

Auxílio de tomada de decisão no manejo e planejamento do plantio de soja com o processo de segmentação de imagens

Daniel C. De Souza¹, Rogério R. De Vargas¹, Nilmar De C. Bastiani¹, Leonardo Koga¹, Alexandre Russini¹

¹Laboratório de Sistemas Inteligentes de Modelagem – Universidade Federal do Pampa (Unipampa) Campus Itaqui

Rua Joaquim de Sá Britto, n/s – Promorar – 97.650-000 – Itaqui – RS – Brasil

{danielciro6, nc.bastiani, lekogox}@gmail.com, {rogeriovargas, alexandrerrussini}@unipampa.edu.br

Abstract. *The development of technologies for agriculture has made possible better control and management production systems. Through monitoring, it becomes possible to analyze phytosanitary conditions, as well as productive potential, and especially failures resulting from process in crop implementation and its management. Thus, this present work aims to identify plant stand failures in a soybean crop grown in floodplain areas with image capture and processing. These were captured with aid an unmanned aerial vehicle and processed by the ckMeans algorithm, reducing number of colors in relation to the original image. Thus, with processing it is possible to identify crop line failures, management errors, sowing, germination problems and areas with drainage deficiency. Therefore, using processed images is a tool that contributes to decision making in soybe crop anmanagement cultivated in lowland areas.*

Resumo. *O desenvolvimento de tecnologias destinadas a agricultura, possibilitou melhor controle e gerenciamento dos sistemas de produção. Por meio do monitoramento, torna-se possível analisar as condições fitossanitárias, bem como o potencial produtivo, e principalmente, falhas decorrentes do processo em implementação da cultura e do seu manejo. Assim, o presente trabalho tem por objetivo identificar falhas no estande de plantas em uma lavoura de soja cultivada em áreas de várzea com captura de imagens e as processando. Essas foram capturadas com auxílio de um veículo aéreo não tripulado e processadas pelo algoritmo ckMeans, reduzindo o número de cores em relação a imagem original. Desta forma, com o processamento é possível identificar falhas nas linhas de cultivo, erros no manejo, semeadura, problemas de germinação e zonas com deficiência de drenagem. Portanto, a utilização de imagens processadas é uma ferramenta que contribui na tomada de decisão no manejo da cultura da soja cultiva em áreas de várzea.*

1. Introdução

A soja chegou no Brasil por volta do ano 1908 trazida pelos japoneses nos iniciando os primeiros cultivos nos estados da Região Sul (Paraná, Santa Catarina e Rio Grande do

Sul), mas apenas a partir da década de 1970 houve um crescimento da produção no país. Ainda, entre os anos de 1970 a 1979 a cultura se expandiu na Região Sul e em São Paulo, devido a fatores como: condições edafo-climáticas favoráveis, boa infraestrutura, o estabelecimento de uma articulada rede de pesquisa de soja e o surgimento de um cooperativismo dinâmico e eficiente (Embrapa, 2003). Conforme Costa (2000), foi a partir da década de 1980, que a soja se expandiu para os estados de Goiás, oeste de Minas Gerais, Bahia, sul do Mato Grosso e Mato Grosso do Sul, dentro do movimento agropecuário em direção ao oeste brasileiro. Atualmente, áreas da Amazônia Legal (região Norte, Mato Grosso e oeste do Maranhão), também estão sendo alvo do avanço do cultivo de soja (Teixeira et al., 2012).

Atualmente o Brasil é o segundo maior produtor de soja do mundo, com uma produção de 116.996 milhões de toneladas, área plantada de 35.100 milhões de hectares e com uma produtividade de 3.333 kg.ha⁻¹ (Embrapa, 2018). É uma cultura de suma importância no agronegócio e principalmente para balança comercial brasileira, pois representa cerca de US\$ 33 bilhões em exportações no ano de 2018 (Brasil, 2018). A expansão da área cultivada é decorrente da incorporação de novas áreas, nas regiões Centro-Oeste e Norte, e também da substituição de outras culturas, na Região Centro-Sul (Embrapa, 2000).

O Rio Grande do Sul, é considerado o terceiro maior produtor de soja brasileiro, com 14% da produção nacional, o que representa uma área cultivada de 5,692 milhões de hectares com produtividade média de 2.981 kg.ha⁻¹ (Embrapa, 2018). O aumento de produtividade se deve ao emprego de tecnologia, com o uso de materiais genéticos de maior potencial produtivo e da crescente profissionalização dos produtores rurais (Melo et. al, 2004).

Na Fronteira Oeste do Rio Grande do Sul a soja é apresentada como alternativa para a rotação da cultura do arroz irrigado na região. Nos últimos anos, o cultivo de soja em terras baixas vem sendo excelente opção para estabelecer rotação com o arroz irrigado, pois permite o controle de plantas daninhas resistentes a herbicidas, além de também proporcionar opção de maior rendimento econômico ao orizicultor (Veiga et al., 2019). Essa introdução foi capaz graças emprego de tecnologia que auxiliam o produtor na tomada de decisão.

