

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**DEFINIÇÃO DE ZONAS DE MANEJO UTILIZANDO ANÁLISES
MULTIVARIADAS**

**Jean Lucas Pereira Oliveira
Engenheiro Agrônomo**

2023

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**DEFINIÇÃO DE ZONAS DE MANEJO UTILIZANDO ANÁLISES
MULTIVARIADAS**

Jean Lucas Pereira Oliveira

Orientador: Prof. Dr. Carlos Eduardo Angeli Furlani

Coorientadores: Prof. Dr. Adão Felipe dos Santos

Prof. Dr. Afonso Lopes

Dra. Brenda Valeska Ortiz

Dra. Franciele Morlin Carneiro

Prof. Dr. José Eduardo Pitelli Turco

Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Doutor em Agronomia (Produção Vegetal).

2023

O48d

Oliveira, Jean Lucas Pereira

Definição de Zonas de Manejo utilizando análises multivariadas / Jean Lucas Pereira Oliveira. -- Jaboticabal, 2024

59 p. : il., tabs., mapas

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Carlos Eduardo Angeli Furlani

Coorientador: José Eduardo Pitelli Turco

1. Zonas de manejo para cana-de-açúcar. 2. Agricultura de precisão. 3. Análise de componentes principais. 4. Irrigação de precisão. 5. Análise espaço-temporal. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.


CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: DEFINIÇÃO DE ZONAS DE MANEJO UTILIZANDO ANÁLISES MULTIVARIADAS


AUTOR: JEAN LUCAS PEREIRA OLIVEIRA
ORIENTADOR: CARLOS EDUARDO ANGELI FURLANI
COORIENTADORA: FRANCIELE MORLIN CARNEIRO
COORIENTADOR: ADÃO FELIPE DOS SANTOS
COORIENTADOR: JOSÉ EDUARDO PITELLI TURCO
COORIENTADOR: AFONSO LOPES
COORIENTADORA: BRENDA VALESKA ORTIZ

Aprovado como parte das exigências para obtenção do Título de Doutor em Agronomia (Produção Vegetal), pela Comissão Examinadora:


Prof. Dr. CARLOS EDUARDO ANGELI FURLANI (Participação Presencial)
Departamento de Engenharia e Ciências Exatas / FCAV UNESP Jaboticabal


Documento assinado digitalmente
gov.br CARLOS EDUARDO ANGELI FURLANI
Data: 20/11/2023 21:02:38 -0300
Verifique em <https://verifica.br.gov.br>

Prof. Dr. RAFAEL HENRIQUE DE FREITAS NORONHA (Participação Virtual)
Universidade Federal do Sul da Bahia (UFSB) / Itabuna/BA


Documento assinado digitalmente
gov.br RAFAEL HENRIQUE DE FREITAS NORONHA
Data: 18/11/2023 16:04:16 -0300
Verifique em <https://verifica.br.gov.br>

Profa. Dra. ELIVÂNIA MARIA SOUSA NASCIMENTO (Participação Presencial)
Departamento de Ciências Agrárias e Naturais / Universidade do Estado de Minas Gerais (UEMG) - Itulutaba/MG


Documento assinado digitalmente
gov.br ELIVANIA MARIA SOUSA NASCIMENTO
Data: 20/11/2023 23:55:42 -0300
Verifique em <https://verifica.br.gov.br>

Profa. Dra. TERESA CRISTINA TARLE PISSARRA (Participação Presencial)
Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal

Profa. Dra. TATIANA FERNANDA CANATA (Participação Presencial)
Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal



Jaboticabal, 17 de novembro de 2023

DADOS CURRICULARES DO AUTOR

JEAN LUCAS PEREIRA OLIVEIRA – nascido em Fortaleza, Ceará, no dia 07 de dezembro de 1994. Ingressou no curso de Agronomia na Universidade Federal do Ceará (UFC) em outubro de 2012 e, durante a graduação, participou de projetos de pesquisa e atuou como bolsista de Iniciação Científica do CNPq (Conselho Nacional de Desenvolvimento à Pesquisa) por, aproximadamente, cinco anos. Atuou, por quatro anos, como diretor de Recursos Humanos e Vice-Presidente na Agrônômica – Consultoria e Projetos Agropecuários, Empresa Júnior do curso de Agronomia da UFC, atuando para produtores rurais e urbanos. Recebeu título de Engenheiro Agrônomo em julho de 2018. Neste mesmo ano, iniciou curso de mestrado no Programa de Pós – Graduação em Agronomia (Produção Vegetal) da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Jaboticabal em agosto de 2018, sendo novamente bolsista do CNPq, no Laboratório de Máquinas e Mecanização Agrícola (LAMMA). Finalizou mestrado em fevereiro de 2020 e, em março deste mesmo ano, ingressou no curso de doutorado em Agronomia no mesmo programa de Pós-graduação, trabalhando com Mecanização e Agricultura de Precisão para cana-de-açúcar. Ministrou aulas no Instituto Municipal de Ensino Superior de Bebedouro – IMESB. Realizou intercâmbio profissional na Auburn University, estado do Alabama, Estados Unidos da América, onde trabalhou com Agricultura de Precisão e manejo inteligente de irrigação. No Laboratório LAMMA, cumpriu as obrigações a que lhe foram atribuídas, dentre elas, o cumprimento de créditos, estágio docência em Máquinas Agrícolas, Mecânica e Máquinas Agrícolas eventos e outras funções. Atualmente, é Especialista de Desenvolvimento Agrônômico no setor sucroenergético. Em novembro de 2023, submeteu-se à defesa da tese para obtenção do título de Doutor em Agronomia, Produção Vegetal.

À minha família, aos meus amigos e mestres

AGRADECIMENTOS

A Deus pela vida, saúde, força e ensinamentos. “Nada te perturbe, nada te espante. Tudo passa, Deus não muda. A paciência tudo alcança. Quem a Deus tem, nada falta. Só Deus basta! Santa Teresa de Jesus, rogai por nós.

Aos meus pais, Regina Lúcia e De Assis Oliveira. Obrigado por tudo e por tanto.

Ao Carlos Eduardo Angeli Furlani pela orientação, amizade, confiança transmitida, por acreditar no potencial e nas ideias de seus alunos e sempre ter palavras de conforto e otimismo para animar os momentos tão difíceis.

Ao José Eduardo Pitelli Turco pela coorientação, amizade, companheirismo, ensinamentos, exemplos de vida e todo o apoio. Vida longa ao senhor e às nossas longas conversas.

Ao Rouverson Pereira da Silva pela amizade, parceria e tantos bons momentos vividos.

Ao Afonso Lopes pela disponibilidade, investimento material e amizade. Você é um grande exemplo de profissional.

Ao Adão Felipe e à Franciele Morlin pelo auxílio na construção e elaboração deste projeto, por todo o auxílio durante e após a aquisição de dados. Parabéns pelo profissionalismo!

Dr. Brenda Ortiz, thanks for the opportunity and very good moments.

Ao Ricardo Bueno, Fazenda Dois Irmãos, por ter cedido área para a realização do trabalho. Agradeço ter sido sempre muito bem recebido e tratado em sua propriedade.

Aos amigos da Fazenda Dois Irmãos: Alberto Ângelo, Igor, Jaqueline e Fabiana Serra, José e Luciana Corrêa. Obrigado por todo o auxílio na condução do ensaio. Agradeço a receptividade!

Ao Programa de Pós-graduação em Agronomia (Produção Vegetal), aos professores que compõem o quadro do programa e propiciaram o aprimoramento dos meus conhecimentos.

A Universidade Estadual Paulista “Júlio de Mesquita Filho”, pela oportunidade de realização deste curso. À FEPE (Fazenda Experimental de Pesquisa e Extensão) e todos os colaboradores, por sempre estarem disponíveis a resolver as demandas.

Aos membros da banca examinadora pela disponibilidade em participar desse importante momento e toda a contribuição para melhoria deste trabalho.

Aos meus irmãos Michelle, Guilherme e Geovana Oliveira, pela paciência e toda a ajuda necessária. Aos meus tios Maria Nair, José Pereira, e Vicente Oliveira, minha avó Aldenora Freire: meu eterno carinho e agradecimento. Obrigado por todos os momentos.

À minha grande e eterna amiga de UFC: Elivânia Sousa. Obrigado. A você, toda a minha consideração e admiração.

Aos amigos do Laboratório de Máquinas e Mecanização Agrícola (LAMMA) Renata Queiroz, Francisca Edcarla, Aline Spaggiari, Bruno Rocca, Samira Luns, Jarlyson Bruno, Armando Brito, Marcelo Júnior, Romário Porto, Eduardo Arouche, Jamile Nascimento, Thiago Caio, Vinícius por todos os momentos em harmonia, boas conversas e divertidos cafés. Por todos os eventos, excursões, trabalhos e aprendizado compartilhado. Muito obrigado!

Aos servidores da UNESP Davi Trevizolli, Valdeci Aparicio (Maranhão), Marquinhos, Edivaldo Nascimento, Vagner Colovatti por compartilharem conhecimento e buscarem a solução de problemas. Muito obrigado.

Aos estagiários do Laboratório de Máquinas e Mecanização Agrícola, agradeço toda a ajuda na condução e avaliações nos experimentos.

Ao Conselho Nacional de Pesquisa pela concessão da bolsa de estudo.

A todos que, direta ou indiretamente, participaram e contribuíram para a realização da pesquisa.

Sumário

RESUMO	11
ABSTRACT -	11
CAPÍTULO 1 – CONSIDERAÇÕES GERAIS	13
Resumo	13
INTRODUÇÃO	14
REVISÃO DE LITERATURA	15
Cultura da cana-de-açúcar	15
Variabilidade espacial	16
Sensoriamento remoto	17
Zonas de Manejo	18
Estatísticas multivariadas	19
REFERÊNCIAS	20
CAPÍTULO 2 – DEFINIÇÃO DE ZONAS DE MANEJO UTILIZANDO FUZZY C-MEANS CLUSTERING	25
Resumo.....	25
Abstract	26
1 Introdução	27
2 Material e métodos	29
2.1 Área experimental	30
2.2 Coleta de dados	30
2.3 Observações meteorológicas	31
2.4 índices de vegetação.....	32
2.5 Estatística descritiva.....	32
2.6 Estatística multivariada.....	33
2.7 Delineamento de zonas de Manejo	33
3 Resultados	33
3.1 Componentes meteorológicos	33
3.2 Índice de cone	35
4 Discussão	36
5 Conclusões	45
6 Referências	46
CAPÍTULO 3 – Spatio-temporal clustering analysis of soil moisture and vegetation indices for zone delineation	38
Abstract	50

Resumo	53
1 INTRODUCTION	54
2 MATERIALS AND METHODS	54
2.1 Vegetation Indexes	57
2.2 Spatial and Temporal Variability	58
3 RESULTADOS E DISCUSSÃO	58
3.1 Correlation Analysis	58
4 CONCLUSÕES	58
5 ACKNOWLEDGEMENTS	56
6 REFERENCES	58
CAPÍTULO 4 - Considerações finais	59

Capítulo 1 – CONSIDERAÇÕES GERAIS

RESUMO

O manejo específico utilizando zona de manejo é utilizado em propriedades agrícolas com intuito de maximizar a produtividade agrícola e a aplicação de insumos. Porém, sabe-se que para a criação de ZM pode-se levar em consideração diversas variáveis de solo, climáticas e das culturas ao longo do ciclo de desenvolvimento. Dessa forma, objetivou-se com este projeto delinear zonas de manejo utilizando análises multivariadas de e o algoritmo fuzzy c-means. O experimento foi conduzido na região de Jaboticabal, São Paulo. Para compor as análises multivariadas, foram avaliados parâmetros químicos e físicos do solo, variáveis meteorológicas, índices de vegetação e produtividade. Os dados de produtividade foram obtidos no grid de amostragem. As variáveis meteorológicas foram obtidas por estação meteorológica automatizada. Para obtenção dos índices de vegetação, foram utilizadas imagens de satélite da plataforma Planet Scope. Após análises laboratoriais, os dados foram submetidos à estatística descritiva e análise de correlação foi realizada para selecionar os atributos relacionados para definir as zonas de manejo. Em seguida, a variabilidade espacial desses atributos foi avaliada e mapas de distribuição espacial foram elaborados usando ferramentas geoestatísticas. Após isso, o algoritmo de médias c difusas foi executado para delinear ZMs utilizando o software MZA.

Palavras-chave: Variabilidade espacial; Fuzzy c-means; Planet Scope

ABSTRACT

Specific management using a management zone is used on agricultural properties with the aim of maximizing agricultural yield and the application of inputs. However, it is known that to create ZM, soil, climatic and crop variables can be taken into account throughout the development cycle. Therefore, the objective of this project was to delineate management zones using multivariate analysis and the fuzzy c-means algorithm. The experiment was conducted in the Jaboticabal region, São Paulo. To compose the multivariate analyses, chemical and physical parameters of the soil, meteorological variables, vegetation indices and productivity were evaluated. Yield data were obtained from the sampling grid. Meteorological variables were obtained by an automated meteorological station. To obtain vegetation indices, satellite images from the Planet Scope platform were used. After laboratory analysis, the data was subjected to descriptive statistics and correlation analysis was performed to select related attributes to define the management zones. Then, the spatial variability of these attributes was evaluated and spatial distribution maps were created using geostatistical tools. After that, the fuzzy c-means algorithm was performed to delineate ZMs using the MZA software.

Keywords: Spatial variability; Fuzzy c-means; Planet Scope

1. INTRODUÇÃO

A cana-de-açúcar é uma das principais culturas do mundo, fonte de açúcar, álcool e energia e cultivada em mais de 100 países e com produção em larga escala em dez: Brasil, Índia, China, Tailândia, Paquistão, México, Colômbia, Indonésia, Filipinas e Estados Unidos, correspondendo a mais de 80% da produção mundial da cultura (FAO, 2020). Ferramentas que visam o incremento da produtividade e características técnicas da cana-de-açúcar vêm sendo estudadas para tornar o manejo da cultura mais sustentável e assertivo, melhorando época e locais de aplicação de insumos, manejo de irrigação, tratamentos da cultura no geral.

