

Delimitação de unidades de gestão diferenciada para o cultivo da cana-de-açúcar na região de Barretos (São Paulo) a partir de índices espectrais e altimetria obtidos por sensoriamento remoto orbital

Leandro Marchetti Stevanato¹, Eduardo Pinheiro de Freitas^{2*}

¹Bacharel em Agronomia, Instituto Federal de São Paulo, Brasil.

²Doutor em Agronomia, Professor no Instituto Federal de São Paulo, Brasil. (*Autor correspondente: eduardo.freitas@ifsp.edu.br)

Histórico do Artigo: Submetido em: 02/02/2022 – Revisado em: 27/02/2022 – Aceito em: 28/03/2022

RESUMO

A cana-de-açúcar tem forte influência na economia brasileira e demanda constantes investimentos em pesquisa de técnicas de agricultura de precisão. O objetivo deste trabalho foi aplicar algumas destas técnicas para delimitação de unidades de gestão diferenciada (UGDs), em uma área cultivada com cana-de-açúcar na região de Barretos (São Paulo), utilizando como atributos dados de relevo e índices espectrais, obtidos a partir da SRTM e de imagens da missão Sentinel-2, respectivamente. Uma rotina em JavaScript foi desenvolvida e utilizada no ambiente interativo Code Editor da plataforma Google Earth Engine para obtenção e processamento destes dados, resultando em uma malha de pontos georreferenciados com os valores de cada atributo, sendo que para os índices espectrais, por se tratar de uma coleção de imagens com diferentes datas, o valor atribuído a cada ponto foi o maior para a posição e para o atributo. Tais malhas foram processadas para verificação das correlações e posterior formação de agrupamentos, a partir dos quais foram obtidas diferentes configurações de UGDs quanto aos níveis de alto, médio e baixo potencial produtivo, que foram analisadas graficamente a fim de identificar quais contemplavam, de forma satisfatória, os diversos atributos existentes e a viabilidade de manejo da área. Selecionada a configuração considerada mais adequada, sua representação gráfica foi editada para aprimoramento da delimitação final das UGDs. A metodologia proposta foi considerada adequada, possibilitando obter e processar dados atualizados em grande quantidade de forma rápida e gratuita, bem como a visualização de diferentes cenários, facilitando a tomada de decisão.

Palavras-Chaves: Zonas de Manejo, SRTM, Sentinel, Google Earth Engine.

Delimitation of management zones for the cultivation of sugarcane in the region of Barretos (São Paulo) based on spectral indices and altimetry obtained by orbital remote sensing

ABSTRACT

Sugarcane has a strong influence on the Brazilian economy and demands constant investments in research into precision agriculture techniques. The objective of this work was to apply some of these techniques for the delimitation of management zones, in an area cultivated with sugarcane in the region of Barretos (São Paulo), using as attributes relief data and spectral indices obtained from SRTM and Sentinel-2 missions, respectively. A JavaScript routine was developed and used in the Code Editor interactive environment (Google Earth Engine platform) to obtain and process this data, resulting in a mesh of georeferenced points with the values of each attribute, and for the spectral indices, as they are a collection of images with different dates. The value assigned to each point was the highest for the position and for the attribute. Such meshes were processed to verify correlations and subsequent formation of clusters, from which different configurations of management zones were obtained regarding the levels of high, medium and low productive potential, which were graphically analyzed in order to identify which ones contemplated, in a satisfactory way, the various existing attributes and the feasibility of managing the area. After selecting the configuration considered most adequate, its graphic representation was edited to improve the final delimitation of the management zones. The methodology was adequate, making it possible to obtain and process updated data in large amounts quickly and free of charge, as well as the visualization of different scenarios, facilitating the decision-making.

Keywords: Management Zones, SRTM, Sentinel, Google Earth Engine.

Stevanato, L. M., Freitas, E. P. de (2022). Delimitação de unidades de gestão diferenciada para o cultivo da cana-de-açúcar na região de Barretos (São Paulo) a partir de índices espectrais e altimetria obtidos por sensoriamento remoto orbital. *Revista Brasileira de Sensoriamento Remoto*, v.3, n.1, p. 15-35.



1. Introdução

A produção de cana-de-açúcar no Brasil tem destaque global. O país lidera o ranking mundial de produção e área plantada, com 654,5 milhões de toneladas produzidas em 8.616.130 hectares na safra 2020/21, o que resulta em uma produtividade de 75,96 toneladas por hectare, demonstrando a importância da cultura na economia do país. Grande parte dessa produção se deve ao estado de São Paulo, respondendo por 54,1% da produção e 51,6% da área plantada na safra 2020/21, no qual localiza-se a região abrangida pelo Escritório de Desenvolvimento Rural de Barretos, com o terceiro maior valor da produção agropecuária de 2020 e com a cana-de-açúcar representando 55,7% deste valor. (Nachiluk, 2021; Companhia Nacional de Abastecimento, 2022; Silva *et al.*, 2021).

Assim como acontece com as demais produções vegetais, principalmente com a produção das chamadas grandes culturas onde a cana-de-açúcar tem forte influência, a busca pela intensificação e sustentabilidade do seu sistema de produção traz desafios cada vez maiores para a pesquisa e extensão rural quanto aos aspectos agronômicos, econômicos, sociais, culturais e para as políticas públicas (Embrapa, 2018).

Neste cenário, a Embrapa (2018) considera que a utilização dos procedimentos relacionados à agricultura de precisão, como o emprego de sensores e imagens de satélite de alta resolução, possibilita a identificação de locais de produção mais adequados para culturas e variedades específicas, além de indicar níveis de produtividade e necessidade de manejos específicos nos talhões.

Massruhá *et al.* (2020) consideram que dados disponíveis a partir de sensores, proximais ou remotos, abrem possibilidades de monitoramento em tempo real das lavouras, otimizando seu manejo. Comentam que isso pode ser feito a partir de índices espectrais de vegetação, dentre outros, indicando condições de manejo, como época de plantio, área plantada e vigor vegetativo, além de sintetizar o vigor da vegetação ao longo do desenvolvimento de uma cultura agrícola. Esses autores comentam também que, no âmbito da agricultura de precisão, o gerenciamento pode se dar a partir de zonas de manejo, também conhecidas como unidades de gestão diferenciada (UGDs), obtidas utilizando-se preferencialmente de atributos relacionados à formação do solo e à cultura, como o relevo e índices de biomassa, dentre outros, com a produtividade histórica utilizada para embasar a delimitação das UGDs.

Dentro do contexto dos supracitados autores, ao se fazer uma pesquisa dos índices espectrais propostos, a plataforma IDB (Index DataBase) desenvolvida por Henrich *et al.* (2009) e disponibilizada no endereço www.indexdatabase.de apresenta 519 índices para diversas aplicações. Dentre os índices de vegetação existentes destacam-se alguns mais difundidos e estudados na agricultura de precisão, como o NDVI – *Normalized Difference Vegetation Index* (Rouse Jr., 1974), o GNDVI – *Green Normalized Difference Vegetation Index* (Gitelson, Kaufman & Merzlyak, 1996), o SAVI – *Soil-Adjusted Vegetation Index* (Huete, 1988), o OSAVI – *Optimized Soil-Adjusted Vegetation Index* (Rondeaux, Steven & Baret, 1996), o VARI – *Visible Atmospherically Resistant Index* (Gitelson *et al.*, 2002) e o EVI – *Enhanced Vegetation Index* (Huete *et al.*, 2002), dentre outros, além de índices mineralógicos como o CMR – *Clay Minerals Ratio* (Alasta, 2011) e o SCI – *Soil Composition Index* (Al-Kaier, 2003). Segundo Huete, Justice e Liu. (1994), apesar dos índices apresentarem diferentes resultados para o mesmo alvo, todos apresentam metodologias tecnicamente adequadas.