Tecnologias como softwares de gestão e de monitoramento já são realidade no agronegócio. De acordo com a Comissão Brasileira de Agricultura (Brasil, 2017) de Precisão, 67% das propriedades agrícolas do Brasil fazem uso de algum tipo de tecnologia, seja na área de gestão do negócio ou nas atividades relacionadas à produção.

O monitoramento aéreo com Vant (Veículo Aéreo não Tripulado), é um meio de realizar o acompanhamento de diferentes culturas. O uso do Vant, popularmente conhecidos como drone, permite a obtenção de imagens aéreas de grandes áreas com baixo custo, com maior frequência e com alta resolução (na escala de centímetros), o que viabiliza o uso desta ferramenta em larga escala. A estimativa de parâmetros biofísicos e bioquímicos com alta acurácia e baixo custo são importantes para a evolução das práticas de manejo e do potencial produtivo de sistemas de produção dentro dos preceitos da agricultura de precisão (Embrapa, 2018). O alto rendimento e precisão espacial na estimativa destas características por meio de imagens aéreas obtidas por drones pode ajudar na avaliação do comportamento de genótipos, práticas de manejo e impactos de estresses bióticos e abióticos, contribuindo na tomada de decisão dos produtores (Embrapa, 2018).

O desenvolvimento dos drones surgiu como uma importante ferramenta para a agricultura de precisão (Frachini et al., 2018). No entanto, existem poucas informações na literatura sobre o uso prático de imagens provenientes de drone e de índices de vegetação simples, obtidos com câmeras que captam a região do visível, como ferramenta para ajustes de manejo, com o objetivo de aumentar a produtividade ou redução dos custos de produção (Frachini et al., 2018).

Com o monitoramento, é possível quantificar as áreas de produção, realizar análise fitossanitária, estimar a capacidade de produção ou até mesmo identificar áreas que apresentam falhas de cultivos que muitas vezes são oriundas da qualidade de sementes, desuniformidade na distribuição de sementes ou por plantas invasoras (Reynaldo et al., 2017). O sensoriamento remoto é um conjunto de métodos de captação de informações dos fenômenos e feições terrestres, por meio de sensores, sem contato direto, sendo indispensáveis as metodologias e técnicas de armazenamento, tratamento, análise e interpretação destas informações (Barbosa, et al., 2019). Uma das ferramentas de análise é o agrupamento que pode ser compreendido como uma técnica de reconhecimento de padrões representados em uma imagem com vários espectros, através do agrupamento de pixels semelhantes que pertençam ao mesmo grupo (Vargas, 2017). Por meio do sensoriamento remoto de imagens de satélite ou com a utilização de veículos aéreos não tripulados, com imagem *in loco* (Longhitano e Quintanilha, 2011), pode-se realizar o processamento de uma imagem para identificar um determinado item no cultivo utilizando filtragem de cores (Lulio, 2017). Esta filtragem também pode ser realizada por meio de um algoritmo específico, como, por exemplo, o ckMeans, onde trata-se de uma imagem multiespectral que tem como objetivo avaliar mapas temáticos digitais gerados, além de ressaltar a potencialidade do método no campo do sensoriamento remoto (Vargas, 2017).

Neste sentido, o presente trabalho tem por objetivo identificar falhas no estande de plantas em uma lavoura comercial de soja cultivada em áreas de várzea, por meio do processo de segmentação de imagens em três grupos de cores e altitude, com a utilização do algoritmo ckMeans.

2. Materiais e métodos

O trabalho foi conduzido em uma área sistematizada em desnível com cultivo comercial de arroz irrigado em rotação com soja, durante o ano agrícola de 2018/2019, no município de Itaqui, localizado na Fronteira Oeste do Estado do Rio Grande do Sul (29° 10' 09,17" S; 56° 34' 21,35" O; 55 m), sendo o solo classificado como PLINTOSSOLO Háplico distrófico (Santos et al. 2013), característico de áreas de solo de várzea. A semeadura da soja foi realizada em sistema de sulcos após preparo convencional de solo seguido de nivelamento.

As imagens foram capturadas no estágio fenológico V3, por meio de um Veículo Aéreo não Tripulado (Vant), tipo Drone Phantom 3 Pro, equipado com Sistema de Posicionamento Global (GPS) e câmera GoPro 4K, nas altitudes de 50, 75, 100 e 150 metros. As imagens foram processadas pelo algoritmo ckMeans (Vargas e Bredegal 2010), disponível em <http://www.labsim.unipampa.edu.br/ckMeans>.