O Brasil é o maior produtor mundial de cana-de-açúcar, tendo essa cultura grande impacto para o agronegócio e estados produtores. O aumento da demanda mundial por etanol oriundo de fontes renováveis e incentivos governamentais para demandar fontes de energia limpas são fortes indícios que é promissor investir em pesquisa e desenvolvimento para o setor. Com isto, inclui-se a população e o meio ambiente como beneficiários de fontes renováveis, diminuindo o consumo e os impactos do uso de combustíveis fósseis. Nesse contexto, a cana-de-açúcar é considerada alternativa viável para o setor de biocombustíveis devido ao grande potencial na produção de etanol, açúcar e energia, além dos inúmeros subprodutos oriundos destes.

A geração de energia a partir da combustão do bagaço da cana-de-açúcar é crescente e contribui para o aproveitamento dos subprodutos da cultura e, o resultante da queima, é aplicado no solo como fonte de nutrientes. Estas características, aliadas às condições edafoclimáticas e áreas disponíveis de produção, colocam o Brasil como centro para desenvolvimento de cana-de-açúcar e produção de produtos, não somente da commodity.

Métodos têm sido propostos para delinear zonas de manejo em áreas agrícolas, que possibilitam orientar as intervenções dos produtores, visando incremento de produtividade e sustentabilidade na utilização de insumos. Acontece que, caso não sejam utilizados parâmetros que tenham elevada correlação com a produtividade, este zoneamento pode ser errôneo e provocar impactos negativos para a cultura. Diante disso, quanto maior a correlação entre as variáveis, mais assertivo é o uso delas como ferramenta de escolha.

O manejo das lavouras pode ser melhorado com o estabelecimento das zonas de manejo, associando diferentes fontes de informações para defini-las. Acredita-se que é possível de se empregar ferramentas de análise multivariadas para definir quais são os melhores indicadores para se criar uma zona de manejo e aliar essa técnica com algoritmo fuzzy, tornando as informações mais confiáveis. O trabalho teve como objetivo delinear zonas de manejo e avaliar a variabilidade espacial dos atributos do solo, clima, mapas de produtividade e índices de vegetação utilizando ferramentas geoestatísticas e lógica fuzzy.

REVISÃO DE LITERATURA

Cultura da Cana-de-açúcar

A cana-de-açúcar (*Saccharum spp.*) é uma cultura semi-perene C4 cultivada em zonas subtropicais e tropicais em todo o mundo (Huang et al., 2020). A cana-de-açúcar atingiu 26 milhões de hectares de área plantada no mundo, sendo o Brasil o maior produtor da cultura, com aproximadamente 10 milhões de hectares (CONAB, 2020; FAO, 2020), sobretudo, devido as condições de clima e características do solo serem favoráveis para o cultivo da cana-de-açúcar no país (Tayt'Sohn et al., 2018). A cana-de-açúcar passou a ter importância econômica para o território brasileiro desde o período colonial, nos primórdios da economia brasileira, especialmente pela disponibilidade de terras e mão-de-obra indígena empregadas para sua produção (Rodrigues e Ross, 2020).

A segunda estimativa, da safra 2023/24, aponta para um aumento na produção de cana-de-açúcar, quando comparada à última safra. A estimativa é de crescimento de 6,9% em relação à safra 2022/23, resultando em uma produção de 652,9 milhões de toneladas de cana-de-açúcar. O país deverá destinar 8.288,3 mil hectares de cana-de-açúcar para a colheita, com um rendimento médio de 78.779 kg/há (CONAB 2023).

O alto potencial produtivo da cana-de-açúcar é a produção de açúcar, álcoois e combustíveis, mas além disso, os subprodutos como o bagaço e a palha, gerados na indústria e no sistema de colheita mecanizada, são matérias-primas essenciais para geração de energia, produção de etanol celulósico e fertilização dos solos (Cervi et al., 2019; Silva et al., 2019). Outras aplicações incluem seu consumo fresco na alimentação humana e forragem na alimentação animal (Oliveira et al., 2018). A área plantada de cana-de-açúcar tem aumentado a cada safra, principalmente pela demanda de biocombustíveis (Bordonal et al., 2018), destacando o Brasil que, além de maior produtor mundial da cultura e de açúcar, também é o segundo maior produtor de bioetanol (Bordonal et al., 2018; Jordão e Moretto, 2015). Outro ponto importante diante da expansão em área plantada é a caracterização da cultura como fonte de emprego e renda (Oliveira et al., 2020).

No Brasil, a cana-de-açúcar é a principal fonte de biomassa para produção de etanol, nos próximos 10 anos, estima-se mudanças significativas em função dos novos avanços e incentivos públicos à produção de biocombustíveis que contribuirão para aumento de produção de cana-de-açúcar (EPE, 2019). O Estado de São Paulo é o maior produtor nacional de cana-de-açúcar, a cultura é considerada um dos principais setores do agronegócio paulista, incorporando áreas de outras lavouras e, principalmente, de pastagens (Adami et al., 2012). A área produtiva do Estado de São Paulo cresce gradativamente a cada safra, aproximadamente 4,3 milhões de hectares foi a área colhida no Estado na safra 2019/2020, alcançando produção de 342,6 milhões de toneladas e um rendimento médio de 79,6 kg ha⁻¹, valor semelhante ao alcançado nas três últimas safras, 77,3; 72,6 e 72,5 kg ha⁻¹, respectivamente (CONAB, 2020).

Variabilidade espacial

O recurso mais importante para a manutenção da qualidade de vida humana é o solo, que é a base para o desenvolvimento agrícola. É um corpo natural ativo que se forma a partir de processos pedogênicos durante e após o intemperismo das rochas. Possui propriedades químicas, físicas, mineralógicas e biológicas distintas e possui profundidade variável sobre a superfície terrestre, o que cria ambiente favorável ao crescimento das plantas (Malla 2020, Li et al., 2021). A variabilidade nas propriedades do solo resulta principalmente das interações complexas entre geologia, topografia, clima, bem como o uso do solo.

A diminuição da produtividade do solo juntamente com o crescimento da população é um problema que ainda permanece sem solução (Li et al., 2021). Isto ameaça à segurança alimentar e o desenvolvimento agrícola e ambiental sustentável (Alemu et al., 2016; Laekemariam et al., 2018). Portanto, existe demanda crescente por dados precisos, científicos e de múltiplas resoluções do solo nas propriedades rurais para tomar medidas decisivas para lidar com os problemas e garantir o uso sustentável da terra no presente e nas gerações futuras (Laekemariam et al., 2018; Li et. al 2016).

As propriedades do solo variam espacialmente de uma área pequena para uma área maior. Isto pode ser devido ao efeito combinado de fatores

intrínsecos e extrínsecos e de atividades humanas, incluindo práticas de manejo do solo e afeta a produtividade agrícola. A informação espacial do solo é essencial para a investigação e a tomada de decisões em diversas disciplinas e em várias escalas, por exemplo, como apoio às decisões individuais dos agricultores sobre como variar a taxa de calcário nas áreas. Compreender e estimar a variabilidade espacial das propriedades do solo é importante para avaliar o ambiente e fornece os fatores e processos que controlam o potencial de produção agrícola (Aliero et al., 2018; Khan et al., 2019). É também um determinante importante da eficiência dos insumos agrícolas, bem como da gestão das culturas e da eficácia do design dos ensaios de pesquisa de campo Aliero et al., 2018; Khan et al., 2019. No entanto, as áreas onde as intervenções de gestão do solo foram sujeitas a recomendações gerais, não levaram em conta as complexidades do solo e a variabilidade espacial, portanto, não são adequadas para serviços de aconselhamento aos agricultores, o que torna necessários testes de solo para uma nutrição equilibrada para manter a saúde do solo (Laekemariam et al., 2018).

Conforme discutido por Damian et al. (2017), a variabilidade do ambiente tem influência na produtividade das culturas. Esta influência está associada ao teor de matéria orgânica, areia, silte, argila e outros compostos (Ding et al., 2006; Haruna e Nkongolo, 2015).

Sensoriamento Remoto

Os dados de detecção remota podem ser avaliados para acompanhar o desenvolvimento das culturas de cobertura e para estimar os seus índices após plantio das culturas e até mesmo de dados históricos. Os satélites podem monitorar grandes áreas no intervalo de tempo adequado para a agricultura (Atzberger, 2013; Kasampalis et al., 2018).

Neste contexto, o recente advento das constelações de satélites pequenos e padronizados, adquirindo dados de alta resolução espacial e temporal, oferece novas perspectivas para diversas aplicações agrícolas (Houborg et al., 2018). Um exemplo desta nova geração de dados é a constelação de satélites PlanetScope (PS) (Planet Labs Inc. Dove satélites) da Planet. (Planet Labs Inc., 2019).

Ao combinar a alta frequência de aquisição de dados com a alta resolução espacial, a constelação de satélites PS aumenta a probabilidade de obter dados livres de nuvens para um monitoramento adequado das culturas. As imagens PS são adquiridas em quatro amplas bandas espectrais posicionadas nos intervalos espectrais azul, verde, vermelho e infravermelho próximo (NIR) com resolução espacial de 3,7m. Apesar do potencial dos satélites PS para aplicações agrícolas, os seus dados nunca foram avaliados para estimativas do AGB de culturas de cobertura visando a delimitação de zonas de gestão.

Um interesse na utilização de índices de vegetação como alternativa à produtividade mapas surgiram nos últimos anos. Globalmente, o NDVI, calculado a partir de imagens de satélite (Tarnavsky et al., 2008) tem sido amplamente utilizado, uma vez que está intimamente correlacionado com a produtividade das culturas (Boken e Shaykewich, 2002; Peralta et al., 2016). Além disso, imagens de satélite de alta resolução pode ser adquirido a um preço baixo, o que permite mapear grandes áreas com baixos investimentos.

Zonas de Manejo

Aumentar a produtividade de um sistema agrícola, aliado a um retorno económico atrativo e a impactos ambientais mínimos, é o que se busca com a utilização de zonas de manejo. A utilização de zonas de manejo é uma abordagem importante que, entre outros benefícios, permite reduções no custo de produção, ao mesmo tempo em que reduz os impactos ambientais das atividades agrícolas (Kaffka et al., 2005; Moral et al., 2011).

A utilização de zonas de manejo (ZM) é uma importante abordagem que, entre outros benefícios, permite reduções no custo de produção, ao mesmo tempo em que reduz os impactos ambientais das atividades agrícolas (Kaffka e outros, 2005; Morais et al., 2011). Para que os agricultores possam para usar ZM, o primeiro passo é delimitar essas zonas com base nos parâmetros gerados que levam em consideração diferentes atributos do solo (Santi et al., 2016; Damian et al., 2016), componentes topográficos (Fraisse et al., 2001; Fridgen et al., 2004), índices de vegetação (Zhang et al., 2004), índices de vegetação (Zhang et al., 2004). al., 2010; Chang et al., 2014) e os parâmetros intrínsecos de cada cultura (El Nahry et al., 2011; Tagarakis et al., 2013). Entre muitas

opções, os dados de produtividade das culturas têm sido considerados o parâmetro mais importante para definição eficiente de ZM em sistemas de cultivo anual (Betzek et al., 2018).

Os mapas de produtividade das culturas são criados a partir dos dados de produtividade coletados por um conjunto de sensores acoplados às colhedoras em conjunto com sistemas de informação de posicionamento (Blackmore e Moore, 1999).

Nos últimos anos surgiu um interesse na utilização de índices de vegetação como alternativa aos mapas de produtividade. Globalmente, o NDVI, calculado a partir de imagens de satélite (Tarnavsky et al., 2008) tem sido amplamente utilizado, uma vez que está intimamente correlacionado com a produtividade das culturas (Boken e Shaykewich, 2002; Sultana et al., 2014; Lopresti et al., 2015; Peralta et al., 2016). Além disso, imagens de satélite de alta resolução podem ser adquiridas a baixo preço, o que permite mapear grandes áreas com baixos investimentos.

Os avanços tecnológicos da agricultura permitem-nos observar a formação de zonas homogêneas do ponto de vista agrícola, com comportamentos similares à adubação e à aplicação de defensivos, por exemplo, gerando uma oportunidade de otimização de recursos e redução do impacto ambiental, além do aumento da lucratividade. A produtividade agrícola varia espacialmente, e as técnicas geoestatísticas surgem para estudar essas variações, possibilitando a elaboração de mapas e o delineamento de áreas de manejo específico (Farias et al., 2002).

Estatísticas multivariadas

A análise de correlação possibilita que seja observada a relação entre as variáveis utilizadas. Outra técnica de estatísticas multivariadas é o PCA, que utiliza atributos ou variáveis correlacionados e identifica uma recombinação linear ortogonal dos atributos, identificando as principais fontes de variabilidade nos dados (Xin-Zhong et al., 2009). Antes das análises estatísticas multivariadas, é interessante que cada conjunto de dados será padronizado (média = 0 e desvio padrão = 1), com o objetivo de transformar cada dado original na mesma ordem

de magnitude. Como as variáveis apresentam ordens de magnitude diferentes, o uso das variáveis padronizadas requer que as matrizes de variância e covariância sejam as mesmas da matriz de correlação

A análise dos componentes principais e de correlação podem ser aplicadas em todas as variáveis estudadas, a exemplo atributos do solo e índices de vegetação, produtividade e dados meteorológicos, com o objetivo de transformar as variáveis originais em número menor de variáveis, denominadas componentes principais (PCs) ou variáveis de correlação (Jolliffe, 2002).

A delimitação das zonas de manejo será realizada podem ser de diversas formas, dentre elas, usando o algoritmo de clustering fuzzy c-means, aplicando a matriz de pontuação dos PCs selecionados, utilizando o software MZA (Minasny e McBratney 2002). Além disso, para definir o número ideal de zonas, podem utilizados o Índice de Desempenho Fuzziness (FPI) e o Índice de Entropia de Classificação Normalizada (NCE). O FPI é uma medida do grau de separação entre observações, isto é, entre dados interpolados e clusters gerados, onde os valores variam de 0 a 1 (Odeh, McBratney e Chittleborough, 1992). A NCE mede o grau de desorganização entre as classes (quanto maior a NCE, maior a quantidade de desorganização) (Fridgen et al. 2004).

