,8 %	8,5%
3 classes	54,4 %	53,7%
4 classes	10,5 %	20,3%

Na Tabela 18 são apresentados os valores do índice Kappa para as classes da Figura 16. Os valores do índice Kappa são similares aos apresentados separadamente para

cada safra analisada. A utilização de séries de dados tende a estabelecer zonas de manejo que são consistentes ao longo do tempo e podem ser gerenciadas diferentemente. A vantagem de utilizar imagens de satélites é que elas podem ser obtidas antes da colheita e sem a dificuldade que os produtores têm encontrado com a utilização dos monitores de produtividade.

Peralta et al. (2016) investigaram o potencial de imagens de alta resolução obtidas durante o meio do ciclo para identificar a variabilidade e prever a produtividade de milho em diferentes locais. Os autores geraram mapas de produtividade que podem auxiliar a implementar ferramentas de manejo local e também podem ser utilizados como representantes dos dados do monitor de produtividade. No presente estudo as imagens orbitais de média resolução foram capazes de inferir a variabilidade em um talhão cultivado com soja, com um grau de concordância que chegou a atingir 67% em relação as zonas de manejo delineadas apenas com mapas de produtividade. Embora o intuito de utilizar imagens índices de vegetação de diferentes datas durante o ciclo do cultivo seja de agregar informações complementares para o delineamento de classes de manejo, alguns índices apresentaram valores próximos ao máximo, indicando tendência de saturação.

Hatfield e Prueger (2010) observaram que os índices de vegetação tendem a apresentar o mesmo comporta ao longo dos anos, e assim puderam recomendar diferentes índices de vegetação para estágios de crescimento das plantas. Os autores analisaram ao longo de um período de oito anos a resposta de índices de vegetação. Neste estudo o objetivo é detectar a variabilidade que está correlacionada espacialmente com a produtividade e assim, utilizar esta informação para delinear zonas de manejo. Os índices de vegetação MSR e GCVI obtidos no meio do ciclo da cultura foram significativos apenas em uma safra. Já os índices obtidos próximos a colheita, apenas o SIWSI apresentou correlação significativa para as duas safras analisadas. Estes índices estão relacionados com parâmetros biofísicos das plantas, variação de concentração de clorofila nas folhas e conteúdo de água nas folhas, respectivamente. Este estudo demonstrou que o grau de concordância com a variabilidade captada pelos mapas de produtividade variou de 5% a 67% dependendo do número de zonas delineadas. Os maiores valores de kappa foram observados quando a área foi delimitada em até três zonas. Os índices de vegetação estudados foram capazes de inferir as diferenças na variabilidade da soja, e assim podem ser utilizados para delinear zonas de manejo.

4. CONCLUSÕES

Para as imagens orbitais, a utilização de diferentes plataformas permitiu evitar algumas limitações de imagens de satélite como presença de nuvens e tempo de revisita. A utilização de índices de vegetação com maiores correlações espacial com a produtividade permitiu agregar informações para delimitação de zonas de manejo.

Os índices de vegetação obtidos no meio do ciclo da cultura foram significativos em apenas uma das safras analisadas. Sendo que alguns índices apresentaram valores muito próximos ao máximo, indicando tendência a saturar. Já os índices obtidos próximos a colheita, apenas o SIWSI apresentou correlação significativa para as duas safras analisadas.

Os índices de vegetação estudados foram capazes de detectar a variabilidade do cultivo que está correlacionado com a produtividade da soja, e assim puderam ser utilizados para delimitar zonas de manejo. A utilização de índices gerados em duas datas tendeu a apresentar valores do índice Kappa similares aos maiores valores observados em uma data individualmente. Este estudo demonstrou que o grau de concordância com a variabilidade captada pelos mapas de produtividade variou de 5% a 67% dependendo do número de zonas delimitadas.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ANSELIN, L. Local Indicators of Spatial Association—LISA. **Geographical Analysis**, v. 27, n. 2, p. 93–115, 1995.

ANSELIN, L.; SYABRI, I.; KHO, Y. An Introduction to Spatial Data Analysis. **Geographical Analysis**, v. 38, n. 1, p. 5–22, 2006.