O ckMeans é um algoritmo de processamento de imagens que consiste de um conjunto $X = \{x_1, x_2, \dots, x_n\}$ dividido em p grupos onde cada grupo é representado por uma cor conforme determinado por Vargas et al. (2017), μ_{ij} é o grau de pertinência

da amostra x_i ao j -ésimo cluster e o resultado do agrupamento expresso pelos graus de pertinência na matriz μ . Busca encontrar conjuntos nos dados, minimizando a função objetivo está demonstrada na Equação (1):

$$\sum_{i=1}^n \sum_{j=0}^p \mu_{ij}^m d(x_i; c_j)^2 \quad (1)$$

Onde:

n : é o número de dados;

p : é o número de clusters considerados no algoritmo o qual deve ser decidido antes da execução;

$m > 1$: é o parâmetro da *fuzzificação*;

x_i : um vetor de dados de treinamento, onde $i = 1, 2, \dots, n$. Cada posição no vetor representa um atributo do dado;

c_j : é o centro de um agrupamento *fuzzy* ($j = 1, 2, \dots, p$);

$d(x_i; c_j)$: é a distância.

A entrada do algoritmo são os n dados, o número de clusters p e o valor de m . Os consistem em:

1. Inicia-se com μ , um valor aleatório contínuo que varia entre zero (nenhuma pertinência) e um (pertinência total), onde a soma das pertinências deve ser um;
2. O calculo do centro do cluster j : no qual se cria uma nova matriz μ , denominada de μ_C em que os valores 1 ou 0. Cada linha da nova matriz tem 1 na posição do maior valor dessa linha na matriz μ e zero nas demais posições da linha. Quando uma coluna da matriz μ_C , for toda com zeros, se atribui o valor 1 na posição correspondente ao maior valor dessa mesma coluna na matriz μ .

O algoritmo *ckMeans* retorna uma matriz μ_C conforme é mostrado na Equação (2). Ou seja, μ_C é a matriz enquanto μ_{Cij} é o conteúdo dessa matriz na posição (ij) .

$$\mu_{Cij} = \max \left(\left\lfloor \frac{\mu_{ij}}{\max_{l=1}^p \mu_{il}} \right\rfloor, \left\lfloor \frac{\mu_{ij}}{\max_{l=1}^n \mu_{il}} \right\rfloor \right) \quad (2)$$

Na função *max* são convertidos os dois argumentos no maior número inteiro que seja menor ou igual ao seu valor real. A primeira argumentação faz com que cada dado tenha o valor 1 no cluster ao qual pertence com maior grau de pertinência e grau de pertinência zero nos demais. A segunda argumentação tem por objetivo que o maior grau de cada coluna (cluster) seja 1, para que se garanta que todo cluster tenha pelo menos um elemento. Dessa forma, em raras ocasiões, pode acontecer que uma linha tenha mais de um valor 1 (o que não ocorre o algoritmo *K-Means* original), mas como esta matriz é apenas auxiliar, não ocasionará qualquer transtorno.

Os passos do algoritmo para calcular o μ_{Cij} é realizado da seguinte forma:

- (a) Leitura de μ ;

- (b) E em cada linha é encontrado o maior valor da matriz μ atribuindo valor 1 a essa mesma posição em μC e zero nas posições restantes;
- (c) O armazenamento em um vetor a quantidade de 1's que cada coluna de μC possui.

Se uma coluna não tiver 1's marque sumariamente com 1 a posição onde está o maior valor. Após calculada a matriz μC calculam-se os novos centros dos clusters conforme a Equação (3).

$$c_j = \frac{\sum_{i=1}^n x_i \mu C_{ij}}{\sum_{i=1}^n \mu C_{ij}} \quad (3)$$

O c_j é calculado pelo somatório dos dados que pertencem ao cluster (de forma *crisp*) e dividido pela quantidade de objetos classificados como 1 na matriz μC deste cluster.

3. Calcule um valor inicial para J usando a Equação (1);
4. Calcule a tabela da função de pertinência fuzzy μ conforme mostrado na Equação (4).

$$c_j = \frac{\left(\frac{1}{d(x_i; c_j)} \right)}{\sum_{k=1}^p \left(\frac{1}{d(x_i; c_k)} \right)^{2/m-1}} \quad (4)$$

5. Retornar a etapa 2 até que uma condição de parada seja alcançada.

Algumas condições de parada possíveis são:

- Um número de iterações pré-fixado for executado;
- O usuário informa um valor de parada $\varepsilon > 0$, e se $d(J_U; J_A) \leq \varepsilon$ então para, onde J_A é a função objetivo (Equação (1)) calculada na iteração anterior e J_U é a função objetivo da última iteração.

Uma vez que o algoritmo *ckMeans* retorna uma matriz na qual cada linha possui o grau de pertinência do pixel aos clusters, faz-se necessário converter a matriz de pixels em um vetor coluna. Sendo assim, monta-se a imagem para tornar possível a interpretação dos padrões obtidos pelo algoritmo de agrupamento.