A concordância entre o mapa das zonas de manejo delimitado pelos principais componentes e o mapa de produtividade da cultura pode ser avaliada através do índice Kappa, de acordo com a metodologia apresentada por Kitchen et al. (2005).

2. REFERÊNCIAS

- ARSLAN, S., and T. S. COLVIN. 2002. **Grain yield mapping: Yield sensing, yield reconstruction, and errors.** Precision Agriculture 3:135–54.
- HONG, Y. 2005. **Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity.** Computers and Electronics in Agriculture
- JOLLIFFE, I.T.; **Principal Component Analysis** (second ed.), Springer, New York (2002)
- Kassambara, A., and F. Mundt. 2017. Package “factoextra” for R: Extract and Visualize the Results of Multivariate Data Analyses.
- MOLIN, JOSÉ PAULO; AMARAL, LUCAS RIOS DO; COLAÇO, ANDRÉ FREITAS. UNIDADES DE GESTÃO DIFERENCIADA. IN: MOLIN, JOSÉ

PAULO; AMARAL, LUCAS RIOS DO; COLAÇO, ANDRÉ ODEH, I. O. A., A. B. MCBRATNEY, AND D. J. CHITTLEBOROUGH. 1992. **Soil pattern recognition with fuzzy-c-means: Application to classification and soil-landform interrelationships**. Soil Science Society of America Journal 56:505–16.

R. ROSSI, A. POLLICE, G. BITELLA, R. LABELLA, R. BOCHICCHIO, M. AMAT O. **Modelling the non-linear relationship between soil resistivity and alfalfa NDVI: a basis for management zone delineation**. J. Appl. Geophys., 159 (2018), pp. 146-156.

R PACKAG. VERSION. MINASNY, B., AND A. B. MCBRATNEY. 2002. **FuzME**. TAYLOR, J. A., A. B. MCBRATNEY, AND B. M. WHELAN. 2007. **Establishing management classes for broadacre agricultural production**. Agronomy Journal

SANTOS. L. 2012. **Definition of management zones in coffee production fields based on apparent soil electrical conductivity**. Scientia Agricola 69:173–79.

SINGH, K. 2019. **Geostatistical and fuzzy clustering approach for delineation of site-specific management zones and yield-limiting factors in irrigated hot arid environment of India**. Precision Agriculture.

CONAB. Safra 19/20. Disponível em:< www.conab.gov.br >

TAYT'SOHN, F. C. O.; NUNES, A. M. B.; PEREIRA, A. O. **“Assessing sugarcane expansion to ethanol production under climate change scenarios in Paranaíba river basin – Brazil”**. Biomass and Bioenergy, v. 119, n. July, p. 436–445, 2018.

Cervi WR, Lamparelli RAC, Seabra JEA, Junginger M, van der Hilst F. (2019) **Bioelectricity potential from ecologically available sugarcane straw in Brazil: A spatially explicit assessment**. Biomass and Bioenergy 122:391–399.

Silva AGB, Lisboa IP, Cherubin MR, Cerri CEP. (2019) **How much sugarcane straw is needed for covering the soil?** Bioenergy Research 12:858–864.

Oliveira LA de, Miranda JH de, Cooke RAC. (2018) **Water management for sugarcane and corn under future climate scenarios in Brazil**. Agricultural Water Management 201:199–206.

Bordonal RO, Carvalho JLN, Lal R, Figueiredo EB, Oliveira BG, La Scala N. (2018) **Sustainability of sugarcane production in Brazil**. A review. *Agronomy for Sustainable Development* 38:1–23.

EPE. (2019) **Investimentos e custos operacionais e de manutenção no setor de biocombustíveis: 2020 - 2030**. Rio de Janeiro, 3 p. (CAPEX, capital expenditure).

Adami M, Rudorff BFT, Freitas RM, Aguiar DA, Sugawara LM, Mello MP. (2012) **Remote sensing time series to evaluate direct land use change of recent expanded sugarcane crop in Brazil**. *Sustainability* 4:574–585.

Cangyu Li, Xinhui Wang, Mingzhou Qin. **Spatial variability of soil nutrients in seasonal rivers: a case study from the Guo River Basin, China** *PLoS One*, 16 (3) (2021)

Saleh Amal Muhamma Spatial variability mapping of some soil properties in JadwalAl amir project babylon, Iraq

J. Indian Soc. Remote Sens. (2018 Razan Malla, Shankar Shrestha, Dinesh Khadka, Chet Raj Ba Soil fertility mapping and assessment of the spatial distribution of sarlahi district, Nepal *Am. J. Agri. Sci.*, 7 (2020), pp. 8-16

Lelago Alemu, TekalignMamo, Wassie Haile, Hailu Shiferaw **Assessment and mapping of status and spatial distribution of soil macronutrients in Kembata Tembaro zone, southern Ethiopia** *Adv. Plants Agri. Res.*, 4 (2016), p. 305–317

Fanuel Laekemariam, Kibebew Kibret, TekalignMamo, HailuShifera **Accounting spatial variability of soil properties and mapping fertilizer types using geostatistics in southern Ethiopi** *Commun. Soil Sci. Plant Anal.*, 4 (2018), pp. 124-137

Jose Manuel Miras-Avalos, María Fandiño, Benjamín J Rey, Jorge Dafonte, Javier J. **Cancel Zoning of a newly-planted vineyard: spatial variability of physico-chemical soil propertie** *Soil Systems*, 4 (2020), p. 62

Muhammad Mansur Aliero, Mohd Hasmadi Ismail, Mohamad Azani Alias, S. Alias Mohd, Salisu Abdullahi, Shehu Hassan Kalgo, Ahmad Abdulrahman Kwaid **Assessing soil physical properties variability and their impact on vegetation using geospatial tools in Kebbi State, Nigeria** *Earth and Environ. Sci.*, 169 (2018)

M.Z. Khan, M.A. Islam, M. Sadiqul Amin, M.M.R. **Bhuiya Spatial variability and geostatistical analysis of selected soil Bangladesh J. Sci. Ind. Res.**, 54 (2019), pp. 55-66

Damian, J.M; A.L. Santi, M. Fornari, C.O Da Ros, V.L. **Eschner. Monitoring variability in cash-crop yield caused by previous cultivation of a cover crop under a no-tillage system.** *Comput. Electron. Agric.*, 142 (2017), pp. 607-621,

Atzberger, 2013 C. Atzberg **Advances in remote sensing of agriculture: context description, existi operational monitoring systems and major information needs** *Remote Sens.*, 5 (2013), pp. 949-981

Kasampalis et al., 2018 D. Kasampalis, T. Alexandridis, C. Deva, A. Challinor, D. Moshou, G. **Zalid Contribution of remote sensing on crop models: a review** *J. Imaging*, 4 (2018), p. 52

Houborg and McCabe, 2018 R. Houborg, M.F. McCabe **A hybrid training approach for leaf area index estimation via Cubist and random forests machine-learning ISPRS J. Photogramm. Remote Sens.**, 135 (2018), pp. 173-188,

Planet Labs Inc., **2019 Planet Labs Inc Planet Imagery Product Specifications.** Mountain View (2019)

FRAISSE, C.W.; K.A. SUDDUTH, N.R. KITCHEN. **Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity.** *Trans. ASAE (Am. Soc. Agric. Eng.)*, 44 (1) (2001), pp. 155-166.

FRAISSE, C.W.; 2004. *Management Zone Analyst (MZA)*. *Agronomy Journal*

GILI, A. C. ÁLVAREZ, R. BAGNATO, E. NOELLEMAYER. **Comparison of three methods for delineating management zones for site-specific crop management.** *Comput. Electron. Agric.*, 139 (2017), pp. 213-223.

XIN-ZHONG, W., L. GUO-SHUN, H. HONG-CHAO, W. ZHEN-HAI, L. QING-HUA, L. XU FENG, H. WEI-HONG, AND L. YAN-TAO. 2009. **Determination of management zones for a tobacco field based on soil fertility.** *Computers and Electronics in Agriculture* 65:168–75.

JOLLIFFE, I.T.; **Principal Component Analysis (second ed.)**, Springer, New York (2002) Kassambara, A., and F. Mundt. 2017. **Package “factoextra” for R: Extract and Visualize the Results of Multivariate Data Analyses**

KITCHEN, N. R., K. A. SUDDUTH, D. B. MYERS, S. T. DRUMMOND, AND S. T. DONG, J. SHANG, J. LIU, B. QIAN, Q. JING, B. MA, et al. **Using RapidEye imagery to identify within-field variability of crop growth and yield in Ontario, Canada.** *Precis. Agric.*, 20 (6) (2019), pp. 1231-1250.

Capítulo 2 - DEFINIÇÃO DE ZONAS DE MANEJO UTILIZANDO *FUZZY C-MEANS CLUSTERING*

RESUMO

O manejo específico nas áreas de cultivo utilizando zona de manejo pode trazer inúmeros benefícios, tais como, aplicação direcionada de insumos e aumento de produtividade. Porém, sabe-se que a criação de ZM deve levar em consideração fatores imutáveis como tipo de solo, textura, clima e aqueles mutáveis como fertilidade e densidade do solo ao longo do ciclo de desenvolvimento das culturas. Dessa forma, neste estudo foi analisado se análises multivariadas de correlação e o algoritmo fuzzy c-means seriam possíveis para delinear zonas de manejo. Para compor as análises multivariadas, foram avaliados parâmetros químicos e físicos do solo, variáveis meteorológicas, produtividade e índices de vegetação na cultura da soja. Os resultados provaram que a abordagem proposta foi eficiente e que atributos do solo e índices de vegetação podem ser fortes definidores das ZMs. Assim, produtores e prestadores de serviços que desejam tratar os campos de produção baseado em ZMs podem utilizar a abordagem proposta neste estudo, de utilizar a tecnologia em favor do desenvolvimento e aprimoramento da cultura da cana-de-açúcar.

Palavra-chave: Índices de vegetação. *Fuzzy c-means*. Variabilidade espacial.

ABSTRACT

Specific management using a management zone can bring numerous benefits, such as targeted application of inputs and increased yield. However, it is known that the creation of ZM must take into account immutable factors such as soil type, texture, climate and changeable factors such as soil fertility and density throughout the crop development cycle. Therefore, this study analyzed whether multivariate correlation analyzes and the fuzzy c-means algorithm would be possible to delineate management zones. To compose the multivariate analyses, chemical and physical parameters of the soil, meteorological variables, productivity and vegetation indices in soybean crops were evaluated. The results proved that the proposed approach was efficient and that soil attributes and vegetation indices can be strong definers of ZMs. Thus, producers and service providers who wish to treat production fields based on ZMs can use the approach proposed in this study.

Keyword: Vegetation indices. Fuzzy c-means. Spatial variability.

1. Introdução

Muitos produtores ainda praticam agricultura convencional baseada em recomendações uniformes sem levar em consideração a variabilidade espacial do ambiente físico. Isso pode resultar na aplicação excessiva ou reduzida de fertilizantes, irrigação, distribuição de sementes em áreas em que não há necessidade, resultando em baixo lucro para os produtores e podendo causar negativos impactos ambientais, além de redução na produção, qualidade dos produtos e intensificação variabilidades. As propriedades do solo variam espacialmente devido atividades intrínsecas (formação) e extrínsecas (práticas de manejo). Áreas de cultivo, com alto grau de variabilidade espacial nas propriedades do solo, poderiam ser mais bem gerenciadas através de levantamento e classificação do campo (Brierley et al., 2022).

As metas de produtividade são frequentemente traçadas a partir das médias históricas de produtividade específicas do local, mas também podem ser moldadas por covariáveis. Conjuntos de dados históricos de produtividade de colhedoras equipadas com sensores de produtividade, por exemplo, são amplamente apresentados em trabalhos de agricultura de precisão (AP). Desde a operação de colheita até a elaboração dos mapas de produtividade, podem ser detectados alguns tipos de erros, que podem ser oriundos de sensores, data logger, falhas, operacionais, posicionamento ou operador, podem comprometer a qualidade dos dados (Arslan e Colvin 2002). Outro fator importante é que os dados podem ter registros comerciais privados, impossibilitando que possa haver estudo da área.

No entanto, as complexas interações entre atributos do solo, clima e condições das culturas dificultam o estabelecimento de áreas com o mesmo potencial de produção (Moharana et al. 2019). Com base nisso, a integração de múltiplas variáveis pode ser a solução para um melhor monitoramento da realidade em campo (Gavioli et al. 2016). Sabendo destes problemas, entende-se que as zonas de manejo (ZMs) ou unidades de gestão diferenciada (UGDs) são agrupadas em regiões que possuem baixa variabilidade espacial e/ou temporal para a confecção de mapas específicos para a aplicação de insumos em cada uma delas (Molin et.al., 2015). ZMs são subdivisões da área com características semelhantes, como textura, topografia, status da água e níveis

de nutrientes do solo que podem ser usados para aplicação de insumos em taxa variável (Moral, Terrón e Silva 2010).

Para o delineamento dessas ZMs pode-se usar diferentes conjuntos de dados, conforme discutido por Gavioli et al. (2019). Os dados de entrada para os algoritmos de delimitação geralmente incluem produtividade das culturas (Damian et al., 2017), métricas topográficas (Fraisse et al., 2001) e atributos do solo (Rossi et al., 2018). O ambiente local e as variações que ocorrem nele é de extrema importância para tomada de decisões e deve ser levado em consideração. Mais recentemente, o sensoriamento remoto também foi proposto como uma ferramenta mais econômica para delimitar zonas de manejo para AP (Damian et al., 2020).

Métodos para mapear a produção de áreas a partir de imagens de sensoriamento remoto podem aumentar a disponibilidade de mapas de produtividade. Portanto, os agricultores podem tirar proveito da aquisição repetitiva de dados e cobertura espacial oferecida por sensores remotos para estimar índices de vegetação e delimitar zonas de gerenciamento, economizando tempo e custo de extensas amostragens de campo (Wang et al., 2019; Damian et al., 2020; Breunig et al., 2020).

Para obter bons resultados no delineamento MZs, a seleção de variáveis com estabilidade temporal e correlacionadas com a produtividade das culturas pode ser importante. Além disso, considerando que a maioria dessas variáveis geralmente está relacionada entre si, uma análise de componente principal (PCA) pode ser usada para resumir esses conjuntos de dados relacionados em alguns componentes significativos (Xin-Zhong et al. 2009) ou, simplesmente, análises de correlação entre as variáveis analisadas.