Diversas são as missões espaciais compostas por satélites de monitoramento que disponibilizam suas bases de dados gratuitamente, dentre as quais têm destaque a CBERS – *China-Brazil Earth Resources Satellite*, a LANDSAT – *Land Remote Sensing Satellite* e a Sentinel, sendo que nesta última se destacam os satélites Sentinel-2A e Sentinel-2B, que em conjunto fornecem imagens com período de revisita de 5 dias e com resolução espacial de 10 metros para as bandas RGB e NIR e 20 metros para duas bandas SWIR (Embrapa Territorial, 2018), bastante adequadas para o trabalho com índices espectrais.

Quanto à utilização de dados de relevo na definição das UGDs, algumas bases disponibilizam gratuitamente modelos numéricos de elevação com abrangência quase total do planeta Terra, em especial a

referente à SRTM da NASA, com malhas de 3" e de 1" de grau (EMBRAPA TERRITORIAL, 2018). A partir desse e de outros modelos disponíveis, que disponibilizam a altitude de pontos conforme uma malha de levantamento, torna-se possível obter informações derivadas, como inclinação e exposição, ou orientação, das vertentes, também importantes na análise dos atributos para definição das unidades de gestão diferenciada.

Um fator que dificulta e por vezes inviabiliza a utilização destas bases de dados, provenientes principalmente de imagens de satélites de alta resolução, é a enorme capacidade de processamento computacional necessária. Uma opção que tem se tornado mais acessível é a computação em nuvem, destacando-se a plataforma interativa Google Earth Engine (GEE), definida como um serviço de processamento geoespacial em escala que emprega a Google Cloud Platform. O GEE combina um catálogo de vários petabytes de imagens de satélite e conjuntos de dados geoespaciais, com recursos de análise em escala planetária (Gorelick *et al.*, 2017). Tanto a missão Sentinel quanto a SRTM estão disponíveis no GEE.

Buscando aglutinar essas informações, objetivou-se com este trabalho empregar índices espectrais de vegetação e de mineralogia, bem como dados de relevo, ambos obtidos a partir de sensoriamento remoto orbital e processados na plataforma Google Earth Engine para delimitar unidades de gestão diferenciada na cultura da cana-de-açúcar em área na região de Barretos, estado de São Paulo.

2. Material e Métodos

Objetivando delimitar as unidades de gestão diferenciada (UGDs) na cultura da cana-de-açúcar, de forma que a análise e interpretação dos dados provenientes do sensoriamento remoto pudessem ser feitas adequadamente, buscou-se uma área cultivada com cana-de-açúcar e histórico de uso do solo estável, além de uma extensão na faixa de 500 a 1000 hectares e localizada na região de Barretos (São Paulo), que permitisse a ocorrência de variabilidade nas condições da cultura. Dessa forma, a partir do software *Google Earth Pro* e da plataforma *Google Earth Engine* fez-se uma varredura que possibilitou identificar e selecionar uma área que contemplasse estas especificidades, apresentando uma constância em termos de uso do solo desde abril de 2019, compreendendo duas glebas vizinhas, conforme delimitadas com traço azul na Figura 1.

Figura 1 – Localização da área escolhida e suas glebas nas proximidades da cidade de Barretos.



Fonte: imagem gerada e salva pelo autor a partir do software Google Earth Pro.

Tais glebas encontram-se separadas por uma área de preservação permanente e cultivadas com cana-de-açúcar, aparentemente de uma cultivar única, com plantio em área total realizado a partir do último decêndio de abril até o segundo decêndio de junho de 2019, primeira colheita realizada a partir do último decêndio de abril até o segundo decêndio de maio de 2020 e segunda colheita realizada a partir do último decêndio de abril

até o segundo decêndio de maio de 2021. Uma das glebas tem uma extensão de 131 ha e a outra uma extensão de 627 ha, totalizando 758 ha, localizadas junto ao cruzamento das rodovias Brigadeiro Faria Lima e Assis Chateaubriand, no município de Barretos (20°31'33,2" S 48°37'03,7" W).

Para início dos trabalhos de delimitação das UGDs definiram-se os atributos a serem utilizados, agrupados em índices espectrais de vegetação e de mineralogia, bem como as informações de relevo, no caso altimetria e exposição. Referente aos índices espectrais, foram escolhidos alguns dos mais difundidos e capazes de abranger todas as bandas do visível (R – Red; G – Green; B – Blue) e do infravermelho (NIR – Near Infrared; SWIR1 – Short Wave Infrared 1; SWIR2 – Short Wave Infrared 2), conforme as equações 1 a 8 abaixo. Para os índices de vegetação selecionou-se: NDVI, GNDVI, SAVI, OSAVI, VARI e EVI. Para os índices de mineralogia selecionou-se: CMR e SCI.

$$NDVI = \frac{NIR-R}{NIR+R} \quad (1)$$

$$GNDVI = \frac{NIR-G}{NIR+G} \quad (2)$$

$$SAVI = (1+L) \frac{NIR-R}{NIR+R+L} \quad (3)$$

$$OSAVI = 1,16 \frac{NIR-R}{NIR+R+0,16} \quad (4)$$

$$VARI = \frac{G-R}{G+R-B} \quad (5)$$

$$EVI = 2,5 \frac{NIR-R}{NIR+6R-7,5B+1} \quad (6)$$

$$CMR = \frac{SWIR1}{SWIR2} \quad (7)$$

$$SCI = \frac{SWIR2-NIR}{SWIR2+NIR} \quad (8)$$

A equação (8) utiliza SWIR1 originalmente. Contudo, no presente estudo foi adotada a banda SWIR2 em sua substituição, buscando enfatizar a presença de minerais de argila.

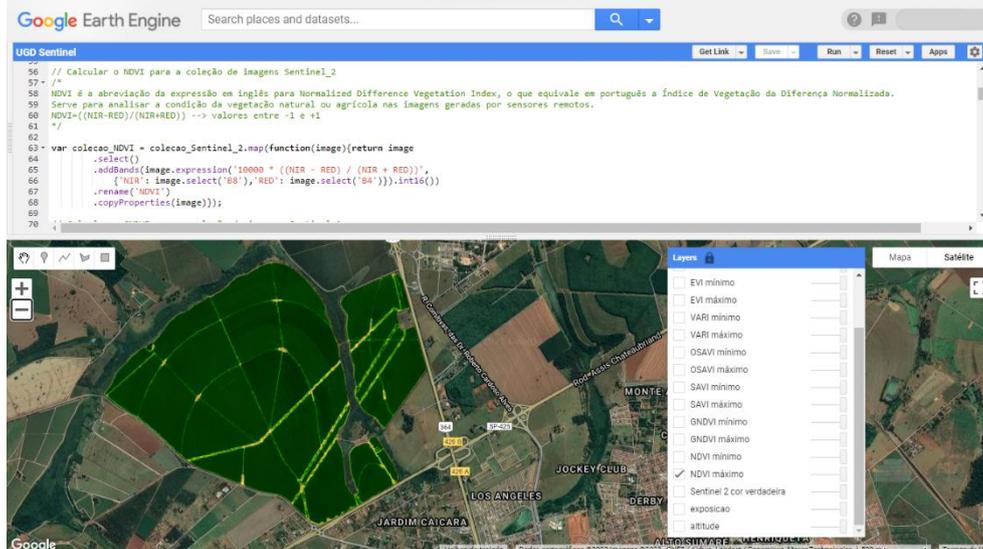
Como fonte de informação para os dados de relevo, utilizou-se o sensor remoto orbital da missão espacial SRTM – Shuttle Radar Topography Mission, realizada no ano de 2000 a bordo da nave Endeavour, o

qual permitiu obter os valores de altitude e exposição, com resolução espacial de 1” de grau (Embrapa Territorial, 2018).