O algoritmo de pós processamento recebe esta matriz (denominada matriz C) e verifica qual grupo o pixel tem maior grau de pertinência. Para facilitar o processamento a matriz C é convertida em vetor coluna S. Os passos do algoritmo são descritos a seguir:

1. Avalia o conteúdo da matriz C e cria uma matriz nula M de mesma dimensão da Matriz C;
2. Procura em cada linha o grupo ao qual o pixel possui maior grau de pertinência;

3. Na matriz M, atribui valor 1 à posição do maior grau de pertinência e zero às demais posições.

Nota-se que assim é obtida uma matriz binária (com valores 0 e 1), onde cada linha possui apenas um valor 1, ou seja, o pixel está associado à apenas um agrupamento. Este procedimento é descrito a seguir e para melhor entendimento, a Figura 2 esquematiza todo o processo pelo qual a imagem é submetida, desde o pré até o pós-processamento;

4. Cada uma das colunas da Matriz M é transformada em uma nova matriz, ou seja, de M originam-se três novas matrizes contendo valores 0 e 1;

5. As três matrizes são multiplicadas pelo escalar 255, originando assim as três bandas da imagem (Red, Green e Blue);

6. As bandas são novamente unidas e a imagem está completamente montada.

A Figura 1 exemplifica o funcionamento do algoritmo ckMeans, todo o processo pode ser dividido em 5 etapas.

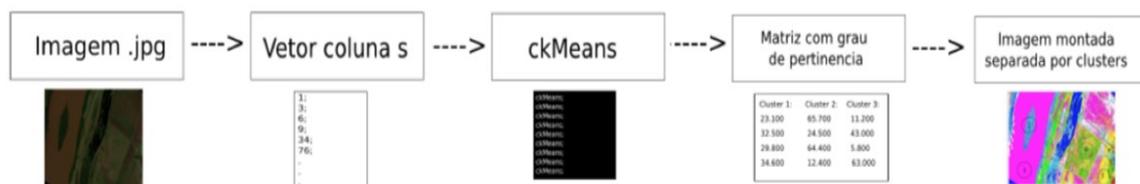


Figura 1. Tarefa realizada pelo algoritmo de pré-processamento.
Fonte. Vargas et al. (2018)

1. **Imagem.jpg:** Imagem a ser processada, ou seja, a imagem capturada pelo VANT;

2. **Vetor coluna s:** Utilizando a biblioteca de processamento de imagens *openCV*, a imagem é convertida em valores das bandas RGB (*Red*, *Green* e *Blue*) e assim criado um vetor com respectivas cores;

3. **ckMeans:** Realizada o processo de agrupamento dos dados de acordo com o número de grupos pré-definido pelo usuário;

4. **Matriz com grau de pertinência:** Após o processo de agrupamento é gerado uma matriz, esses valores foram obtidos do processo do algoritmo devendo ser reagrupado para gerar a nova imagem segmentada;

5. **Imagem montada separada por clusters:** imagem resultante de todo o processo.

3. Resultados e discussão

A Figura 2 apresenta a imagem capturada à 50 metros de altitude (original), com processamento em 3 grupos de cores. O parâmetro de entrada do algoritmo ckMeans foi $\varepsilon = 0,01$ e $p = 3$ (grupos), $p = 4$ (grupos) e $p = 5$ (grupos) (*fuzzificação*).