Uma abordagem eficaz para definir MZs ao usar várias camadas de informação é o uso de algoritmos de cluster não supervisionados, como médias C difusas (Tripathi et al. 2015). Essa técnica agrupa pontos de dados semelhantes (células), com base em sua estrutura inerente, em classes distintas. Assim, a integração de geoestatística, estatística multivariada e algoritmos de agrupamento pode permitir a definição de MZs com maior precisão. Como foi verificado por Valente et al. (2012), avaliando as propriedades físicas e químicas do solo, utilizou análise geoestatística combinada com a análise fuzzy de c-means clustering para definir ZMs no café (*Coffea arabica* L.).

O trabalho teve como objetivos: Delinear zonas de manejo; II) Avaliar a variabilidade espacial dos atributos do solo, mapas de produtividade e índices de vegetação utilizando ferramentas geoestatísticas; III) Delinear zonas de manejo por meio de análise de correlação e lógica fuzzy.

3. Material e métodos

2.1 Área experimental

A pesquisa foi desenvolvida no município Jaboticabal/SP, em área comercial com 21 ha. O estudo foi conduzido no período em que houve a reforma do canavial com a cultura da soja. O experimento foi realizado no período de safra, com semeadura em 18 de novembro de 2020 e colheita em 15 de março de 2021. O solo é classificado como LATOSSOLO VERMELHO Eutroférico típico, classe textural franco argilo arenoso, A moderado e relevo suave ondulado. A precipitação média anual de 1.400 mm, temperatura média anual de 22 °C e umidade relativa do ar média de 70% (ANDRIOLI & CENTURION, 1999). O clima da região, segundo a classificação de Koeppen é do tipo Cwa, subtropical com estiagem no inverno.

2.2 Coleta de dados

2.2.1 Amostragem de solo

As amostras de solo foram coletadas em grade amostral previamente definida utilizando ferramentas do software QGIS, com dimensões de 50x50 m, totalizando 92 amostras, conforme descrito na Figura 1. Cinco subamostras de solo foram coletadas dentro de cada grade e, ao final, feita uma amostra composta. As amostras de solo foram realizadas de 0-40 cm e foram coletadas antes do preparo do solo para reforma do canavial e cultivo da cultura da soja, utilizando amostrador automatizado Falker SoloStar acoplado a um quadriciclo agrícola. Os locais onde foram realizadas as análises tiveram a massa vegetal superficial removida previamente à coleta de solo. Os pontos amostrais foram georreferenciados utilizando receptor de navegação do Sistema de Navegação Global por Satélite (GNSS), acoplado ao quadriciclo. Após este processo, as

amostras foram encaminhadas à laboratório para obtenção dos parâmetros físico-químicos.

Semelhante às coletas para análise físico-química laboratorial, foram realizadas leituras de índice de cone mecânica do solo à penetração (RMSP), utilizando penetrômetro automatizado também acoplado a um quadriciclo agrícola, em três momentos: antes do preparo do solo para reforma do canavial, após este preparo e, por fim, após a colheita da cultura da soja, escolhida esta como cultura de reforma.

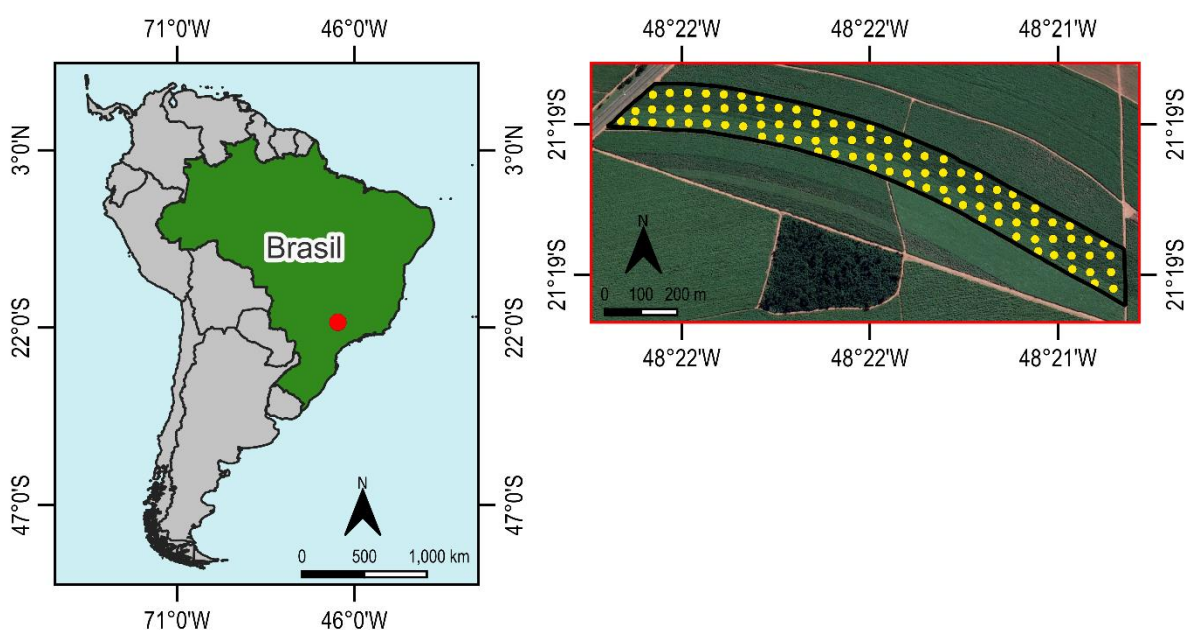


Figura 1. Área experimental, com grid amostral de 50x50 m, total de 92 pontos.

2.4 Observações meteorológicas

Os dados meteorológicos referentes a todo o período de implantação e condução do experimento foram coletados por Estação Meteorológica Automatizada da Campbell Scientific instalada próximo à área experimental, abrangendo todo o período do experimento. A estação possuía os seguintes sensores: temperatura e umidade relativa do ar, velocidade do vento e radiação solar global.

2.5 Índices de vegetação (VI)

Os índices de vegetação NDVI, GNDVI e NLI foram obtidos por meio de imagens do satélite Planet Scope (alta resolução, com 3 m). As imagens utilizadas compreenderam o ciclo da cultura da soja. Em seguida, as imagens foram processadas, no qual foram realizadas as calibrações radiométrica, atmosférica e geométricas para obter a refletância da superfície, que foram efetuadas por meio do software QGIS. Após o processamento digital das imagens, foram calculados os índices.

Após o cálculo dos índices, os valores correspondentes aos pixels que os pontos estão localizados foram extraídos usando a ferramenta de amostragem de pontos no QGIS. Este procedimento foi realizado para padronizar o número de amostras dos índices com os atributos do solo e os dados de produtividade da cultura. Os VI's foram coletados em 4 datas durante o ciclo da soja, de acordo com a Figura 1, caixas em vermelho. Em dia próximo à coleta das imagens para obtenção dos VI's, foram também coletados dados biométricos de altura, largura e diâmetro do colmo de plantas. Para estimar a produtividade, foi utilizada a mesma grade de amostragem inicial e, com auxílio de molduras de 1m² no estágio anterior à colheita, descrito em amarelo na Figura 2, foram coletadas todas as plantas que estavam dentro da moldura e as vagens processadas. No campo, estas amostras foram retiradas no centro de cada ponto de amostragem georreferenciado.




Figura 2. Estádios da cultura da soja em que foram obtidos os índices de vegetação. VN: 22/01/2021, R2: 04/02/2021, R4:19/02/2021, R7: 04/03/2021 e R8: colheita, 15/03/2021.

2.4 Estatística descritiva

Dados de atributos do solo, biometria, índices de vegetação e produtividade da cultura foram submetidos à análise estatística descritiva, com nível de significância de 5% utilizando o software R. Foram obtidos os seguintes parâmetros: valores mínimos, médios e máximos, desvio padrão, coeficiente de

variação (CV) e coeficientes de assimetria e curtose. A dispersão dos dados em torno da média foi classificada como sugerido por Warrick e Nielsen (1980). A normalidade dos dados foi avaliada pelo teste de Shapiro Wilk, com nível de significância de 5%.

2.6 Estatísticas multivariadas

A análise de correlação é uma técnica de análise multivariada que observa a relação de covariáveis entre si. Esta análise foi aplicada aos atributos do solo e índices de vegetação e biometria da soja, com o objetivo de observar correlações, diminuir a quantidade de variáveis e estabelecer os parâmetros para criação das zonas de manejo (Jolliffe, 2002). Os principais componentes foram selecionados quando explicaram pelo menos 70% da variação total do conjunto de dados (Li et al. 2007). A análise de correlação foi realizada usando o pacote “factominer” no software R.

2.7 Delineamento de zonas de manejo

A delimitação das zonas de gerenciamento foi realizada usando o algoritmo de clustering fuzzy c-means, aplicando os valores das variáveis selecionadas, utilizando o software MZA. Além disso, para definir o número ideal de zonas, foram utilizados o Índice de Desempenho Fuzziness (FPI) e o Índice de Entropia de Classificação Normalizada (NCE). O FPI é uma medida do grau de separação entre observações, isto é, entre dados interpolados e clusters gerados, onde os valores variam de 0 a 1 (Odeh, McBratney e Chittleborough, 1992). A NCE mede o grau de desorganização entre as classes, ou seja, quanto maior a NCE, maior a quantidade de desorganização (Fridgen et al. 2004). Além disso, a análise de variância foi usada para indicar heterogeneidade entre diferentes MZs.

As configurações escolhidas no software FuzME foram: medida de similaridade = mahalanobis como norma para expressar a distância entre as observações e os centróides do agrupamento, que testa a dissimilaridade entre os clusters; expoente difuso (ponderação de imprecisão) = 1,3; número máximo de iterações = 300; e critério de convergência = 0,0001 (Taylor, McBratney e

Whelan 2007) e número mínimo de 2 e máximo de clusters 5. Por fim, foram simulados clusters em determinada quantidade de zonas de manejo e, o número ideal, foi definido com base nos menores valores de FPI e NCE pois, quanto mais próximo de 0, melhor a divisão dos clusters, de acordo com as Equações 1 e 2:

$$FPI = 1 - \frac{c}{c-1} \left[1 - \frac{\sum_{i=1}^c \sum_{k=1}^n (\mu_{ik}^2)}{n} \right]$$

$$NCE = \frac{n}{n-c} \left[- \frac{\sum_{k=1}^n \sum_{i=1}^c \mu_{ik} \log_a (\mu_{ik})}{n} \right]$$

onde c é o número de clusters e n é o número de observações, μ_{ik} é a pertinência difusa e \log_a é o logaritmo natural.

Após o resultado obtido no software MZA, novamente foram utilizadas ferramentas do QGIS para observar o mapa com zonas de manejo geradas pelos componentes selecionados na análise de correlação.

3 RESULTADOS

3.1 Componentes meteorológicos

Na Figura 3, são apresentadas as temperaturas máxima, mínima e média do período de condução do experimento. Observou-se que a maior temperatura foi de 37,95 °C aos 27 dias após a semeadura e a temperatura mínima foi de 9,84 °C, aos 20 dias após semeadura.




Figura 3. Temperatura máxima, média e mínima do período de condução do experimento. T méd= Temperatura média; T máx= Temperatura máxima; T mín=Temperatura mínima, Precip= Precipitação.

Na Figura 4, observam-se os valores de radiação durante a condução do experimento. Neste estudo, foi adotada a mesma quantidade de radiação incidente para a área inteira. Observou-se que a quantidade de radiação acumulada incidente no dossel da cultura da soja, de $3311,5 \text{ MJ}^{-2} \text{ dia}^{-1}$ foi dentro do recomendado para o bom desenvolvimento da cultura.




Figura 4. Valores de Radiação Global e Radiação fotossinteticamente ativa durante a condução do experimento. Rad Global = Radiação Global.

3.2 Índice de cone – RMSP

Mapas interpolados com valores de índice de cone (kPa) foram construídos para mapear a dinâmica de compactação do solo antes e após o preparo do solo e, após o cultivo da soja (Figura 5). Claramente, as camadas superficiais do solo (0-20 cm) eram as menos compactadas. Em contraste, quando a profundidade do solo era de 20-40 cm os níveis de compactação eram maiores. Analisando os resultados antes do preparo do solo (Figura 5a) notou-se que a camada 0-20 cm era em média 1500 kPa, um forte indicador de que os níveis de compactação da área nesta camada eram satisfatórios para área de cultivo onde não havia revolvimento anual do solo. Nesta camada do solo, apenas 15% da área era representada por regiões com kPa maior que 2000. No entanto, quando se observou a camada de 20-40, os indicadores de

compactação atingiram valores considerados padrão rígido (kPa = 4000) e, em suma, o índice de compactação do solo era alto, assim, implantar culturas com sistemas radiculares que compreendessem esta camada, como a soja, seria um problema.

Após o preparo do solo notou-se que os indicadores de compactação reduziram mais de 50% (Figura 5cd). Na camada de solo de 0-20 cm os indicadores mostraram que a compactação foi, em média, 700 kPa. Por outro lado, na profundidade de 20-40 cm os valores atingiram, em média, 1700 kPa, tornando, portanto, o solo propício para o cultivo da cultura da soja. Após o cultivo da soja na área, cerca de 130 dias após a semeadura, construiu-se novos mapas de índice de cone baseados em dados coletados em campo (Figura 5ef). A camada 0-20 cm aumentou sutilmente os níveis de compactação de 700 para 780 kPa, aumento este esperado devido tráfego de máquinas em tarefas de tratos culturais. No entanto, a camada 20-40 cm reduziu cerca de 100 kPa comparada a análise antes da semeadura da soja, uma mudança também sutil, mas que pode ser fortemente justificada pela ação de crescimento e desenvolvimento do sistema radicular pivotante da soja.