Para a obtenção dos índices de vegetação e de mineralogia foram utilizadas imagens dos satélites da missão Sentinel-2, pertencente ao programa da ESA – *European Space Agency*, lançados justamente com o propósito de monitoramento de vegetação, possuindo para as bandas espectrais utilizadas, sensores com resolução espacial de 10 metros (R – banda 4; G – banda 3; B – banda 2; NIR – banda 8) e de 20 metros (SWIR1 – banda 11; SWIR2 – banda 12), com revisita a cada 5 dias. (Embrapa Territorial, 2018).

Todas as imagens foram obtidas e processadas na plataforma Google Earth Engine (GEE) a partir do ambiente interativo *Code Editor* (Figura 2), utilizando rotina em *JavaScript*.

Figura 2 – Tela do ambiente interativo Code Editor da plataforma GEE, com a janela de edição JavaScript acima.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Do supracitado processamento foram obtidos os valores de relevo (altitude e exposição) com resolução espacial de 1” de grau, os índices de vegetação (NDVI, GNDVI, SAVI, OSAVI, VARI e EVI) com resolução espacial de 10 metros e os índices de mineralogia (CMR e SCI) com resolução espacial de 20 metros, resultando em 74.914 pontos de índices de vegetação, 18.724 pontos de índices de mineralogia e 8.403 pontos de altitude e exposição, todos geoposicionados.

As imagens Sentinel-2 selecionadas abrangeram um intervalo de tempo desde 31 de março de 2019 até 31 de outubro de 2021, representando um total de 190 revisitações, ou 190 imagens. Contudo, em função da possível presença de nuvens, encobrendo parcialmente ou totalmente a área em estudo, um filtro foi aplicado de forma a manter apenas as imagens com cobertura de nuvens em uma proporção menor do que 1% do número de pixels da imagem em sua dimensão original.

Por se tratar de uma coleção com uma dada quantidade de imagens Sentinel-2, o que resulta em uma coleção de mesma quantidade de valores de cada um dos índices espectrais estudados para uma mesma coordenada geográfica, apenas o maior valor em cada coleção foi selecionado para representar o respectivo índice na referida coordenada.

O supracitado intervalo de tempo representa duas safras de cana-de-açúcar com ciclo de 12 meses, desde abril de 2019 até maio de 2021. As imagens Sentinel-2 selecionadas antes e depois das duas safras ilustram condições de solo sem vegetação e de rebrota, sendo mantidas visando contribuir para o cálculo dos índices CMR e SCI, especificamente.

Devido à presença de carregadores delimitando os talhões internamente às glebas, estes foram expurgados do processamento para todos os índices de vegetação, utilizando os dados de EVI como máscara, resultando em 66.765 pontos para definição da malha utilizada na krigagem dos dados de CMR, SCI, altitude e exposição.

Para realização da krigagem utilizou-se o software VESPER 1.6 – *Variogram Estimation and Spatial Prediction with Error* (Minasny, McBratney, & Whelan, 2002), desenvolvido pelo *Australian Centre for Precision Agriculture, The University of Sydney*, onde obteve-se previamente os variogramas ajustados para os referidos atributos, obtendo-se então 66.765 pontos para todos os atributos – vegetação, mineralogia e relevo – que foram normalizados, emparelhados e importados no software MZA 1.0 – *Management Zone Analyst* (Fridgen *et al.*, 2004), do *Agricultural Research Service, U.S. Department of Agriculture (USDA)*, a fim de calcular e verificar o grau de correlação entre atributos importados.

De tais correlações, as melhores foram selecionadas para compor novos agrupamentos que, processados novamente no MZA e analisados quanto à sua representação gráfica para uma configuração de três níveis de potencial produtivo: alto, médio e baixo, resultaram nas unidades de gestão diferenciada propostas para a área estudada.

3. Resultados e Discussão

A partir da delimitação da área selecionada no ambiente interativo Code Editor da plataforma GEE (Figura 3), que restringiu o processamento ao conteúdo das imagens interno ao limite definido pela linha azul, bem como o filtro para nuvens, restringindo o uso de imagens com no máximo 1% de cobertura e resultando em 54 imagens viáveis, foi possível obter as visualizações referentes a cada um dos atributos.

Figura 3 – Delimitação da área selecionada no GEE.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Tais visualizações são formadas de acordo com o valor calculado do índice em cada um dos pixels que as compõem. Desta forma, verifica-se na Figura 4 a distribuição espacial na área selecionada dos valores do NDVI, conforme a paleta de cores apresentada no canto inferior esquerdo da figura, indicando menores valores de vigor vegetativo nos tons mais à esquerda (marrom), com um mínimo de 0,1499, e maiores valores de vigor vegetativo nos tons mais à direita (verde), com um máximo de 0,8729.

Alface *et al.* (2019), analisando o comportamento espectral da cana-de-açúcar em condições de irrigação por pivô central, observaram valores de NDVI variando de 0,2 ao início do ciclo fenológico até 0,8 na condição de máximo desenvolvimento vegetativo. Ao se comparar tais valores com os do presente estudo, apenas 14% dos pixels apresentam valores menores do que 0,8, enquanto que apenas 0,06% dos pixels apresentam valores menores do que 0,2. Contudo, os baixos valores representam, possivelmente, a interferência dos carregadores e falhas nas linhas de plantio.

Figura 4 – Distribuição espacial dos valores do NDVI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Observa-se nesta Figura 4 que a distribuição espacial dos valores de NDVI não é homogênea, apresentando talhões com valores maiores (verde mais escuro) e talhões com valores menores (verde mais claro), bem como há a percepção de falhas nas linhas de plantio, com a presença de linhas vizinhas com tonalidades diferentes de verde.

Uma diferenciação semelhante à do NDVI pode ser notada na Figura 5, referente ao GNDVI. Esta, porém, apresentou tons ligeiramente mais contrastantes, embora representando uma menor faixa de valores (mínimo de 0,4133 e máximo de 0,7920), possivelmente por se tratar de um índice mais sensível às variações da clorofila.

Figura 5 – Distribuição espacial dos valores do GNDVI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Machado e Lamparelli (2007), estudando a resposta espectral da cana-de-açúcar em imagens orbitais, observaram que o GNDVI foi um dos índices com melhor correlação com a produtividade, além de apresentar valores mais constantes comparativamente ao NDVI, dando a impressão de atingimento da saturação, o que está condizente com a menor faixa de variação observada no presente estudo.

A Figuras 6, referente ao SAVI e a Figura 7, referente ao OSAVI, apresentam-se praticamente idênticas ao NDVI, o que pode ser explicado pela baixa ou quase nula interferência do solo no cálculo do NDVI, visto que ambos os índices visam corrigir esses efeitos e que a cobertura vegetal se mostrou bastante efetiva, uma vez que apenas 2% dos pixels resultaram em valores de NDVI abaixo de 0,5, o que corresponderia ao limite inferior para caracterizar uma cobertura vegetal densa.