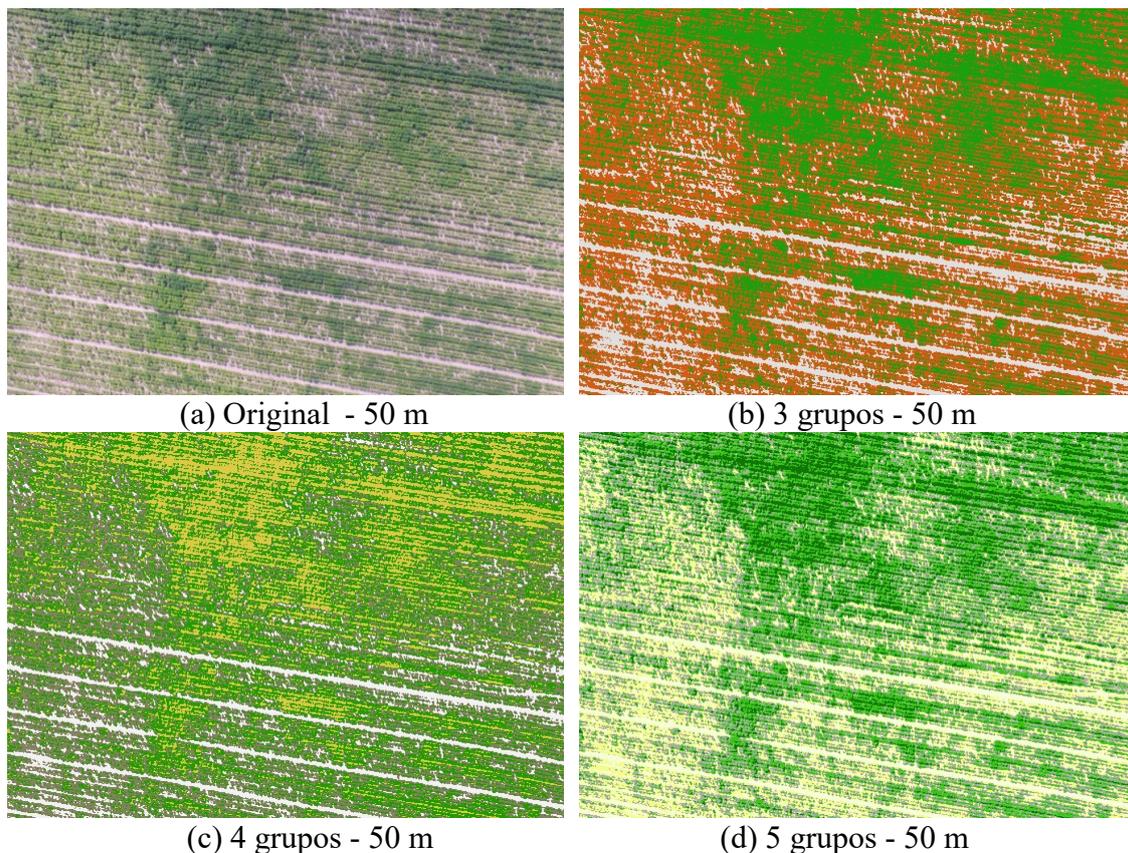


Figura 2. Imagem original (a), imagens processadas em 3 grupos (b), 4 grupos (c) e 5 grupos (d).

Observou-se as falhas linhas de semeadura principalmente no processamento com 5 grupos, decorrente de problemas de semeadura e estabelecimento inicial da cultura, bem como o desenvolvimento desuniforme das plantas nos estádios vegetativos seguintes devido a deficiência de drenagem do solo. Nota-se que os sulcos destinados a irrigação e drenagem se destacam devido a ausência de cobertura vegetal, confirmando que pontos de mesma cor (tonalidade), nas linhas caracterizam a ausência de plantas.

No processamento com 4 grupos as falhas são menos visíveis, porém as diferenças no desenvolvimento na cultura da soja são mais aparentes. Neste sentido, a ausência, e a desuniformidades no desenvolvimento de plantas facilitam surgimento e desenvolvimento de plantas daninhas que pode ocasionar uma competição com a cultura reduzindo o tamanho das plantas influenciando no enchimento de grão, reduzindo consequentemente a produtividade da cultura (Fleck; Candemil, 1995). No processamento com 5 grupos, observou-se com maior intensidade a vegetação, os sulcos de irrigação e drenagem estão mais aparentes em relação os grupos de cores apresentados.

A Figura 3 apresenta a imagem capturada à 75 metros de altitude (original), com o processamento com 3, 4 e 5 grupos, com os mesmos parâmetros de entrada no algoritmo da Figura 2.

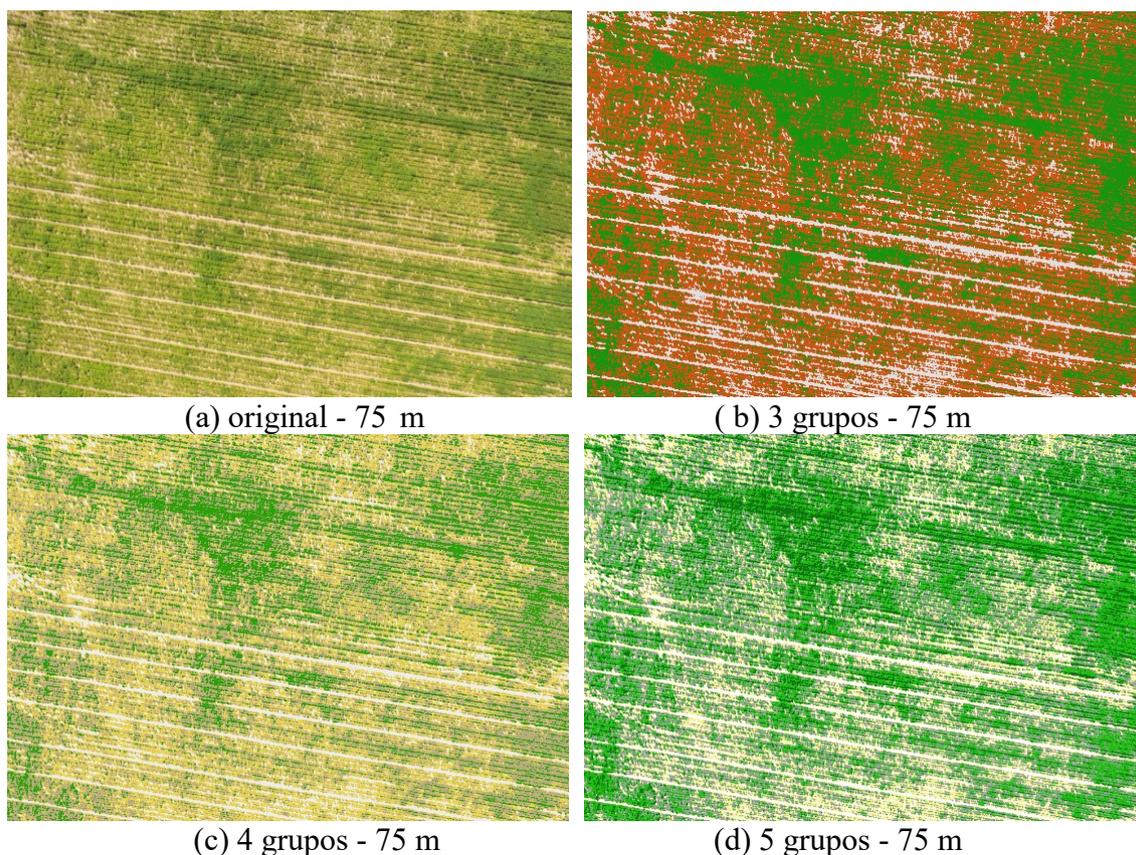


Figura 3. Imagem original (a), imagens processadas em 3 grupos (b), 4 grupos (c) e 5 grupos (d).