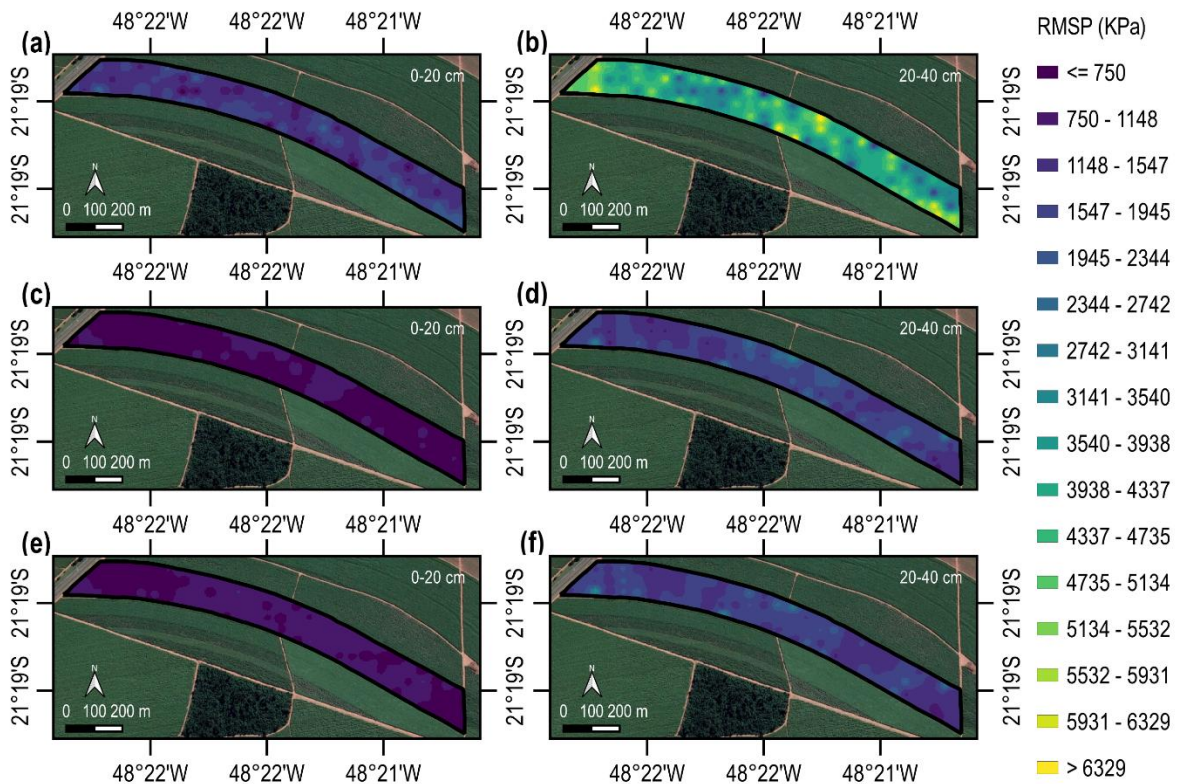


Figura 5. Variabilidade espacial de compactação do solo por índice de cone (kPa). (a-b) campo antes do preparo de solo. (c-d) campo após preparo do solo.

(e-f) campo após cultivo de soja. Os mapas foram construídos com dados coletados em campo por interpolação IDW em 5x5 m.

Apresentada em material suplementar, está a Tabela 1 com a análise descritiva de todas as variáveis disponíveis para a realização desta pesquisa. Observou-se ainda a normalidade dos dados.

3.3 Análise das variáveis

A Tabela 2 representa a análise de correlação para todas as variáveis disponíveis. Observaram-se algumas correlações acima dos 70%, dentre elas, correlação entre a quantidade de areia e argila, MG+, soma de bases e V% do solo e correlação entre os índices de vegetação GNDVI, NDVI e NLI. Sendo assim, estas variáveis foram selecionadas para compor o conjunto de dados para definir as ZMs. Após a análise de correlação entre as variáveis, observou-se correlação acima dos 70% para alguns atributos do solo e índices de vegetação, sendo eles: quantidade de argila, V%, magnésio-MG, soma de bases; GNDVI, NDVI e NLI na data 19/02/2021.

Observada esta correlação, os valores destes atributos foram inseridos no software MZA para a geração das zonas de manejo. Com a descrição do software já inserida na metodologia, obteve-se os índices NCI e NCE para a formação de até 5 ZM's. Conforme pode ser observado na Figura 6, o menor valor de NCE foi para C2, que significa divisão da área em duas ZM's. O valor de FPI para C2 foi o maior entre as zonas formas, mas, mesmo assim, obteve resultado satisfatório para o grau de separação entre as duas zonas observadas.



Figura 6. Gráficos de desempenho dos índices fuzzy Normalized Classification Entropy (NCE) e Fuzziness Performance Index (FPI). Esta Figura foi gerada pelo software MZA com dados de variáveis com correlação positiva.

Após finalizado o trabalho com o MZA, as classificações foram carregadas no QGIS para a montagem do mapa com as zonas de manejo. A Figura 7 representa a divisão das ZMs utilizando duas zonas como referência, de acordo com o índice NCE. Observou-se que as zonas não estão bastante juntas, isso pode ser explicado pelo maior valor de FPI, ou seja, as ZMs estão separadas.




Figura 7. Divisão das zonas de manejo geradas a partir de classificações do MZA.

Para observar a similaridade das duas ZMs com a produtividade da área obtida em campo, foi gerado o mapa (Figura 8). Nesta Figura, é possível observar a divisão da área em três grupos: alta, média e baixa produtividade. Observando estes, a partir das cores, têm-se que é similar ao mapa de divisão de ZMs, tendo áreas com maior (acima de 5 t/ha) e outras de menor (abaixo de 3 t/ha) produtividade.




Figura 8. Organização da produtividade na área em estudo, dividida em três classes: baixa, média e elevada produtividade.

DISCUSSÃO

De acordo com EMBRAPA 2018, a temperatura durante o ciclo da cultura foi dentro do indicado para o correto desenvolvimento, temperatura essa de 25 °C em média na maior parte do ciclo.

A superfície da área recebeu similar quantidade de radiação solar e, conseqüentemente, radiação PAR. Isso ocorreu devido a superfície ter relevo suavemente ondulado e exposição à radiação solar incidente semelhante, seja qual for à posição que o sol se encontra. Carneiro et al. (2013), que estudaram o saldo de radiação em cana-de-açúcar para diferentes regiões no Brasil, confirmaram a dependência do albedo (reflexão) em função do ângulo de elevação solar. Segundo estes autores a variação angular de incidência dos raios solares sobre as plantas diverge no saldo de radiação que penetra e é retido, desta forma, diferentes cenários produtivos com dependência geográfica do terreno influenciam no saldo de radiação total pela cultura.

É de grande importância realizar análise do grau de compactação do solo para se obter o manejo adequado, dentre eles, mensurar a profundidade de trabalho, tipo de equipamentos e tempo gasto para as operações, assim, tendo maior controle do ambiente de produção e evita investimentos extras ou que não surtem efeito durante a condução da cultura. Na área em estudo, o parâmetro usado para mensurar a compactação foi a RMSD que, antes do preparo do solo, apresentava valores acima do recomendado para o correto desenvolvimento do

sistema radicular das plantas. Valores acima do recomendado dificultam a captação de água e nutrientes do solo pela cultura, retardando desenvolvimento e não uso dos insumos disponíveis no solo, uma vez que o crescimento das raízes e a produtividade variam de forma inversamente proporcional ao seu valor (FERNANDES *et. al*, 2020).

A FPI mede o grau de imprecisão criado por um número especificado de classes e os valores de FPI podem variar de 0 a 1. Valores próximos a 0 indicam classes distintas com pouco compartilhamento de membros enquanto valores próximos a 1 indicam não há classes distintas com um alto grau de compartilhamento de membros. O NCE é uma estimativa da quantidade de desorganização criada por um determinado número de aulas. O número ideal de clusters para cada computador índice (FPI e NCE) é obtido quando o índice está no mínimo, representando o menor compartilhamento de associação (FPI) e a maior quantidade de organização (NCE) como resultado do processo de agrupamento (Fridgen *et. al*, 2004). Neste estudo, foram selecionadas duas ZMs, mas deve-se continuar as observações de dados e realizar outras análises, como o índice Kappa, por exemplo, para testar a veracidade da divisão formada.

No mapa representativo das ZMs, Figura 7, é possível observar semelhança com a Figura 8, ou seja, locais com as mesmas características têm níveis de produtividade similar. Este artigo foi elaborado apenas com resultados de uma safra. Após a realização deste trabalho, foi conduzida a cultura da cana-de-açúcar. Pode ser que ao analisar os dados de duas safras, as informações tornem-se mais robustas na escolha de locais com as mesmas características de produtividade. Outro ponto a ser observado é que não se havia monitor de produtividade disponível na colhedora de grãos, o que dificulta a visualização da área em parâmetros gerais de produtividade.

Mesmo com os valores obtidos neste estudo, já é possível aplicar a ferramenta para melhorar o manejo e maximizar a capacidade produtiva da cultura nesta área. Espera-se também que o impacto ambiental seja reduzido com a correta utilização de insumos agrícolas, evitando também aumento nos custos de produção.

CONCLUSÕES

A partir dos resultados encontrados neste trabalho, é possível concluir que há heterogeneidade na área em estudo, fazendo com que seja necessário adotar as zonas de manejo para maximizar o manejo da área. Foi possível delinear zonas de manejo utilizando diversas variáveis e analisando-as com a estatística multivariada. Ainda com este trabalho, será quantificado o impacto da utilização das zonas de manejo no retorno ao produtor.

REFERÊNCIAS

Gary Brierley, Xilai Li, Kirstie Fryirs, Jay Gao, Yan Shi, George L.W. Perry, Carola Cullum,

Development of place-based catenal models for grassland ecosystems of the Upper Yellow River, Western China. CATENA, Volume 213, 2022, 106193, ISSN 0341-8162, <https://doi.org/10.1016/j.catena.2022.106193>.

ARSLAN, S., and T. S. COLVIN. 2002. **Grain yield mapping: Yield sensing, yield reconstruction, and errors.** Precision Agriculture 3:135–54.

MOHARANA, P. C., R. K. JENA, U. K. PRADHAN, M. NOGIYA, B. L. TAILOR, R. S. SINGH, AND S. OLDONI, H., V. S. SILVA TERRA, L. C. TIMM, C. R. JÚNIOR, AND A. MONTEIRO, B. 2019. **Delineation of management zones in a peach orchard using multivariate and geostatistical analyses.** Soil and Tillage Research 191:1–10.

GAVIOLI, A., E. G. DE SOUZA, C. L. BAZZI, L. P. C. GUEDES, AND K. SCHENATTO. 2016. **Optimization of management zone delineation by using spatial principal components.** Computers and Electronics in Agriculture 127:302–10.

MOLIN, José Paulo; DO AMARAL, Lucas Rios; COLAÇO, André. Agricultura de precisão. Oficina de textos, 2015.

MORAL, F. J., J. M. TERRÓN, AND J. R. M. D. SILVA. 2010. **Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques.** Soil and Tillage Research 106:335–43.

GAVIOLI, A. E. G. de SOUZA, C.L. BAZZI, K. SCHENATTO, N.M. BETZEK. **Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods.** Biosyst. Eng., 181 (2019), pp. 86-102.

DAMIAN, J.M; A.L. SANTI, M. FORNARI, C.O DA ROS, V.L. ESCHNER. **Monitoring variability in cash-crop yield caused by previous cultivation of a cover crop under a no-tillage system.** *Comput. Electron. Agric.*, 142 (2017), pp. 607-621,

FRAISSE, C.W.; K.A. SUDDUTH, N.R. KITCHEN. **Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity.** *Trans. ASAE (Am. Soc. Agric. Eng.)*, 44 (1) (2001), pp. 155-166.

R. ROSSI, A. POLLICE, G. BITELLA, R. LABELLA, R. BOCHICCHIO, M. AMAT O. **Modelling the non-linear relationship between soil resistivity and alfalfa NDVI: a basis for management zone delineation.** *J. Appl. Geophys.*, 159 (2018), pp. 146-156.

DAMIAN, J.M; O.H. DE C. PIAS, M.R. CHERUBIN, A. Z. DA FONSECA, E.Z. FORNARI, A.L. SANTI. **Applying the NDVI from satellite images in delimiting management zones for annual crops.** *Sci. Agric.*, 77 (1) (2020).

WANG, H.; A.K. MORTENSEN, P. MAO, B. BOELT, R. GISLUM. **Estimating the nitrogen nutrition index in grass seed crops using a UAV-mounted multispectral camera.** *Int. J. Rem. Sens.*, 40 (7) (2019), pp. 2467-2482.

BREUNIG, F.M. L.S. GALVÃO, R. DALAGNOL, C.E. DAUVE, A. PARRAGA, A. L. SANTI, et al. **Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data.** *Int. J. Appl. Earth Obs. Geoinf.*, 85 (2020), p. 102004.

XIN-ZHONG, W., L. GUO-SHUN, H. HONG-CHAO, W. ZHEN-HAI, L. QING-HUA, L. XU FENG, H. WEI-HONG, AND L. YAN-TAO. 2009. **Determination of management zones for a tobacco field based on soil fertility.** *Computers and Electronics in Agriculture* 65:168–75.

TRIPATHI, R., A.K. NAYAK, M. SHAHID, B. LAL, P. GAUTAM, R. RAJA, S. MO HANTY, A. KUMAR, B. B. PANDA, AND R. N. SAHOO. 2015. **Delineation of soil management zones for a rice cultivated area in eastern India using fuzzy clustering.** *Catena* 133:128–36.

VALENTE, D. S. M., D. M. DE QUEIROZ, F. D. A. DE CARVALHO PINTO, N. T. SANTOS, AND F. CONGEDO, L. 2016. *Semi-Automatic Classification Plugin Documentation Release 4.8.0.1. Release.*

ANDRIOLI, I.; CENTURION, J. F. Levantamento detalhado dos solos da Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal. In: **CONGRESSO BRASILEIRO DE CIÊNCIAS DO SOLO**, 27.; 1999, Brasília. **Anais** Brasília: Sociedade Brasileira de Ciência do Solo, 1999.

WARRICK, A. W., AND D. R. NIELSEN. 1980. **Spatial Variability of Soil Physical Properties in the Field**. Applications of Soil Physics.

JOLLIFFE, I.T.; **Principal Component Analysis** (second ed.), Springer, New York (2002) Kassambara, A., and F. Mundt. 2017. Package “factoextra” for R: Extract and Visualize the Results of Multivariate Data Analyses.