BAZZI, C. L. et al. Management Zones Definition Using Soil Chemical and Physical Attributes in a Soybean Area. **Engenharia Agrícola**, v. 33, n. 5, p. 952–964, 2013.

BIVAND, R. et al. **spdep package - Spatial Dependence: Weighting Schemes, Statistics and Models**, 2017. Disponível em: <<https://cran.r-project.org/web/packages/spdep/spdep.pdf>>

BOLTON, D. K.; FRIEDL, M. A. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. **Agricultural and Forest Meteorology**, v. 173, p. 74–84, 2013.

CÂMARA, G. et al. Capítulo 5 - Análise de Dados de Área. In: DRUCK, S. . C.; M.S.; CÂMARA, G. .; MONTEIRO, A. V. M. (EDS) (Eds.). . **Análise Espacial de Dados Geográficos**. Brasília: EMBRAPA, 2004. v. 0p. 44.

CHEN, J. M. Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229–242, 1996.

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

CONAB: COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da Safra Brasileira de Grãos Monitoramento agrícola- Safra 2016/2017**. [s.l: s.n.]. Disponível em: <<http://www.conab.gov.br>>.

CÓRDOBA, M. A. et al. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems Engineering**, v. 143, p. 95–107, 2016.

EMBRAPA SOJA. **Tecnologias de Produção de Soja - Região Central do Brasil Sistemas de Produção**. Londrina - PR: [s.n.]. Disponível em: <http://www.cnpso.embrapa.br/download/publicacao/central_2005.pdf>.

ESA. **SENTINEL-2 User Handbook**. Disponível em: <https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook>.

FENSHOLT, R.; SANDHOLT, I. Derivation of a shortwave infrared water stress index from MODIS near- and shortwave infrared data in a semiarid environment. **Remote Sensing of Environment**, v. 87, n. 1, p. 111–121, 2003.

GAVIOLI, A. et al. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, v. 127, p. 302–

310, 2016.

GITELSON, A. A. et al. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, p. 4–7, 2003.

HABOUDANE, D. et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, n. 3, p. 337–352, 2004.

HATFIELD, J. L.; PRUEGER, J. H. Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. **Remote Sensing**, v. 2, n. 2, p. 562–578, 2010.

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

JIANG, Z. et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 2008.

LEE, K. et al. **Software for Grain Yield Monitoring System Suitable to Korean Full-feed Combines User Console**. 2016 ASABE Annual International Meeting. **Anais...**St. Joseph, Mich.: ASABE - American Society of Agricultural and Biological Engineers, 2016.

LI, P.; JIANG, L.; FENG, Z. Cross-comparison of vegetation indices derived from landsat-7 enhanced thematic mapper plus (ETM+) and landsat-8 operational land imager (OLI) sensors. **Remote Sensing**, v. 6, n. 1, p. 310–329, 2014.

LIN, M.; LUCAS, H. C.; SHMUELI, G. Too big to fail: Large samples and the p-value problem. **Information Systems Research**, v. 24, n. 4, p. 906–917, 2013.

LYLE, G.; BRYAN, B. A.; OSTENDORF, B. Post-processing methods to eliminate erroneous grain yield measurements: Review and directions for future development. **Precision Agriculture**, v. 15, n. 4, p. 377–402, 2014.

MINASNY, B., MCBRATNEY, A.B., 2002. FuzME version 3.0, **Australian Centre for Precision Agriculture**, The University of Sydney, Australia. 2002.

MINASNY, B.; MCBRATNEY, A.B.; WHELAN, B.M., 2005. VESPER version 1.62. **Australian Centre for Precision Agriculture**, McMillan Building A05, The University of Sydney, NSW. 2006.

MOLIN, J. P.; AMARAL, L. R. DO; COLAÇO, A. F. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de Textos, 2015.

MOLIN, J. P.; DE CASTRO, C. N. Establishing Management Zones Using Soil Electrical Conductivity And Other Soil Properties By The Fuzzy Clustering Technique. **Scientia Agricola**, v. 65, n. 6, p. 567–573, dez. 2008.

- MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, 2013.
- NGUY-ROBERTSON, A. et al. Green leaf area index estimation in maize and soybean: Combining vegetation indices to achieve maximal sensitivity. **Agronomy Journal**, v. 104, n. 5, p. 1336–1347, 2012.
- OLIVEIRA, R. P. DE; GREGO, C. R.; BRANDÃO, Z. N. **Geoestatística Aplicada Na Agricultura De Precisão Utilizando O Vesper**. Brasília, DF: Embrapa, 2015.
- ORTEGA-BLU, R.; MOLINA-ROCO, M. Evaluation of vegetation indices and apparent soil electrical conductivity for site-specific vineyard management in Chile. **Precision Agriculture**, v. 17, n. 4, p. 434–450, 2016.
- PEDROSO, M. et al. A segmentation algorithm for the delineation of agricultural management zones. **Computers and Electronics in Agriculture**, v. 70, n. 1, p. 199–208, 2010.
- PENG, Y.; GITELSON, A. A. Application of chlorophyll-related vegetation indices for remote estimation of maize productivity. **Agricultural and Forest Meteorology**, v. 151, n. 9, p. 1267–1276, 2011.
- PERALTA, N. et al. Mid-Season High-Resolution Satellite Imagery for Forecasting Site-Specific Corn Yield. **Remote Sensing**, v. 8, n. 10, p. 848, 2016.
- PING, J. L.; DOBERMANN, A. Processing of yield map data. **Precision Agriculture**, v. 6, n. 2, p. 193–212, 2005.
- R Core Team. R: A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria, 2015; Disponível em: <https://www.R-project.org/>
- ROSS, K. W.; MORRIS, D. K.; JOHANNSEN, C. J. A review of intra-field yield estimation from yield monitor data. **Applied Engineering in Agriculture**, v. 24, n. 3, p. 309–317, 2008.
- SENTELHAS, P. C. et al. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **The Journal of Agricultural Science**, v. 153, n. 8, p. 1394–1411, 2015.
- SKAKUN, S. et al. Combined Use of Landsat-8 and Sentinel-2A Images for Winter Crop Mapping and Winter Wheat Yield Assessment at Regional Scale. **AIMS Geosciences**, v. 3, n. 2, p. 163–186, 2017.
- SUDDUTH, K. A.; DRUMMOND, S. T. Yield editor: Software for removing errors from crop yield maps. **Agronomy Journal**, v. 99, n. 6, p. 1471–1482, 2007.
- SUDDUTH, K. A.; DRUMMOND, S. T.; MYERS, D. B. **Yield Editor 2.0: Software for Automated Removal of Yield Map Errors**. 2012 ASABE Annual International Meeting. **Anais...**St. Joseph, Mich.: ASABE - American Society of

Agricultural and Biological Engineers, 2012.

SUN, W. et al. An integrated framework for software to provide yield data cleaning and estimation of an opportunity index for site-specific crop management. **Precision Agriculture**, v. 14, n. 4, p. 376–391, 2013.

TAYLOR, J. A.; MCBRATNEY, A. B.; WHELAN, B. M. Establishing management classes for broadacre agricultural production. **Agronomy Journal**, v. 99, n. 5, p. 1366–1376, 2007.

TEAM, Q. D. **QGIS geographic information system. Open source geospatial foundation project**Online, online, 2016.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

USGS. **Product guide - Landsat 8 Surface Reflectance Code (LaSRC)** Disponível em:
<https://landsat.usgs.gov/sites/default/files/documents/lasrc_product_guide.pdf>.

VALENTE, D. S. M. et al. Definition of management zones in coffee production fields based on apparent soil electrical conductivity. **Scientia Agricola**, v. 69, n. 3, p. 173–179, 2012.

VALENTE, D. S. M. et al. Spatial variability of apparent electrical conductivity and soil properties in a coffee production field. **Engenharia Agrícola**, v. 34, n. 6, p. 1224–1233, 2014.

ZOU, X.; MÖTTUS, M. Sensitivity of Common Vegetation Indices to the Canopy Structure of Field Crops. **Remote Sensing**, v. 9, n. 10, p. 994, 2017.