Com o aumento da altitude de captura da imagem nota-se uma diferença na visualização da imagem, nas quais as falhas apresentam-se menores em relação a imagem original da Figura 3. No processamento com grupos, é possível observar os sulcos de irrigação e drenagem apresentam ausência de cobertura vegetal, confirmando que pontos de mesma cor (tonalidade), nas linhas se caracterizam a ausência de plantas, como na imagem da Figura 3. Outro ponto a ser observado é o acréscimo da área com o aumento da altitude de captura da imagem, mas os mesmos casos de falhas são observados.

Já no processamento com 4 grupos, observou-se que houve um o aumento da área capturada, uma menor área de falhas, porém as diferenças no desenvolvimento na cultura da soja são mais visíveis.

No processamento com 5 grupos de cores a visualização dos sulcos são ainda maiores e melhores de serem visualizados em relação a Figura 3.

A Figura 4 apresenta a imagem capturada à 100 metros de altitude com processamento com 3, 4 e 5 grupos, mantendo os mesmos parâmetros da Figura 2.

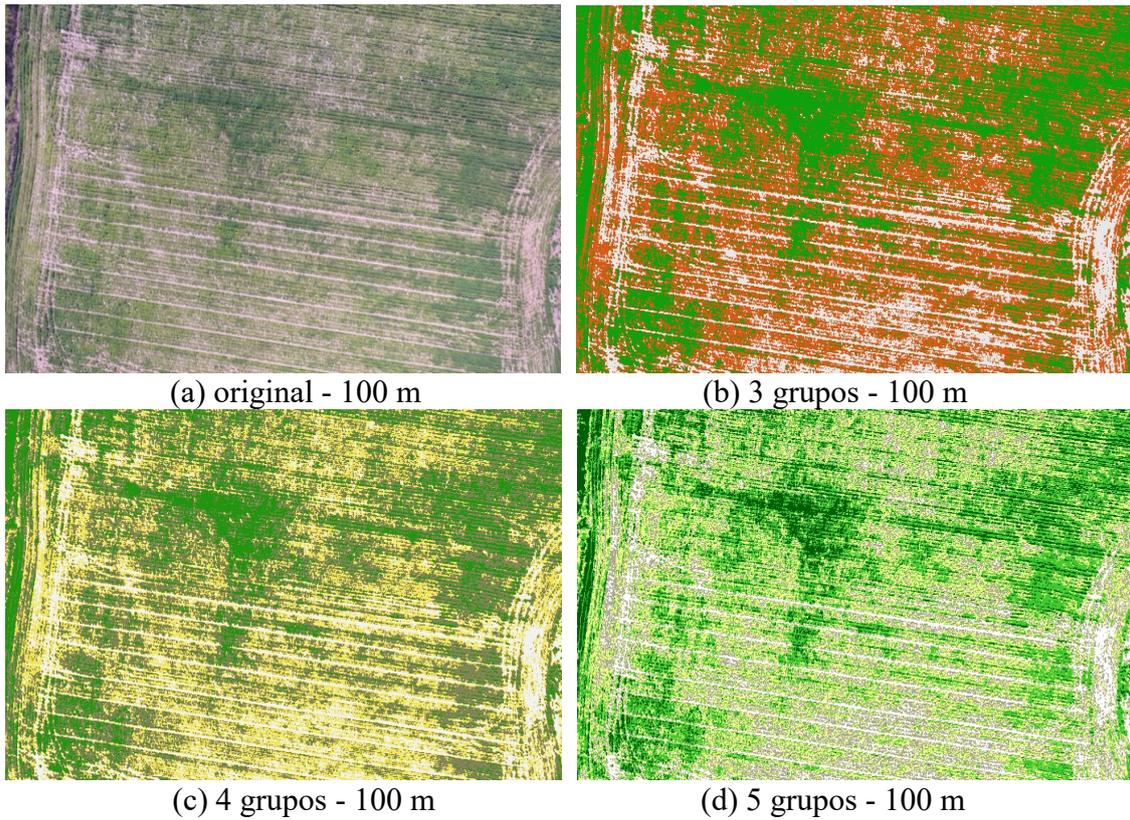
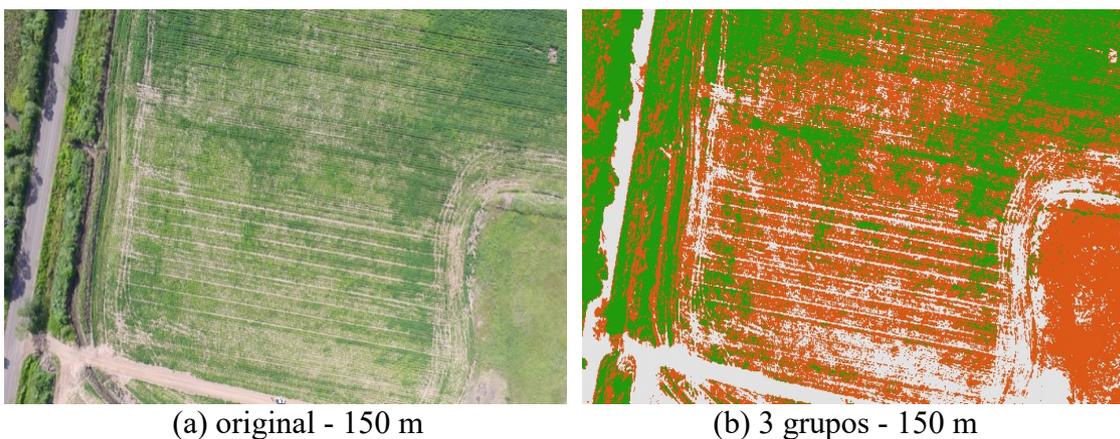
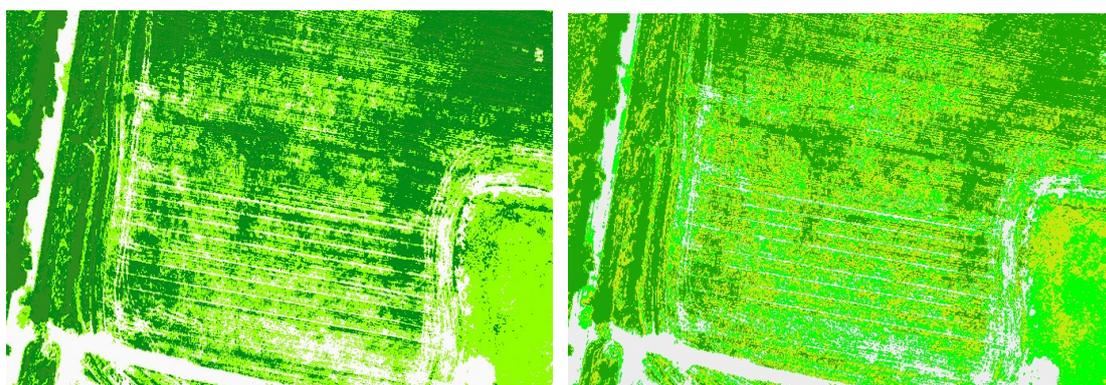