EMBRAPA 2018. Boletim agrometeorológico da Embrapa Soja Londrina, PR - 2014

TAYLOR, J. A., A. B. MCBRATNEY, AND B. M. WHELAN. 2007. **Establishing management classes for broadacre agricultural production**. Agronomy Journal

FERNANDES, M. M. H.; COELHO, A. P.; SILVA, M. F. ; BERTONHA, R. S. ; QUEIROZ, R. F. ; FURLANI, C. E. A. ; FERNANDES, C. . **Estimation of soil penetration resistance with standardized moisture using modeling by artificial neural networks**. CATENA, v. 189, p. 1-9, 2020.

Fridgen, J.J., Kitchen, N.R., Sudduth, K.A., Drummond, S.T., Wiebold, W.J., Fraisse, C.W.,

2004. **Management zone analyst (MZA): software for subfield management zone delineation**. Agron. J. 96, 100–108.

MATERIAL SUPLEMENTAR

Tabela 1. Análise descritiva das variáveis disponíveis.

	mean	median	min	max	Assimetria	kurtosis
V2	51.67	51	1	92	0.1	4.06
V3	258.81	263	2	302	-6.32	50.36
V4	679.14	683.5	3	722	-8.77	79.17
V5	18.64	19	4	24	-1.44	6.88
V6	52.53	52.1	5	74.1	-2.59	19.89
V7	68.69	68.78	6	86.5	-4.6	34.18
V8	41.11	40	7	123	1.76	4.91

V9	1.3	1.2	0.9	8	8.26	72.77
V10	9.28	9	7	13	0.69	0.37
V11	36.79	35.7	10	64.1	0.41	4.3
V12	0.79	0.67	0.3	11	8.81	79.49
V13	63.74	64	12	79.33	-2.51	14.76
V14	61.93	63	13	72.67	-3.73	23.67
V15	8.83	8.7	6.26	14	1.23	1.88
V16	95.32	95.67	15	112.33	-4.98	37.72
V17	66.59	67	16	82.33	-3.39	22.51
V18	10.12	9.93	6.92	17	0.98	2.93
V19	97.95	99	18	110.5	-5.39	40.35
V20	68.14	68	19	82	-3.05	18.99
V21	10.77	10.6	7.64	20	1.97	7.29
V22	93.21	94	21	108.5	-4.41	29.99
V23	63.73	63.5	22	85.5	-1.29	2.8
V24	10.45	10.08	7.19	23	2.76	13.22
V25	1.1	0.86	0.81	24	9.33	86.06
V26	1.15	0.9	0.82	25	9.33	86.05
V27	1.1	0.85	0.66	26	9.33	86.01
V28	1.07	0.79	0.68	27	9.33	86.02
V29	1.12	0.84	0.71	28	9.33	86.01
V30	0.98	0.73	0.17	29	9.29	85.5
V31	1.1	0.8	0.74	30	9.33	86.06
V32	1.18	0.86	0.8	31	9.33	86.06
V33	1.05	0.74	0.53	32	9.33	86
V34	1.03	0.68	0.62	33	9.33	86.06
V35	1.07	0.75	0.55	34	9.33	85.96
V36	0.72	0.44	-0.1	35	9.28	85.38

	Yield	Site	Clay	Total sand	MO	CTC	Vk	Fósforo	Potássio	Magnésio	Soma de B Saturação	Height 1	Width 1	Diameter 1	Height 2	Width 2	Diameter 2	Height 3	Width 3	Diameter 3	Height 4	Width 4	Diameter 4	GNDV 1	NDVI 1	NDI 1	GNDV 2	NDVI 2	NDI 2	GNDV 3	NDVI 3	NDI 3	GNDV 4	NDVI 4	NDI 4				
Yield	-0.12																																						
Site	0.25	-0.37																																					
Clay	-0.17	-0.32	-0.72																																				
Total sand	0.23	0.07	0.31	-0.37																																			
MO	0.00	0.19	0.03	-0.20	0.61																																		
CTC	-0.01	0.23	0.00	-0.17	0.43	0.73																																	
Vk	0.07	-0.01	0.14	-0.13	0.29	0.28	0.24																																
Fósforo	0.05	0.06	0.03	-0.03	0.59	0.64	0.53	0.36																															
Potássio - K	0.06	0.14	0.09	-0.19	0.64	0.64	0.78	0.37	0.26																														
Magnésio - l	0.02	0.24	0.02	-0.19	0.56	0.95	0.88	0.27	0.62	0.73																													
Soma de B	-0.16	-0.15	-0.30	0.37	-0.44	-0.30	-0.51	-0.06	-0.05	-0.33	-0.42																												
Saturação d	-0.32	0.20	-0.24	0.13	0.03	0.18	0.26	-0.19	0.11	0.22	0.23	0.00																											
Height 1	-0.15	0.09	-0.11	0.10	0.07	0.15	0.05	-0.05	0.38	0.17	0.12	0.07	0.53																										
Width 1	-0.14	-0.04	-0.10	0.10	-0.09	-0.08	-0.10	-0.22	-0.01	-0.14	-0.10	0.04	0.23	0.13																									
Diameter 1	-0.14	0.15	0.01	-0.10	-0.01	-0.03	-0.01	-0.11	-0.05	-0.12	0.00	0.00	0.51	0.34	0.18																								
Height 2	-0.09	0.22	-0.13	0.05	-0.10	-0.18	-0.13	0.01	-0.16	-0.14	-0.14	0.09	0.21	0.21	0.15	0.38																							
Width 2	-0.19	0.12	-0.35	0.26	0.02	0.12	0.28	-0.05	0.28	0.26	0.20	0.05	0.33	0.07	0.37	0.04	0.14																						
Diameter 2	-0.09	0.00	0.04	0.00	-0.07	-0.02	-0.03	-0.03	-0.13	-0.05	-0.02	0.04	0.21	0.12	-0.16	0.30	0.18	-0.12																					
Height 3	0.12	-0.08	-0.16	0.23	0.15	0.06	0.06	-0.11	0.11	0.06	0.09	0.06	0.09	-0.07	0.12	-0.06	0.06	0.28	-0.20																				
Width 3	0.02	0.07	-0.23	0.20	-0.08	0.04	0.07	-0.15	0.18	0.02	0.06	0.05	0.11	0.12	0.31	-0.04	0.00	0.35	-0.30	0.34																			
Diameter 3	0.03	0.00	0.02	-0.03	-0.10	-0.15	-0.08	-0.13	-0.23	-0.13	-0.13	0.13	0.13	0.09	-0.06	0.41	0.14	-0.14	0.41	-0.10	-0.16																		
Height 4	0.04	-0.26	0.19	0.02	-0.09	-0.15	-0.09	0.06	-0.16	-0.04	-0.13	0.10	-0.06	0.03	-0.14	0.04	0.14	-0.22	0.39	-0.01	-0.11	0.29																	
Width 4	0.03	0.01	-0.12	0.14	-0.01	0.06	0.12	-0.11	0.15	0.05	0.09	0.01	0.16	0.03	0.40	0.15	0.00	0.36	-0.00	0.27	0.36	-0.17	0.00																
Diameter 4	0.20	-0.06	0.14	-0.13	-0.03	-0.07	-0.12	0.03	-0.09	-0.11	-0.11	-0.02	-0.18	-0.18	-0.24	0.16	-0.16	-0.27	0.24	-0.34	0.20	0.05	-0.44																
GNDV 1	0.25	-0.05	0.14	-0.15	-0.06	-0.13	-0.16	0.08	-0.09	-0.13	-0.18	0.02	-0.24	-0.15	-0.24	0.14	-0.19	-0.28	0.19	-0.37	-0.31	0.24	0.09	-0.39	0.93														
NDVI 1	0.25	-0.07	0.16	-0.15	-0.07	-0.17	-0.21	0.06	-0.13	-0.16	-0.22	0.03	-0.28	-0.17	-0.29	0.10	-0.19	-0.32	0.24	-0.38	-0.35	0.23	0.10	-0.45	0.92	0.98													
NDI 1	0.02	0.13	0.29	-0.40	0.11	0.08	0.05	0.23	-0.07	-0.11	0.08	-0.26	-0.16	-0.37	-0.12	0.33	0.01	-0.18	0.12	-0.09	-0.26	0.09	-0.06	-0.04	0.37	0.37	0.37												
GNDV 2	0.01	0.14	0.22	-0.34	0.00	-0.03	0.01	0.21	-0.13	-0.17	-0.01	-0.19	-0.21	-0.41	-0.14	0.28	-0.01	-0.14	0.12	-0.16	-0.27	0.10	-0.06	-0.06	0.40	0.42	0.42	0.95											
NDVI 2	-0.02	0.24	0.24	-0.43	0.04	0.02	0.05	0.27	-0.08	-0.08	0.05	-0.16	-0.14	-0.33	-0.17	0.22	-0.01	-0.11	0.04	-0.19	-0.28	0.02	-0.11	-0.04	0.25	0.26	0.27	0.86	0.93										
NDI 2	0.32	-0.17	0.24	-0.16	-0.11	-0.29	-0.35	0.11	-0.24	-0.21	-0.36	0.06	-0.58	-0.24	-0.39	-0.30	-0.24	-0.46	0.10	-0.37	-0.40	0.06	0.16	-0.47	0.62	0.67	0.74	0.20	0.24	0.17									
GNDV 3	0.35	-0.09	0.20	-0.17	-0.13	-0.27	-0.29	0.08	-0.21	-0.18	-0.33	0.03	-0.49	-0.21	-0.31	-0.20	-0.19	-0.39	0.11	-0.39	-0.33	0.09	0.19	-0.43	0.71	0.75	0.81	0.19	0.24	0.17	0.94								
NDVI 3	0.35	-0.12	0.23	-0.17	-0.12	-0.26	-0.32	0.10	-0.23	-0.21	-0.33	0.05	-0.56	-0.25	-0.38	-0.23	-0.24	-0.46	0.14	-0.38	-0.37	0.11	0.17	-0.49	0.68	0.73	0.85	0.23	0.28	0.21	0.98	0.99							
NDI 3	0.21	0.08	0.06	-0.14	-0.10	-0.09	-0.15	-0.11	-0.14	-0.18	-0.14	0.21	-0.11	-0.01	-0.15	0.07	0.05	-0.25	0.25	-0.21	-0.17	0.30	0.05	-0.23	0.24	0.25	0.34	0.01	0.03	0.02	0.39	0.40	0.44						
GNDV 4	0.32	-0.15	0.28	-0.20	-0.10	-0.24	-0.32	0.11	-0.23	-0.20	-0.31	0.10	-0.60	-0.21	-0.41	-0.34	-0.24	-0.50	0.12	-0.37	-0.38	0.12	0.18	-0.49	0.44	0.49	0.58	0.11	0.15	0.14	0.91	0.83	0.91	0.57					
NDVI 4	0.32	-0.14	0.28	-0.22	-0.09	-0.22	-0.31	0.11	-0.23	-0.19	-0.30	0.09	-0.59	-0.22	-0.41	-0.31	-0.22	-0.50	0.15	-0.38	-0.39	0.13	0.19	-0.50	0.46	0.51	0.60	0.13	0.17	0.15	0.91	0.84	0.91	0.61	1.00				
NDI 4																																							

Spatio-temporal clustering analysis of soil moisture and vegetation indices for zone delineation

Abstract: Site-specific management (SSM) of crop fields could result in high yield, less year-to-year variability, and greater input use efficiency. This SSM results from adjusting inputs to the edaphic and topographic within-field variability. Therefore, the spatial and temporal analysis of soil water content (SWC) and crop growth assessed through spectral vegetation indices (Vis) was used to study within-field variability and delineate management zones (MZs). The research was conducted at a 25 hectare cotton-peanut rotation field located in central-east Alabama, USA. In 2022, data of SWC collected at three soil depths 15, 30 and 60 cm from ten locations within the field was used for the analyses. Data of soil texture and soil electrical conductivity (Soil ECa) was also included into the analyses. Spatial and temporal crop growth clusters were determined using Planet Scope satellite images from mid-July and mid-August of years 2017, 2019 and 2022. The images were used to calculate the GNDVI, MNDI indices and Spatio-Temporal data. A principal component analysis (PCA) was used to identify clusters on the data. Two separate PCA analysis were done, one only with the SWC data and the other with the GNDVI and MNDI indices. Individual PCs were correlated with data of soil texture, TPI and TWI topographic indices, and Soil ECa. The spatial organization the SWC clusters followed the soil texture, soil ECa, and terrain attributes variability. The clusters of only VIs data showed good spatial and temporal correlation with individual Vis for each one of the years of the study. There was agreement among the clusters determined using SWC and VIs with respect to the field areas that exhibited either light and heavy soil texture. These results shows that the field exhibited SWC and crop growth variability and this variability could be grouped on MZs that exhibited different VIs, soil ECa and soil texture characteristics.

Keywords: Principal Components Analysis; Irrigation Management; Spatial and Temporal analysis; Soil water content.

Análise de clustering espaço-temporal de índices de vegetação e umidade do solo para delimitação de zonas de manejo

Resumo: O manejo específico do local (SSM) de áreas agrícolas pode resultar em alto potencial produtivo, menor variabilidade ano a ano e maior eficiência no uso de insumos. Este SSM resulta do ajuste dos insumos à variabilidade edáfica e topográfica dentro da área de cultivo agrícola. Portanto, a análise espacial e temporal do conteúdo de água no solo (SWC) e do crescimento das culturas avaliado através de índices espectrais de vegetação (Vis) foi utilizada para estudar a variabilidade dentro da área e delimitar zonas de manejo (MZs). A pesquisa foi conduzida em um campo de rotação de algodão e amendoim de 25 hectares localizado no centro-leste do Alabama, EUA. Em 2022, dados de SWC coletados em três profundidades de solo de 15, 30 e 60 cm de dez locais do campo foram utilizados para as análises. Dados de textura e condutividade elétrica do solo (ECa do solo) também foram incluídos nas análises. Os clusters espaciais e temporais de crescimento das culturas foram determinados usando imagens de satélite Planet Scope de meados de agosto dos anos de 2017, 2019 e 2022. As imagens foram usadas para calcular os índices GNDVI, MNLI e dados espaço-temporais. Uma análise de componentes principais (PCA) foi usada para identificar clusters nos dados. Foram feitas duas análises separadas de PCA, uma apenas com os dados do SWC e outra com os índices GNDVI e MNLI. Os PCs individuais foram correlacionados com dados de textura do solo, índices topográficos TPI e TWI e CEa do solo. A organização espacial dos clusters SWC seguiu a variabilidade da textura do solo, CEa do solo e atributos do terreno. Os agrupamentos apenas de dados de VIs apresentaram boa correlação espacial e temporal com Vis individuais para cada um dos anos do estudo. Houve concordância entre os clusters determinados usando SWC e VIs em relação às áreas de campo que exibiram textura de solo leve e pesada. Esses resultados mostram que o campo exibiu variabilidade do SWC e do crescimento da cultura e essa variabilidade pode ser agrupada em MZs que exibiram diferentes VIs, CEa do solo e características de textura do solo.