Figura 6 – Distribuição espacial dos valores do SAVI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Figura 7 – Distribuição espacial dos valores do OSAVI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Esteves *et al.* (2012), estudando o albedo, NDVI e SAVI durante o ciclo da cana-de-açúcar no Norte Fluminense, observaram que tanto o NDVI quanto o SAVI acompanharam a interação entre índice de área foliar e albedo, com correlações muito próximas (0,96 e 0,94 respectivamente). O SAVI teve como valores extremos um mínimo de 0,2248 e um máximo de 1,3092, enquanto o OSAVI teve um mínimo de 0,1739 e um máximo de 1,0125.

Na imagem gerada referente ao VARI e apresentada na Figura 8, é possível verificar que as diferenças ficaram menos evidentes comparativamente às apresentadas pelos índices anteriores, observando-se um nível de ruído relativamente maior nos pixels da imagem, possivelmente devido à característica deste índice em buscar corrigir a iluminação e os efeitos da atmosfera. Seus valores variaram desde um mínimo de -0,3999 até um máximo de 0,5099.

Figura 8 – Distribuição espacial dos valores do VARI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Susantoro *et al.* (2018), ao analisarem alguns índices de vegetação que pudessem ser utilizados no mapeamento de áreas cultivadas com cana-de-açúcar na Indonésia, chegaram à conclusão de que o VARI impossibilitou a obtenção de um retrato significativo das anomalias nesses cultivos. Justificam tal conclusão comentando que o baixo desvio padrão observado representa valores de VARI relativamente uniformes, fazendo com que tais anomalias não sejam evidenciadas, o que ratifica o resultado referente a este índice obtido no presente estudo.

O EVI (Figura 9), assim como o VARI, apresentou um nível de ruído maior nos pixels, representando uma maior dispersão dos valores, o que pode ser explicado pelo método de cálculo semelhante dos índices, em que ambos visam corrigir os efeitos da atmosfera utilizando a banda azul. Além disso, o EVI também mitiga as interferências do solo, que foi considerada de baixo impacto na área estudada, sendo que seus valores tiveram um mínimo de 0,1681 e um máximo de 2,9302.

Xin *et al.* (2020), ao estudarem a produção primária bruta de cultivos de cana-de-açúcar em uma área no município de Luiz Antonio, estado de São Paulo, a partir de imagens MODIS, dentre outros assuntos, comentam que obtiveram resultados indicando haver uma relação linear entre a produção primária bruta e o EVI, com r^2 de 0,68, enquanto que a mesma relação para o NDVI o valor de r^2 foi de 0,52, ligeiramente inferior à anterior.

Figura 9 – Distribuição espacial dos valores do EVI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

A Figura 10 apresenta o comportamento do CMR, que juntamente com o SCI buscam representar a variabilidade do solo. Visualmente observa-se um serrilhado mais aparente do que nas demais imagens, isso em função da resolução espacial das bandas do infravermelho de ondas curtas SWIR1 e SWIR2, presentes nas equações de ambos os índices, ser de 20 metros.

A interpretação que se pretende para o CMR é a de que quanto menor o valor que este índice alcança, maior o teor de argila do solo e menor seu teor de areia. Consequentemente, valores mais elevados de CMR seriam um indício de menores teores de argila e maiores teores de areia.

Figura 10 – Distribuição espacial dos valores do CMR na área selecionada.

Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Cabe ressaltar que a área selecionada apresenta solo classificado como Latossolo Vermelho Distrófico típico no Sistema Brasileiro de Classificação de Solos, conforme Santos *et al.* (2018), caracterizado por uma vasta abrangência e com raras manchas de outros solos, além de baixos teores de argila e geralmente do tipo 1:1, mais intemperizada e com menor capacidade de retenção de água, que resultariam em valores mais elevados de CMR.

Um fator que pode dificultar sobremaneira o comportamento esperado para a área em questão é a manutenção da palhada sobre o solo após a colheita mecanizada da cana-de-açúcar da mesma, alterando as características de refletância do solo. Isso pode ser constatado pelo comportamento deste índice nos carregadores, nos quais a palhada comumente não estaria presente. Os valores de CMR tiveram seus extremos com um mínimo de 1,1404 e com um máximo de 2,5076.

Quanto ao SCI, cujo comportamento na área em estudo pode ser visualizado na Figura 11, por também considerar a banda SWIR2 no presente estudo, mas em combinação com o NIR como uma diferença normalizada, a interpretação é semelhante ao CMR, ou seja, solos com maior teor de argila teriam valores de SCI menores, enquanto maiores valores representariam solos com maior teor de areia. Pode-se observar que o possível efeito da palhada sobre o solo foi menos pronunciado, visto os carregadores não estarem contrastando tanto com os talhões comparativamente ao CMR. Os valores de SCI variaram desde um mínimo de -0,0991 até um máximo de 3,125.

Raros são os trabalhos relacionando índices mineralógicos, como o caso do CMR e do SCI abordados no presente estudo, com a aptidão agrícola dos solos, havendo a necessidade de aprofundamentos dos estudos para um melhor entendimento de como se comporta o espectro de radiação eletromagnética com os constituintes do solo.

Figura 11 – Distribuição espacial dos valores do SCI na área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

Referente ao atributo altitude, ou elevação, a Figura 12 apresenta a representação hipsométrica em tons de cinza, na qual os tons mais claros representam os pontos mais elevados e os mais escuros os pontos mais baixos. As altitudes extremas na área em questão, máxima e mínima, foram de 577 e 505 metros, respectivamente.

A altimetria tem um importante papel na pedogênese, com a migração de partículas superficiais de solo a partir das áreas convexas rumo às côncavas, além do maior acúmulo de água no solo nos topos e nas planícies em comparação com as vertentes, dois dos fatores definidores da aptidão agrícola de um solo. Santos, Salcedo e Candeias (2002), estudando a relação entre o relevo e as classes texturais do solo, comentam que as áreas menos declivosas, em especial as de planície, são geralmente mais férteis, além de manterem a umidade do solo por períodos de tempo mais longos. Comentam também que as encostas contribuem para a definição da classe textural dos solos das planícies, como consequência dos processos erosivos superficiais.

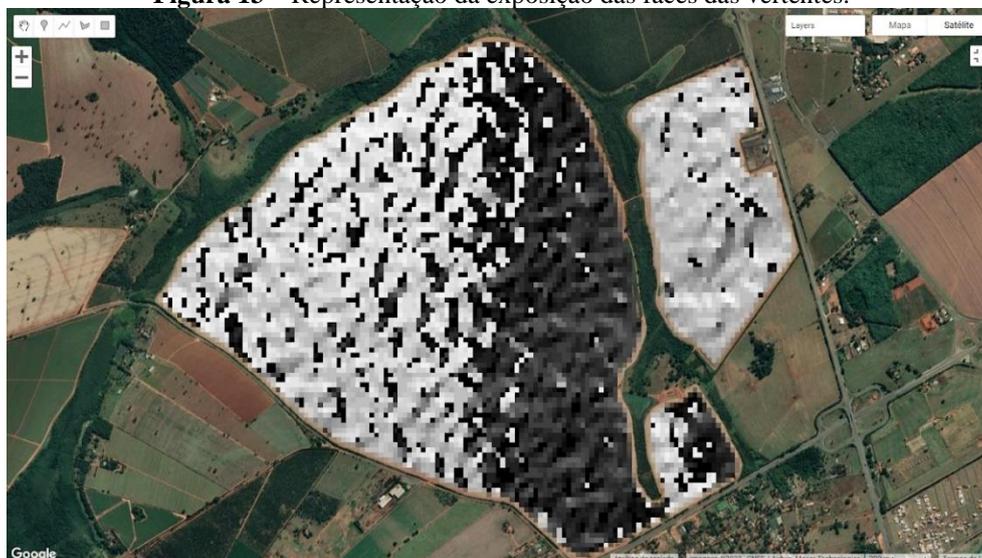
Figura 12 – Representação hipsométrica da área selecionada.