Figura 4. Imagem original (a), imagens processadas em 3 grupos (b), 4 grupos (c) e 5 grupos (d).

Quanto maior o número de grupos de cores possibilita-se uma melhor visualização das falhas em cada imagem processada, bem como observar todas as desuniformidades.

A Figura 5 apresenta a imagem capturada à 150 metros de altitude com processamento em 3, 4 e 5 grupos de cores com os mesmos parâmetros da Figura 2.





(c) 4 grupos - 150 m

(d) 5 grupos - 150 m

Figura 5. Imagem original (a), imagens processadas em 3 grupos (b), 4 grupos (d) e 5 grupos (d).

Com o aumento da altitude de captura da imagem nota-se uma diferença na visualização da imagem, nas quais as falhas apresentam-se menores em relação a imagem original das Figuras 2 a 5.

É possível observar os sulcos de irrigação e drenagem e nota-se ausência de cobertura vegetal, confirmando que pontos de mesma cor (tonalidade), nas linhas se caracterizam a ausência de plantas, como na imagem das Figuras 3, 4 e 5.

Outro ponto a ser observado é o aumento da área capturada com a aumento da altitude da tomada da imagem. Mas os mesmos casos de falhas são observados.

4. Conclusão

As imagens processadas permitiram visualizar ausência de plantas nas linhas de cultivo, provenientes de problemas na semeadura e germinação, que interferem diretamente no estágio inicial de plantas, bem como o desenvolvimento desuniforme de plantas decorrentes da deficiência de drenagem, comuns em áreas de várzea. Portanto, o processamento de imagens se apresenta como mais uma ferramenta no intuito de auxiliar a tomada de decisão no manejo e planejamento, permitindo desta forma que áreas de várzea possam ser utilizadas com cultura da soja e com rendimentos significativos. Quanto maior a altitude e a quantidade de cores processadas, maior é a visualização de falhas de cultivo nas condições em que o estudo foi realizado.