Palavras-chave: Análise de Componentes Principais; Gestão de Irrigação; Análise Espacial e Temporal; Conteúdo de água no solo.

1 Introduction

It is common rural areas still practice conventional agriculture, based on uniform recommendations, without considering the spatial variability of the physical environment. This can result in excessive or reduced application of fertilizers, irrigation, seed rates, which causes high heterogeneity in production and product quality, resulting in low profit for producers and may cause negative environmental impacts. However, the complex interactions between soil attributes, climate and crop conditions make it difficult to establish areas with the same production potential (Moharana et al. 2019).

Based on this, the integration of multiple variables can be the solution for better monitoring of reality in the field (Gavioli et al. 2016). Know these problems, it is understood that the management zones (MZs) are grouped in regions that have little variability for the preparation of specific maps for the application of inputs in each of them (Molin et.al., 2015). MZs are subdivisions of the area with similar characteristics such as soil texture, topography, water status and soil nutrient levels that can be used for variable rate input application (Moral, Terron and Silva 2010). For the delineation of these ZMs, different sets of data can be used, as discussed by Gavioli et al. (2019). Input data for delineation algorithms usually include crop productivity (Damian et al., 2017), topographic metrics (Fraisse et al., 2004) and soil attributes (Rossi et al., 2017).

The local environment and the variations that occur in it are extremely important for decision making and must be considered, using values obtained by volumetric water content (VWC) sensors. VWC can be related to soil texture characteristics remote sensing has also been proposed as a more cost-effective tool to delineate management zones (Damian et al., 2020). Therefore, farmers can take advantage of the repetitive data acquisition and spatial coverage offered by remote sensors to estimate vegetation indices and delineate management zones, saving time and cost of extensive field sampling (Wang et al., 2019; Damian et al., 2020).

To obtain good results in the MZs design, the selection of variables with temporal stability and correlated with crop productivity can be important. Furthermore, considering that most of these variables are usually related to each

other, a principal component analysis (PCA) can be used to summarize these related datasets into a few significant components and observe their division into clusters (Xin-Zhong et al. 2009). Principal component analysis (PCA) scores can be mapped using kriging methods, in the same way as individual attribute values (Goovaerts 1997).

Subsequently, PCA scores can be used to delineate MZs, as suggested in other studies (Oldoni et al. 2019). Being aware of all this information and seeking practical application for Producers in the state of Alabama-US, the objective of this study was to carry out a spatial and temporal analysis of soil water content (SWC) and growth of the cotton crop, evaluated through spectral vegetation index (VIs), to study and interpret variability within the field to delineate possible management zones (MZs).

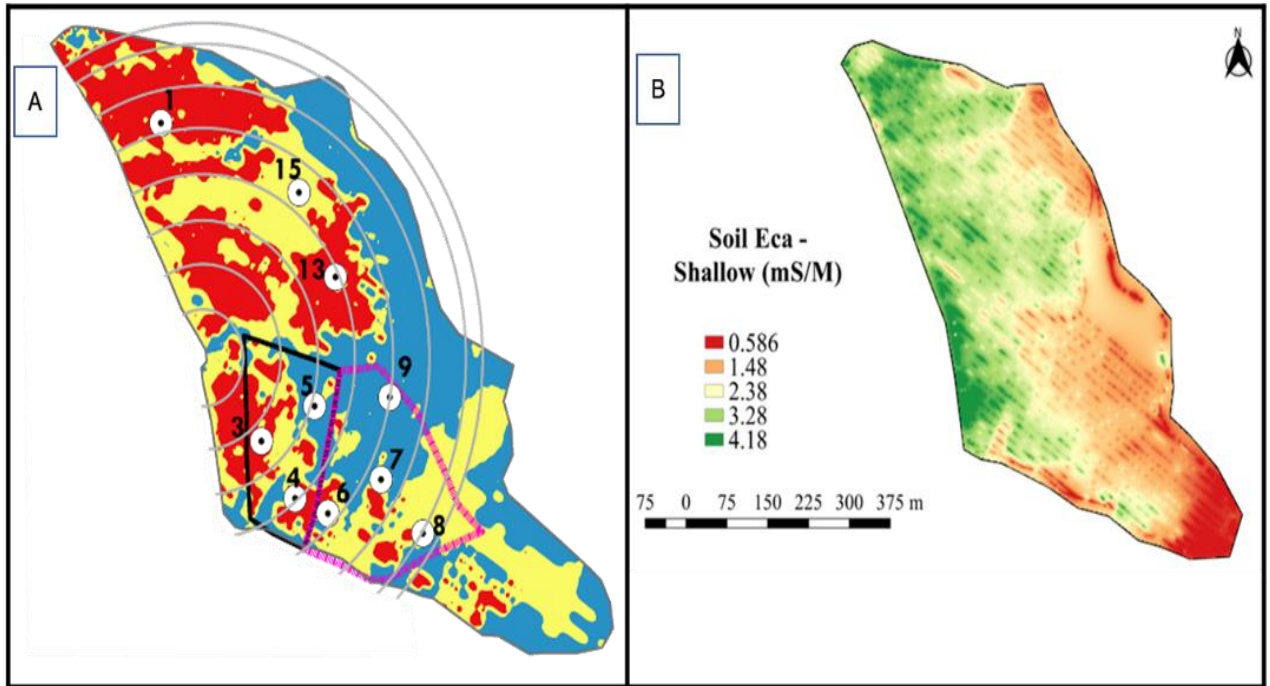
2 Materials and Methods

The research was conducted at a 25 hectare cotton-peanut rotation field located in the Society Hill, central-east Alabama, USA. The commercial irrigated field it is located in 32°25'17" N 85°24'54" W. The climate in the region is subtropical classify. The region has an annual mean temperature of 18°C and annual mean precipitation of 1320 mm. The soil in the experimental field was classified according to the characters the soil texture in 10 representative locations, according to Table 1.

Table 1: Soil properties in 10 Locations the field in percentage collected at 30 cm.

Location	% Sand	% Silt	% Clay	Soil textural class
1	51.8	18.12	30.08	Sandy Clay Loam
3	71.48	10.24	18.28	Sandy Loam Sandy Clay
4	51.76	15.12	33.12	Loam
5	68.92	17.16	13.92	Sandy Loam Sandy Clay
6	61.7	18.16	20.16	Loam
7	63.9	20.0	16.16	Sandy Loam
8	71.4	12.28	16.28	Sandy Loam
9	77.8	10.08	12.16	Sandy Loam Sandy Clay
13	51.8	18.12	30.08	Loam
15	65.5	20.2	14.28	Sandy Loam

Figure 1 (A, B): A- The map represents areas of the field with differences in soil texture and field terrain influence water movement & availability. B- The map represents the Soil Electrical Conductivity Shallow in field. This information can use to delineate areas for VRI.



Soil samples were collected in a predetermined sampling grid, generated according to topographic indices TPI (Topographic Position Index) and TWI (Topographic Wetness Index). Samples were collected within a radius of 20 meters from each central point. The sampling points were georeferenced using the Global Navigation Satellite System (GNSS) navigation receiver. Soil samples at the depths of 15, 30 and 60 cm collected at all locations. Soil electrical conductivity (Soil ECa) was also included into the analyses and data provided by VERIS 3100®.

The irrigation of the field is by Valley center pivot (Valmont Irrigation, Valley Nebraska) irrigation system of 300 meters length and the control is realized about the need of the crop and soil sensors. To monitor the volumetric water content in the field, an integrated digital TDR soil moisture sensor, the Acclima TRUE TDR-315H, recommended for the soil type of the field to provide good precision. Data from the SWC was collected daily, and to standardize the observations, 8 am was chosen for the 3 depths. The exception for the days of collection were on days when there was irrigation and precipitation management, followed by 3 days

after these events. The experiment was used data the 2017-2022. In the years the 2017, 2019 and 2022 was conducted cotton in field. For monitoring and obtaining meteorological data, an automated weather station, Vantage Pro model (Davis Instruments), was used in an area covered by grass. The weather station was installed close the research field. The data was used to monitor temperature and rainfall to support the irrigation schedule.

2.1 Vegetation Indexes

Satellite data for the field were obtain from the Planet Scope satellite for 2017-2022 using the Planet website. The Planet scope sensors are in low-earth sun-synchronous orbits and acquire 12-bit red, green, blue and NIR images with 3.7–4.1 m spatial resolution, depending on the satellite orbit altitude, and the data are distributed resampled to 3 m the 16-bit GeoTIFF images (Planet Team 2020a). The analysis of vegetation indices comprised two collections per year in the years 2017, 2019 and 2022 for cotton, in the middle of August. These periods were chosen because it is a time of greater water demand for the crop for growth and reduced precipitation in the same period, also occurring a greater number of irrigation operations. For this study, two vegetation indices were used: Green Normalized Difference Vegetation Index (GNDVI), described by Gitelson et al., 1996 and Modified Non-Linear Index (MNLI), described by (Gong et al., 2003).

GNDVI, which is quite similar to NDVI, with the difference being that it uses the green instead of the red band, is considered to be more sensitive to changes in chlorophyll-a concentrations compared to NDVI. MNLI modifies NLI and incorporates merits of SAVI. Under conditions of low LAI, where ρ_R is relatively high and ρ_{NIR} relatively low, a small change in ρ_R produces a larger proportional change in NDVI than SR. The four VIs were derived using the four spectral bands provided by Planet's images following the formulations given in Equation 1 and 2.

$$GNDVI = \frac{\rho(\lambda_{NIR}) - \rho(\lambda_{GREEN})}{\rho(\lambda_{NIR}) + \rho(\lambda_{GREEN})}$$

$$MNLI = \frac{\rho(NIR)^2 - \rho(\lambda_{RED}) * (1 + L)}{\rho(NIR)^2 + \rho(\lambda_{RED}) + L}$$

2.2 Spatial and Temporal variability

The spatial variability of the GNDVI and MNDLI was quantified following the method by Basso et al. (2012). The spatial variability of the 2017, 2019 and 2022 GNDVI was calculated from the relative percentage difference of the indices, at each 3 m pixel, average values obtained for the entire cultivated area, according to Equation 3:

$$\sigma_{si}^{-2} = \frac{1}{n} \sum_{k=1}^n \frac{Y_{i,k} - Y_k}{Y_k} \times 100 \quad (3)$$

where n is the total number of years available, k = 1, ..., n is the integer corresponding to each year, σ^2 is the average percentage difference at location i, y_k is the average of the variable obtained for the whole village in year k, $y_{i,k}$ is the variable monitored at location i in year k. Pixels with high values of σ^2 are associated with high throughput (under the assumption that GNDVI is directly proportional to throughput) and pixels with low values are associated with lower throughput. Temporal variability, which is a measure of stability, was calculated as temporal variance to overcome problems with variable stability over time (PRINGLE et al., 2003). The temporal variance of patterns in the GNDVI and MNDLI index data was calculated using Equation 4:

$$\sigma_{ti}^{-2} = \frac{1}{n} \sum_{k=1}^n (Y_{i,k} - Y_{i,n})^2 \quad (4)$$

where σ^2 is the value of the temporal variance at location i, $y_{i,k}$ is the value of the monitored variable at location i in year k, $y_{i,n}$ is the average value of the variable at location i over the n years. The greater the temporal variance, the more unstable the measurement of indices and, therefore, the productivity in these specific locations over time.

Principal component analysis (PCA) was performed to identify clustering and organization trends, in addition to reducing the dimensionality of SWC data and real values, for each year, of vegetation indices. After obtaining the PC's from the SWC data, a correlation analysis was performed with data from the terrain attributes, which were: TWI, TPI, slope, elevation Electrical Conductivity (ECa) shallow and deep, and average the clay, silt and sand the 3 soil depths. Temporal

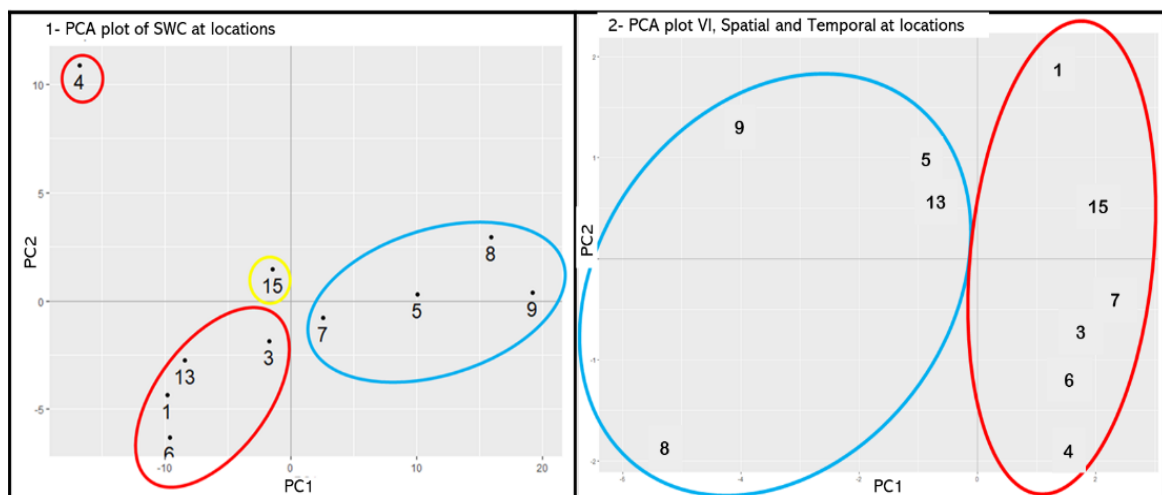
and spatial values were used to identify stable zones within the area, however, the choice of threshold to determine the stable zone can considerably affect the result. To overcome this problem, a similar division of the evaluation sites of the cluster analysis performed for SWC and VIs was used, since in this analysis it makes possible the grouping of similar values and characters.