Fonte: imagem gerada e salva pelo autor a partir do Google Earth Engine.

A exposição representada na Figura 13 indica para qual sentido estão voltadas as vertentes, de acordo com seus valores de azimute. O azimute de 0° é exibido em preto, variando em tons de cinza até alcançar o ângulo de 360° na cor branca.

Figura 13 – Representação da exposição das faces das vertentes.



Fonte: imagem gerada e salva pelo autor a partir do *Google Earth Engine*.

Observa-se uma predominância de exposição nos quadrantes noroeste e nordeste. Mazaron, Turco e Silva (2016), avaliando a influência da exposição e da declividade sobre a cultura da cana-de-açúcar irrigada concluíram que o mesmo é influenciado positivamente pela exposição, em especial a norte, quanto ao crescimento da planta, o diâmetro do colmo e a produtividade final. Concluíram também que as declividades são menos efetivas em alterar o crescimento da planta.

Após a obtenção e ajustes dos variogramas e as respectivas krigagens dos atributos CMR, SCI, altitude e exposição, o processamento de tais atributos no MZA resultou na tabela base de comparação de seus coeficientes de correlação de Pearson (Tabela 1).

Tabela 1 – Coeficientes de correlação de Pearson entre os atributos utilizados.

	NDVI	GNDVI	SAVI	OSAVI	VARI	EVI	altitude	exposição	CMR	SCI
NDVI	-	0,795	1,000	1,000	0,819	0,675	0,161	0,041	0,611	0,210
GNDVI	0,795	-	0,795	0,795	0,500	0,509	0,220	0,036	0,433	0,187
SAVI	1,000	0,795	-	1,000	0,819	0,675	0,160	0,041	0,611	0,210
OSAVI	1,000	0,795	1,000	-	0,819	0,675	0,160	0,041	0,611	0,210
VARI	0,819	0,500	0,819	0,819	-	0,753	0,179	-0,005	0,627	0,265
EVI	0,675	0,509	0,675	0,675	0,753	-	0,203	0,004	0,616	0,334
altitude	0,161	0,220	0,160	0,160	0,179	0,203	-	-0,254	0,072	0,431
exposição	0,041	0,036	0,041	0,041	-0,005	0,004	-0,254	-	0,084	0,011
CMR	0,611	0,433	0,611	0,611	0,627	0,616	0,072	0,084	-	0,434

SCI	0,210	0,187	0,210	0,210	0,265	0,334	0,431	0,011	0,434	-
-----	-------	-------	-------	-------	-------	-------	-------	-------	-------	---

Fonte: dados gerados pelo autor a partir do software MZA.

O coeficiente de correlação de 1,000, ou correlação de 100% entre NDVI, SAVI e OSAVI indica haver uma perfeita aderência dos valores desses atributos, devendo dois deles serem descartados da análise e mantendo apenas o NDVI, de onde derivam os outros dois. Moura (2013), estudando a correlação entre produtividade da cana-de-açúcar e índices de vegetação, obteve fortes correlações positivas e muito próximas entre si para os índices NDVI, SAVI e OSAVI, semelhante ao encontrado no presente estudo.

É importante salientar que o descarte destes dois índices, SAVI e OSAVI, objetivamente não implica em serem considerados inadequados, já que a influência do solo pode ser significativa em outras condições de análise que não a do presente estudo, devido às diferenças na cobertura vegetal.

Desconsiderou-se também o atributo exposição, uma vez que este apresentou coeficientes de correlação próximos de 0, indicando ausência de correlação com os demais e independência deste atributo. Esse comportamento está em conformidade com as conclusões supracitadas de Mazaron, Turco e Silva (2016) quanto à exposição norte.

Os sete atributos restantes (NDVI, GNDVI, VARI, EVI, altitude, CMR e SCI), após reagrupados de formas diversas, formaram os novos agrupamentos conforme a Tabela 2, sendo então processados no software MZA para obtenção das UGDs.

As representações gráficas das unidades de gestão diferenciada, obtidas para cada um dos sete agrupamentos apresentados na Tabela 2, foram analisadas visualmente a fim de identificar quais contemplavam, de forma satisfatória, os diversos atributos existentes, considerando-se também a viabilidade de se manejar a área com tal delimitação. Nestas representações, a cor vermelha corresponde ao potencial produtivo elevado, enquanto que as cores verde e azul correspondem a potenciais produtivos médio e baixo, respectivamente.

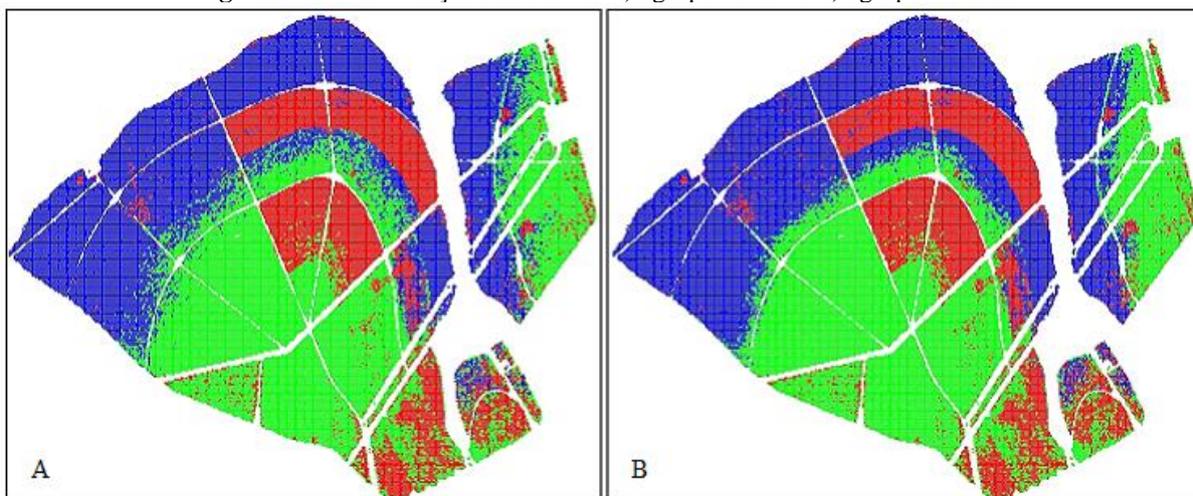
Tabela 2 – Agrupamentos e seus respectivos atributos utilizados na definição das UGDs.

agrupamento	atributos
1	NDVI, GNDVI, VARI, EVI, altitude, CMR
2	NDVI, GNDVI, VARI, EVI, CMR, SCI
3	NDVI, GNDVI, VARI, CMR
4	NDVI, GNDVI, VARI, EVI, CMR
5	NDVI, GNDVI, EVI, altitude, CMR
6	NDVI, GNDVI, EVI, CMR, SCI
7	NDVI, GNDVI, VARI, CMR, SCI

Fonte: dados definidos pelo autor.

Nas imagens relativas aos agrupamentos 1 (Figura 14A) e 5 (Figura 14B), obtidas a partir do software SPRING (Câmara *et al.*, 1996), pôde-se constatar uma grande influência exercida pelo atributo altitude sobre os demais, percebida pelo destaque da cor verde nas partes de maior altitude da área e azul nas de menor altitude, minimizando as contribuições da variabilidade dos demais atributos na definição das UGDs. Como este comportamento não seria realista, considerando os fatores definidores da aptidão agrícola dos solos, ambas as condições foram descartadas.