References

- Barbosa, C. C. F. et al. (2019) Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: Princípios e aplicações. São José dos Campos: Instituto de Pesquisas Espaciais. 166p. Disponível em: <http://www.dpi.inpe.br/labisa/livro/res/conteudo.pdf>, Setembro, 2019.
- Brasil. (2018) Ministério da Economia, Indústria, Comércio Exterior e Serviços. Balança comercial registra superávit de US\$ 4,971 bilhões em setembro. Disponível em: <http://www.mdic.gov.br/index.php/noticias/3600-balanca-comercial-registra-superavit-de-us-4-971-bilhoes-em-setembro>, Março, 2019.
- Brasil. (2017) Ministério da Economia, Indústria, Comércio Exterior e Serviços. Tecnologia já é usada em cerca de 67% das propriedades rurais do país. Disponível

- em: <http://www.agricultura.gov.br/noticias/tecnologia-ja-e-usada-em-cerca-de-67-das-propriedades-rurais-do-pais-1>, Sembro, 2019.
- Costa, F. G. (2000) Avaliação do potencial de expansão da soja na Amazônia Legal: uma aplicação do modelo de Von Thünen. 162p. Dissertação (Mestrado em Economia Aplicada) – Escola Superior de Agricultura Luiz de Queiroz, USP, Piracicaba.
- Embrapa. (2018) Soja em números: safra2017/2018. <https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>, Março, 2019.
- Embrapa. (2003) Tecnologias de produção de soja – Região central do Brasil. s/l. Disponível em: www.cnpsa.embrapa.br, Julho. 2019.
- Embrapa. (2000) Recomendações técnicas para a cultura da soja na região central do Brasil 2000/01. Londrina: Embrapa Soja/Fundação MT, 2000. 245p.
- Fleck, N. G.; Candemil, C. R. G. (1995) Interferência de plantas daninhas na cultura da soja (*Glycine max* (L.) Merrill). *Cienc. Rural*, v.25, n.1, Santa Maria. DOI: <http://dx.doi.org/10.1590/S0103-84781995000100006>
- Frachini, J. C. et al. (2018) Uso de imagens aéreas obtidas com drones em sistemas de produção de soja Londrina: Embrapa Soja, 2018. 39 p.
- Longhitano, G. A.; Quintanilha, J. A. (2011) Avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas através de sensoriamento remoto por VANTs. In: III Coloquio Evaluación de Peligro, Vulnerabilidad y Riesgos para La Reducción de los Desastres de la VIII Convención Internacional sobre Medio Ambiente y Desarrollo, 2011, La Habana. Anais da VIII Convención Internacional sobre Medio Ambiente y Desarrollo.
- Lulio, L. C. Processamento de imagens como soluções práticas ao agronegócio. *Jornal da USP*. (2017) Disponível em: <https://jornal.usp.br/artigos/processamento-de-imagens-como-solucoes-praticas-ao-agronegocio/>, Março, 2019.
- Melo, R. W. et al. (2004) Indicadores de produção de soja no Rio Grande do Sul comparados ao zoneamento agrícola. *Pesq. agropec. bras.* vol.39 no.12, Brasília. DOI: <http://dx.doi.org/10.1590/S0100-204X2004001200002>
- Reynaldo, E. F. et al. (2017) Influência da velocidade de deslocamento na distribuição de sementes e produtividade de soja. *Engenharia na agricultura*, Viçosa, v.24 n.1. DOI: <https://doi.org/10.13083/reveng.v24i1.634>
- Santos, H. G. dos. et al. (2013) Sistema brasileiro de classificação de solos. 3.ed. rev. e ampl. Brasília: Embrapa, 353p.
- Vargas, R. R. et al. (2017) Algoritmo ckMeans Aplicado ao Sensoriamento Remoto. *Proceeding Series of the Brazilian Society of Applied and Computational Mathematics*, v. 5, n. 1. DOI: <https://doi.org/10.5540/03.2017.005.01.03>
- Teixeira, B. E. S. Et al. (2012) A expansão da fronteira agrícola da soja no município de santarém (pa) e suas transformações socioespaciais. Anais: XXI Encontro Nacional de Geografia Agrária. Universidade Federal de Viçosa. Disponível em: http://www.lagea.ig.ufu.br/xx1enga/anais_enga_2012/eixos/1282_1.pdf, Julho, 2019.

- Vargas, R. R.; Bedregal, B. (2010) A Comparative Study Between fuzzy c-means and ckMeans Algorithms. In: Proc. Conf. North American Fuzzy Information Processing Society (NAFIPS 2010), Toronto, Canada.
- Vargas, R. R. et al. (2018). Identificação de áreas agrícolas para o manejo diferenciado utilizando o algoritmo ckMeansImage. Congresso Argentino de Agroinformática. Buenos Aires, Argentina. Disponível em: http://sedici.unlp.edu.ar/bitstream/handle/10915/70981/Documento_completo.pdf-PDFA.pdf?sequence=1&isAllowed=y, Setembro, 2019.
- Veiga, A. B. et al. (2019) Efeito do sistema de cultivo e manejo do solo no estabelecimento de soja em terras baixas. (Anais de Congresso) XI Congresso Brasileiro de Arroz Irrigado. Balneário Camboriú. Disponível em: <https://www.alice.cnptia.embrapa.br/bitstream/doc/1112094/1/13Veiga.pdf>, Agosto, 2019.