3 Results and Discussion

Figure 2 presents the principal component analysis for the SWC, VI and Spatio-temporal data. In 2-1, it is possible to observe the organization of water volume data in different locations, which indicates at least two organization trends. Locations 1,3,6, 13 and 15 have similar characteristics in terms of water volume and terrain attributes, as shown in Figure 1A.

The predominant type of soil in these places is Sandy Clay Loam, with a percentage of sand close to 60%. The same organization occurs for the data used in Figure 2-2, the division also occurs with locations 5, 7, 8 and 9 with a predominance of Sandy Loam in the soil textural class with more than 60% Sand. The same can be seen in Figure 1-A. Figure 1-B represents the Soil Eca map. The highest Eca values comprise the part of the field where there is a greater volume of water and similar TPI and TWI topographic indices.

Figure 2 (1, 2): The Figure represents plot clusters analysis. In 1, the data distribution the SWC of the locations. 2 represents cluster for vegetation indexes and Spatio-temporal data.



On Figure 3, the temporal analysis map of the field represents the variance of the vegetation index, the red color represents more stable areas and the darker green color, unstable areas in the years of observation. From the temporal analysis of GNDVI and MNDI (Figure 3(A, B)), it was observed that parts of the field with higher Eca values (3.28-4.18 mS/M), greater amount of water and similar terrain attributes present greater stability for crop development for the analyzed month, not necessarily areas where higher yields occur. These Soil Eca values indicate that, possibly, the plants are not losing water to the soil, instead absorbing water from the soil, which would reduce the absorption of nutrients by the plant. Therefore, there is a greater possibility of yield gain in this part of the field. After observing the maps in Figure 1 and those in Figure 3(A, B), it is possible to obtain more arguments for decision-making about the variability of the studied field.

Figure 3 (A, B, C, D): The Figure represents maps the GNDVI and MNDI in Temporal and Spatial analysis for Mid-August the 2017, 2019 and 2022.

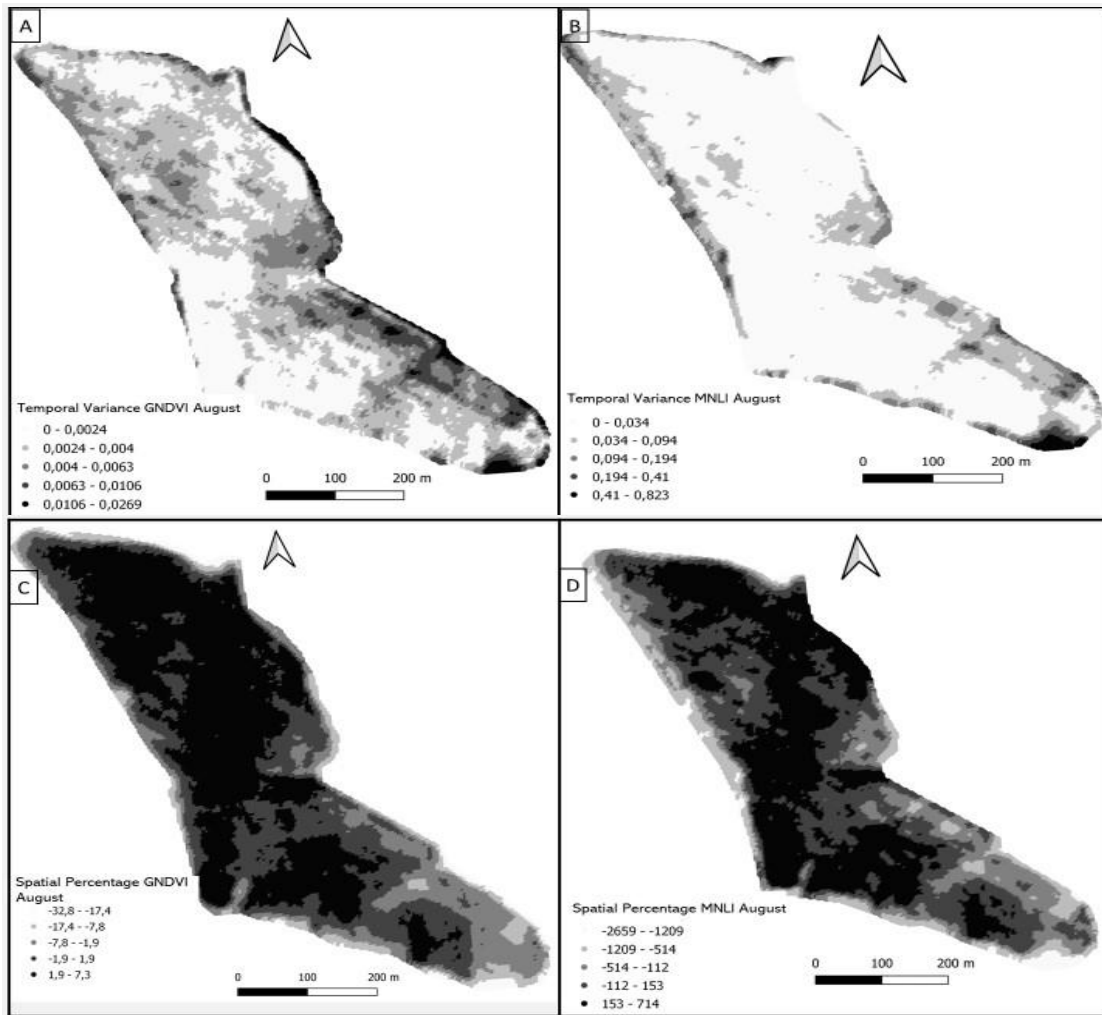


Figure 3(C, D) represents the spatial evaluation maps over the years. Locations in red represent portions of the field with lower vegetation indices and coloration values. Dark represents areas with higher indexes, possibly places with higher yield values. Based on this Figure, it is possible to observe the variability of the field and, comparing the index information with terrain attributes, it is possible to observe the presence of at least two areas with similar characteristics, which can characterize the use of variable rate irrigation in this field, according to the characteristics of soil, water volume and vegetation indices proposed in the analyzes for this work.


3.1 Correlation analysis

PC1 represents the main components for SWC and is positively correlated with sand amount, slope, and temporal analysis. This correlation may indicate

that the greater the volume of water available in the soil, the greater the values of the indices in time and space. It also indicates that the amount of water depends on the amount of sand and the slope of the portion of the land, an interaction that can help or hinder the growth of the crop and, consequently, yield. It was also observed that there is a negative correlation between the amounts of silt and sand, which is expected as the type of soil changes.

A negative correlation was observed in the spatial analysis of the GNDVI and MNLI indices with the amount of sand, SWC, slope and temporal analysis. Regarding the indices, this is correct, because the smaller the variance in the temporal analysis, the greater the vegetation index values in the spatial analysis. As for slope and sand, the higher the value of the slopes, the lower the amount of these two variables. SWC has an inverse correlation with the spatial analysis of the VIs, which may indicate excess water in these portions of the field, since with the difference in slope and soil with a greater amount of sand, the movement of water in the soil occurs more quickly, which can generate accumulation in the part with less slope. For ECa, a positive correlation was observed with GNDVI spatial, which states that places with higher ECa values also have a higher index value.

Figure 4: The Figure represents the correlation analysis the soil terrain attributes, GNDVI, MNLI, Temporal and Spatial analysis for Mid-August the 2017, 2019 and 2022.



The greater water availability can influence the organic matter content in the evaluated soil layer, causing a negative correlation with ECa. The results of several studies have consistently shown that the increase in water content with the addition of organic matter is greater at field capacity than at permanent wilting point (Obour et al., 2018). This effect is most pronounced for sandy soils with 0-20% clay and becomes smaller from 20 to 40% clay and insignificant when clay is greater than 40% (Minasny and McBratney, 2018). This discussion is important to understand the variability the field and define the variable rate irrigation.

4 Conclusions

From the spatial and temporal analysis, it was possible to identify areas in the field where similar behavior occurs in terms of terrain attributes, water volume and crop growth by vegetation indices. It is possible to divide the field into two management zones, thus being able to vary the amount of applied water and inputs. This work need continue also need to observe the yield maps of this field, new vegetation index to verify the agreement of the analyzes.

5 Acknowledgements

Funding for this project was provided by the Alabama Soil and Water Conservation Committee, Alabama Agricultural Experiment Station, and NRCS.

6 References

Gavioli, A., E. G. de Souza, C. L. Bazzi, L. P. C. Guedes, And K. Schenatto. 2016. **Optimization of management zone delineation by using spatial principal components**. Computers and Electronics in Agriculture 127:302–10.

Moharana, P. C., R. K. Jena, U. K. Pradhan, M. Nogiya, B. L. Tailor, R. S. Singh, And S. Oldoni, H., V. S. Silva Terra, L. C. Timm, C. R. Júnior, And A. Monteiro, B. 2019. **Delineation of management zones in a peach orchard using multivariate and geostatistical analyses**. Soil and Tillage Research 191:1–10.

Gavioli, A. E.G. De Souza, C.L. Bazzi, K. Schenatto, N.M. Betzek. **Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods**. Biosyst. Eng., 181 (2019), pp. 86-102.

Molin, José Paulo; Amaral, Lucas Rios Do; Colaço, André Freitas. Unidades De Gestão Diferenciada. In: Molin, José Paulo; Amaral.

Breunig, F.M. L.S. Galvão, R. Dalagnol, C.E. Dauve, A. Parraga, A.L. Santi, et al. **Delineation of management zones in agricultural fields using cover–crop biomass estimates from PlanetScope data**. Int. J. Appl. Earth Obs. Geoinf., 85 (2020), p. 102004.

Damian, J.M; O.H. De C. Pias, M.R. Cherubin, A. Z. Da Fonseca, E.Z. Fornari, A.L. Santi. **Applying the NDVI from satellite images in delimiting management zones for annual crops**. Sci. Agric., 77 (1) (2020).

Damian, J.M; A.L. Santi, M. Fornari, C.O. Da Ros, V.L. Eschner. **Monitoring variability in cash-crop yield caused by previous cultivation of a cover crop under a no-tillage system**. Comput. Electron. Agric., 142 (2017), pp. 607-621,

Fraisse, C.W.; K.A. Sudduth, N.R. Kitchen. **Delineation of site-specific management zones by unsupervised classification of topographic attributes and soil electrical conductivity**. Trans. ASAE (Am. Soc. Agric. Eng.), 44 (1) (2001), pp. 155-166.

Fraisse, C.W.; 2004. **Management Zone Analyst (MZA)**. Agronomy Journal

Moral, F. J., J. M. Terrón, And J. R. M. D. Silva. 2010. **Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques.** Soil and Tillage Research 106:335–43

R. Rossi, A. Pollice, G. Bitella, R. Labella, R. Bochicchio, M. Amato. **Modelling the non-linear relationship between soil resistivity and alfalfa NDVI: a basis for management zone delineation.** J. Appl. Geophys., 159 (2018), pp. 146-156.

Wang, H.; A.K. Mortensen, P. Mao, B. Boelt, R. Gislum. **Estimating the nitrogen nutrition index in grass seed crops using a UAV-mounted multispectral camera.** Int. J. Rem. Sens., 40 (7) (2019), pp. 2467-2482.

Xin-Zhong, W., L. Guo-Shun, H. Hong-Chao, W. Zhen-Hai, L. Qing-Hua, L. Xu Feng, H. Wei-Hong, And L. Yan-Tao. 2009. **Determination of management zones for a tobacco field based on soil fertility.** Computers and Electronics in Agriculture 65:168–75.

Goovaerts, P., 1997. **Geostatistics for natural resources evaluation, Geostatistics for natural resources evaluation.**

Obour et al., 2018

P.B. Obour, J.L. Jensen, M. Lamandé, C.W. Watts, L.J. Munkholm **Soil organic matter widens the range of water contents for tillage.** Soil Till. Res., 182 (2018), p. 57

Minasny and Mcbratney, 2018 B. Minasny, A.B. Mcbratney. **Limited effect of organic matter on soil available water capacity.** Eur. J. Soil Sci., 69 (2018), pp. 39-47

CAPÍTULO 4 – Considerações finais

O aumento da produtividade das culturas é impulsionado pelo gerenciamento das atividades desenvolvidas no campo, visando a otimização do processo produtivo e é ferramenta indispensável para o desenvolvimento sustentável dos sistemas de cultivo, pois, com atividades pensadas, ocorrerá redução do desperdício de insumos, mão de obra e incremento positivo para o meio-ambiente. Isso impacta diretamente no retorno financeiro.

Para se conseguir que a produção seja sustentável, exige-se que haja análise das necessidades das culturas e a verificação do ambiente. O aumento da produtividade da cana-de-açúcar foi possível devido à adoção de tecnologias modernas proporcionadas pela ciência, a exemplo da melhoria de variedades, adubos com liberação lenta de nutrientes, estudo do ambiente para alocação de variedades, da correção e da fertilização adequada do solo, técnicas de manejo integrado de plantas invasoras e pragas.

O uso da tecnologia aliado ao conhecimento dos profissionais de campo auxilia na assertividade do manejo e o torna mais eficaz. Em pequenas propriedades, a tecnologia ainda está pouco distante da realidade, mas, em grandes corporações, a tecnologia de ponta é destaque e utilizada em quase todos os processos. Entender como funciona e o que há disponível no ambiente é ferramenta para obter sucesso no desenvolvimento das culturas. Sendo assim, metodologias para definir áreas de mesmo potencial produtivo são importantes para facilitar a localização destas áreas.

Com os resultados obtidos neste trabalho, notou-se que é possível utilizar diferentes variáveis para definir áreas de mesmo potencial e que ferramentas de análise multivariada auxiliam na seleção dos atributos.