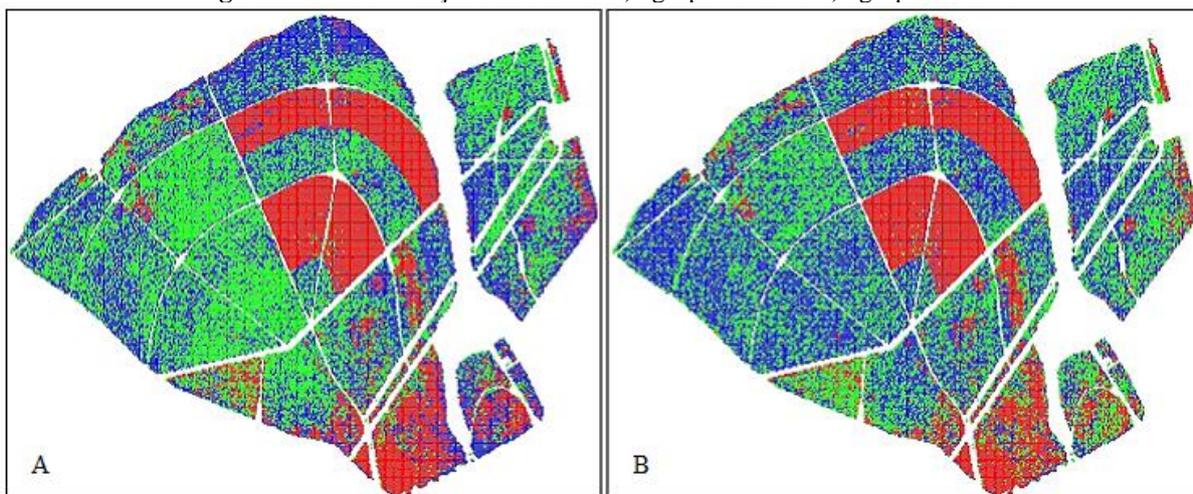
Figuras 14 – Delimitação das UGDs. A) agrupamento 1. B) agrupamento 5.



Fonte: imagens geradas e salvas pelo autor a partir do software SPRING.

As representações gráficas das UGDs referentes aos agrupamentos 2 e 4, conforme a Figura 15A e a Figura 15B, respectivamente, apresentaram significativa quantidade de pontos dispersos, também conhecidos como ruídos, com pouca definição de partes contínuas e extensas, que se consideradas para uma gestão dificultariam, ou mesmo inviabilizariam, sua inclusão em um esquema de agricultura de precisão, portando também foram descartadas.

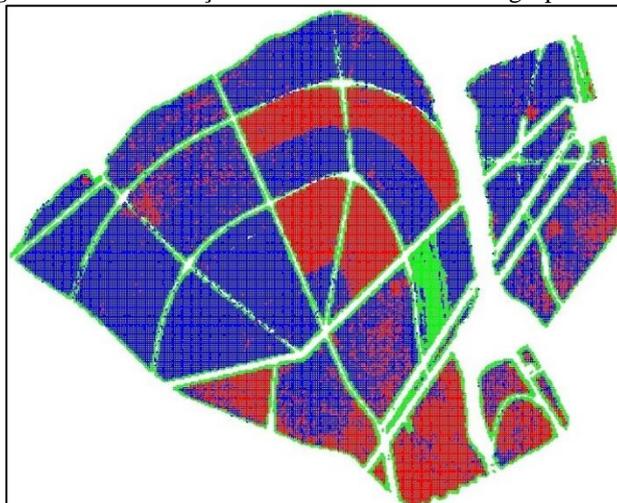
Figuras 15 – Delimitação das UGDs. A) agrupamento 2. B) agrupamento 4.



Fonte: imagens geradas e salvas pelo autor a partir do software SPRING.

Referente ao agrupamento 3, sua representação gráfica quanto às UGDs, conforme a Figura 16, mostra uma supressão de valores intermediários, apresentados na cor verde, posicionando a área praticamente apenas nas condições de alto e baixo potencial produtivo, portanto também considerada não realista, o que resultou no seu descarte.

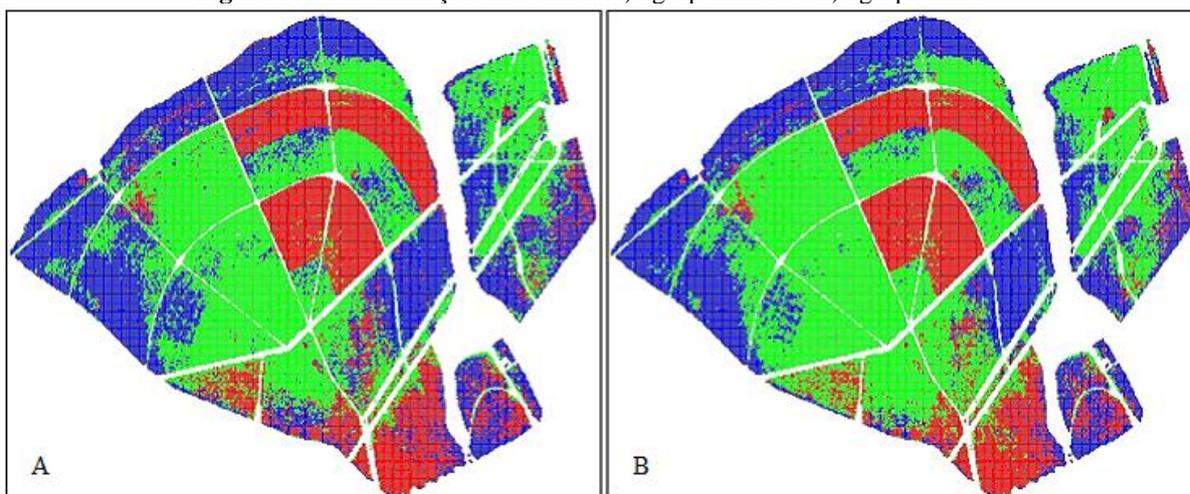
Figura 16 – Delimitação das UGDs referente ao agrupamento 3.



Fonte: imagem gerada e salva pelo autor a partir do software SPRING.

Os últimos agrupamentos avaliados, o agrupamento 6 (Figura 17A) e o agrupamento 7 (Figura 17B), apresentam delimitações de UGDs visualmente bastante semelhantes, contudo observa-se uma menor dispersão de pontos e limites mais bem definidos nas UGDs referentes ao agrupamento 7, o que a princípio contribuiria para uma melhor condição de gerenciamento da área dentro de um programa de agricultura de precisão. Em função disso, O agrupamento 7 foi considerado aquele que resultou na melhor configuração das unidades de gestão diferenciada para a área selecionada.

Figuras 17 – Delimitação das UGDs. A) agrupamento 6. B) agrupamento 7.

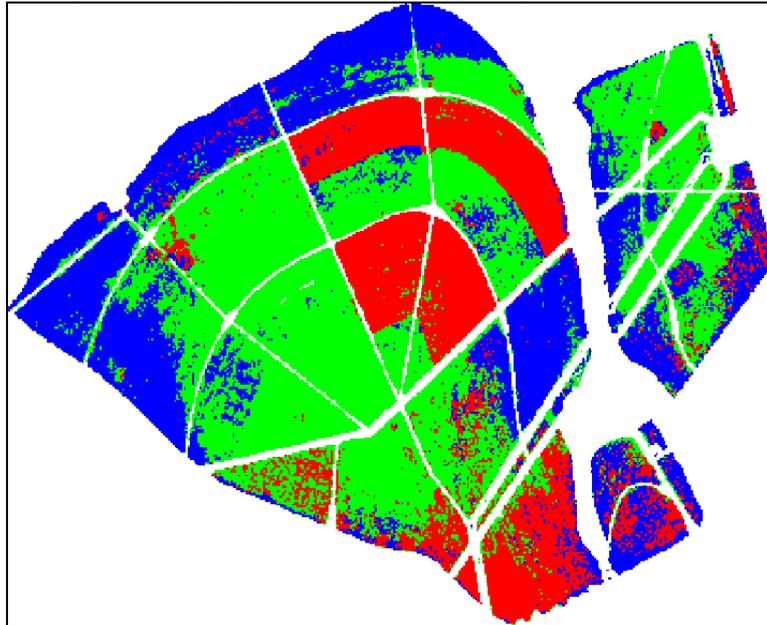


Fonte: imagens geradas e salvas pelo autor a partir do software SPRING.

A Figura 17B, referente ao agrupamento 7, escolhido, portanto, para a definição das UGS da área selecionada, é o resultado da visualização de uma malha de pontos espaçados de 10 metros. A fim de torná-la uma imagem matricial, esta foi editada graficamente, resultando na Figura 18 que, por sua vez, também foi editada passando por um procedimento de segmentação, no qual pontos dispersos ou pequenas manchas foram

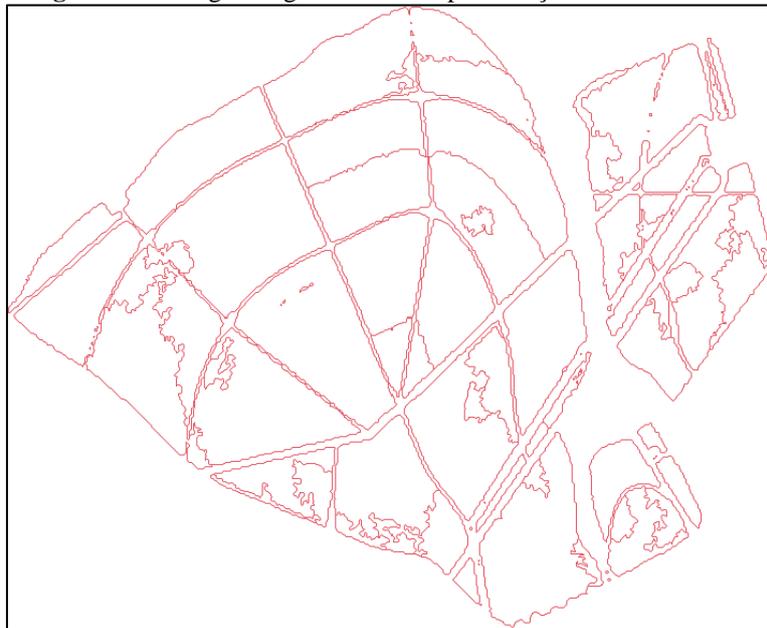
suprimidas e os contornos foram suavizados, possibilitando o estabelecimento dos limites de cada UGD (Figura 19).

Figura 18 – Imagem matricial da representação final das UGDs.



Fonte: imagem gerada e salva pelo autor a partir do software SPRING.

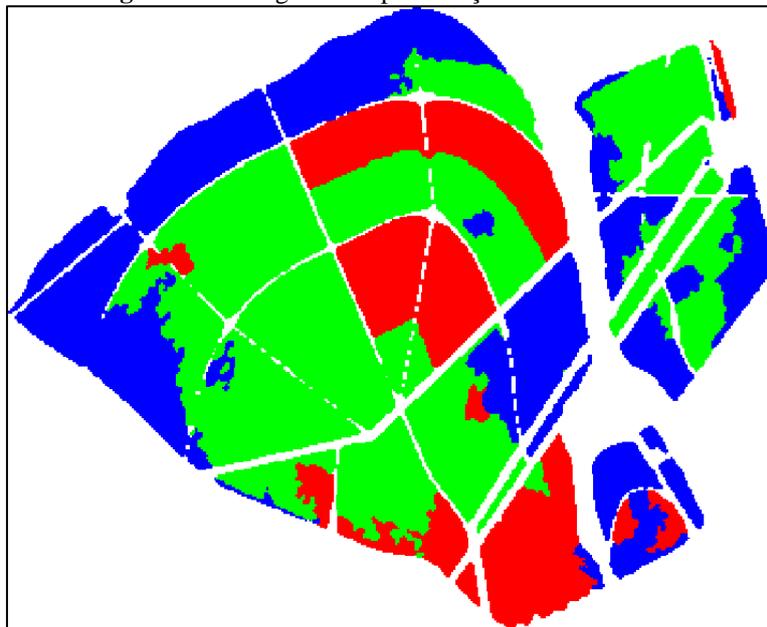
Figura 19 – Imagem segmentada da representação final das UGDs.



Fonte: imagem gerada e salva pelo autor a partir do software SPRING.

Obtida a imagem segmentada, esta foi preenchida com as cores de cada nível de potencial produtivo através de um tratamento de classificação seguido da pós-classificação, resultando em uma melhor suavização dos contornos e supressão de pontos ou pequenas manchas ainda presentes. A Figura 20 apresenta o resultado final desta edição gráfica, sendo a representação final das UGDs para a área selecionada.

Figura 20 – Imagem da representação final das UGDs.



Fonte: imagem gerada e salva pelo autor a partir do software SPRING.

A Figura 20, por se tratar da configuração final das UGDs, define como unidade de alto potencial a região vermelha, com uma área de 161,5 hectares; unidade de médio potencial a região verde, com uma área de 350,6 hectares; e unidade de baixo potencial a região azul, com uma área de 245,9 hectares, totalizando os 758,0 hectares da área selecionada.

4. Conclusão

Os atributos NDVI, SAVI e OSAVI apresentaram correlações perfeitas entre si, sendo recomendado o emprego de apenas um deles, enquanto que os atributos de relevo, especialmente a exposição, apresentaram correlações desprezíveis a fraca com todos os atributos, com a altitude prevalecendo sobre os demais nos agrupamentos em que participou.

O agrupamento envolvendo os atributos NDVI, GNDVI, VARI, CMR e SCI foi o que visualmente resultou na melhor configuração de UGDs, cujas correlações são entendidas como moderadas a fortes dentro do agrupamento, exceto para o SCI, que apresentou correlação fraca a desprezível com os demais atributos.

A metodologia proposta para a delimitação de UGDs no cultivo da cana-de-açúcar mostrou-se adequada e de baixo custo, visto a computação em nuvem gratuita na plataforma Google Earth Engine dispensar a necessidade de se possuir um sistema computacional de alta capacidade, além de disponibilizar as bases de dados atualizadas de sensores remotos orbitais adequados ao procedimento.

O método proposto permite que grande quantidade de informações sejam avaliadas, possibilitando simular diversos cenários e alternar facilmente entre as possibilidades, facilitando as tomadas de decisão.

5. Referências

- Alasta, A. F. (2011). Using remote sensing data to identify iron deposits in central western Libya. **International Conference on Emerging Trends in Computer and Image Processing**, Bangkok. Retrieved January 26, 2022, from https://www.researchgate.net/publication/325550303_Using_Remote_Sensing_data_to_identify_iron_deposits_in_central_western_Libya
- Alface, A. B., Pereira, S. B., Filgueiras, R., & Cunha, F. F. (2019). Sugarcane spatial-temporal monitoring and crop coefficient estimation through NDVI. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 23(5), 330-335. DOI: <http://dx.doi.org/10.1590/1807-1929/agriambi.v23n5p330-335>
- Al-Kaier, F. (2003). **Soil salinity detection using satellite remote sensing**. Master of Science in Geo-information Science and Earth Observation, Watershed Management, Conservation on River Basin Planning specialization, University of Twente, 70 p. The Netherlands. Retrieved January 26, 2022, from https://webapps.itc.utwente.nl/librarywww/papers_2003/msc/wrem/khaier.pdf
- Câmara, G., Souza, R. C. M., Freitas, U. M., & Garrido, J. (1996). SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, 20(3), 395-403. DOI: [https://doi.org/10.1016/0097-8493\(96\)00008-8](https://doi.org/10.1016/0097-8493(96)00008-8)
- Companhia Nacional de Abastecimento. (2022). **Série Histórica das Safras**. Brasília: Conab. Recuperado em 26 janeiro, 2022, de <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras>
- Embrapa. (2018). **Visão 2030: o futuro da agricultura brasileira**. Brasília: Embrapa, 212 p. Recuperado em 26 janeiro, 2022, de <https://www.embrapa.br/visao/o-futuro-da-agricultura-brasileira>
- Embrapa Territorial. (2018). **Satélites de Monitoramento**. Campinas. Recuperado em 26 janeiro, 2022, de <https://www.embrapa.br/satelites-de-monitoramento>
- Esteves, B. dos S., Sousa, E. F. de, Mendonça, J. C., Lousada, L. de L., Muniz, R. de A., & Silva, R. M. da (2012). Variações do albedo, NDVI e SAVI durante um ciclo da cana-de-açúcar no Norte Fluminense. **Revista Brasileira de Ciências Agrárias**, 7(4), 663-670. DOI: <https://doi.org/10.5039/agraria.v7i4a1597>
- 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. **Agronomy Journal**, 96(1), 100-108. DOI: <https://doi.org/10.2134/agronj2004.1000>
- Gitelson, A. A., Stark, R., Grits, U., Rundquist, D., Kaufman, Y., & Derry, D. (2002). Vegetation and soil lines in visible spectral space: a concept and technique for remote estimation of vegetation fraction. **International Journal of Remote Sensing**, 23(13), 2537-2562. DOI: <https://doi.org/10.1080/01431160110107806>
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**. 58(3), 289-298. DOI: [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, 202, 18-27. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>

Henrich, V., Götze, C., Jung, A., & Sandow, C. (2009). Development of an online indices database: motivation, concept and implementation. **EARSel Imaging Spectroscopy SIG Workshop Innovative Tool for Scientific and Commercial Environment Applications**, Tel Aviv. Retrieved January 26, 2022, from https://www.researchgate.net/publication/259802556_Development_of_an_online_indices_database_Motivation_concept_and_implementation

Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, 25(3), 295-309. DOI: [http://dx.doi.org/10.1016/0034-4257\(88\)90106-X](http://dx.doi.org/10.1016/0034-4257(88)90106-X)

Huete, A. R., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, 83(1-2), 195-213. DOI: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)

Huete, A. R., Justice, C., & Liu, H. Q. (1994). Development of vegetation and soil indices for MODIS-EOS. **Remote Sensing of Environment**, 49(3), 224-234. DOI: [https://doi.org/10.1016/0034-4257\(94\)90018-3](https://doi.org/10.1016/0034-4257(94)90018-3)

Machado, H. & Lamparelli, R. A. C. (2007). Desenvolvimento metodológico para amostragem em cana-de-açúcar, considerando a resposta espectral da biomassa em imagens orbitais. **Revista Brasileira de Cartografia**, 59(2), 115-126. Recuperado em 2 março, 2022, de <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44897/23907>

Massruhá, S. M. F. S., Leite, M. A. A., Oliveira, S. R. de M., Meira, C. A. A., Luchiari Junior, A., & Bolfe, E. L. (Ed.) (2020). **Agricultura Digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília: Embrapa, 406 p. Recuperado em 26 janeiro, 2022, de <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/218131/1/LV-Agricultura-digital-2020.pdf>

Mazaron, B. H. S., Turco, J. E. P., & Silva, V. L. da. (2016). Crescimento da cana-de-açúcar em superfícies irrigadas, com diferentes exposições e declividades. **Irriga**, 1(1), 109-125. DOI: <https://doi.org/10.15809/irriga.2016v1n1p109-125>

Minasny, B., McBratney, A. B., & Whelan, B. M. (2002). **VESPER version 1.6**. Sydney: Australian Centre for Precision Agriculture – The University of Sydney. Retrieved January 26, 2022, from <https://precision-agriculture.sydney.edu.au/resources/software/download-vesper/>

Moura, M. C. F. de. (2013). **Correlação entre produtividade em cana-de-açúcar e índices de vegetação espectrais: estudo de caso na região de Oratórios**. Tese de doutorado, Pós-Graduação em Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, MG, 91 f.

Nachiluk, K. (2021). Alta na Produção e Exportações de Açúcar Marcam a Safra 2020/21 de Cana. **Análises e Indicadores do Agronegócio**, 16(6), 1-5. Recuperado em 26 janeiro, 2022, de <http://www.iea.sp.gov.br/out/TerTexto.php?codTexto=15925>

Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, 55(2), 95-107. DOI: [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)

Rouse Jr., J. W. (1974). Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. **Type III final rep. NASA/GSFC**. Texas A&M University. Retrieved January 26, 2022, from <https://ntrs.nasa.gov/citations/19740022555>

Santos, A., Salcedo, I. H., & Candeias, A. L. B. (2002). Relação entre o relevo e as classes texturais do solo na microbacia hidrográfica de Vaca Brava, PB. **Revista Brasileira de Cartografia**, 54(1), 86-94. Recuperado em 3 março, 2022, de <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43941/23205>

Santos, H. G. dos, Jacomine, P. K. T., Anjos, L. H. C. dos, Oliveira, V. A. de, Lumbrreras, J. F., Coelho, M. R., Almeida, J. A. de, Araujo Filho, J. C. de, Oliveira, J. B. de, & Cunha, T. J. F. (2018). **Sistema Brasileiro de Classificação de Solos**. (5ª ed., rev. e ampl.). Brasília: Embrapa, 356 p. Recuperado em 2 março, 2022, de <https://www.embrapa.br/solos/busca-de-publicacoes/-/publicacao/1094003/sistema-brasileiro-de-classificacao-de-solos>

Silva, J. R., Coelho, P. J., Caser, D. V., Bueno, C. R. F., Pinatti, E., Pini, D. L. de C., Monteiro, A. V. V. M., & Franca, T. J. F. (2021). Valor da Produção Agropecuária nas Regiões do Estado de São Paulo em 2020. **Análises e Indicadores do Agronegócio**, 16(5), 1-7. Recuperado em 26 janeiro, 2022, de <http://www.iea.sp.gov.br/out/TerTexto.php?codTexto=14918>

Susantoro, T. M., Wikantika, K., Saepuloh, A., Handoyo A., & Harsolumakso, H. A. (2018). Selection of vegetation indices for mapping the sugarcane condition around the oil and gas field of North West Java Basin, Indonesia. **IOP Conference Series: Earth and Environmental Science**, v.149, Bogor, Indonesia. DOI: <https://doi.org/10.1088/1755-1315/149/1/012001>

Xin, F., Xiao, X., Cabral, O. M. R., White Jr, P. M., Guo, H., Ma, J., Li, B., & Zhao, B. (2020). Understanding the land surface phenology and gross primary production of sugarcane plantations by eddy flux measurements, MODIS images, and data-driven models. **Remote Sensing**, 12(14), 2186. DOI: <https://doi.org/10.3390/rs12142186>