

Failure analysis of sugarcane cultivation from images of Remotely Piloted Aircraft

José Érico do N. Barros^{*}, Ana Lúcia B. Candeias^{**}, João R. Tavares Junior^{***}

^{*}Mestre em Ciências Geodésicas e Tecnologias da Geoinformação; Universidade Federal de Pernambuco (UFPE), Recife-PE.
E-mail: erico_barros@yahoo.com.br

^{**}Professor Associado III; Universidade Federal de Pernambuco (UFPE), Recife-PE. E-mail: ana.candeias@ufpe.br

^{***}Professor Adjunto III; Universidade Federal de Pernambuco (UFPE), Recife-PE. E-mail: joao.tavaresjr@ufpe.br

Received 20 April 2021; accepted 31 July 2021

Abstract

Precision Agriculture aims at the detailed management of the agricultural production system. High resolution orbital sensors have limitations such as temporal resolution and cloud cover. The RPA (Remotely Piloted Aircraft) appears as an option to assist in Precision Agriculture, since the acquisition of the images can be decided according to the need of the study of the planting and, therefore, no longer having the limitation of the temporal resolution of imaging. In addition, the cloud cover problem is no longer a problem as there is the advantage of being able to plan the flight to a lower altitude than the clouds present in the area. This study shows how the obtaining of the products of a cartographic base, produced from an aerial survey of a Remotely Piloted Aircraft, makes it possible to detect failures in sugarcane cultivation from orthomosaic generated by three - dimensional processing. The collection of information on the geographic distribution gives us support for the development of this work, aiming to subsidize the management of private resources in agriculture, enabling the improvement of productivity.

Keywords: Geographic information system. Precision agriculture. Remotely piloted aircraft.

Análise de falhas no cultivo da cana de açúcar a partir de imagens de Aeronave Remotamente Pilotada

Resumo

A Agricultura de Precisão visa o gerenciamento detalhado do sistema de produção agrícola. Os sensores de alta resolução orbital possuem limitações tais como a resolução temporal e o recobrimento de nuvens. O RPA (*Remotely Piloted Aircraft* ou Aeronave Remotamente Pilotada) surge como opção para auxiliar na Agricultura de Precisão, pois a obtenção das imagens pode ser decidida conforme a necessidade do estudo do plantio e, portanto, não tendo mais a limitação da resolução temporal de imageamento. Além disso, o problema de recobrimento de nuvens não é mais um problema, pois pode-se planejar o voo para uma altitude inferior às nuvens presentes na área. Este estudo mostra como a obtenção dos produtos de uma base cartográfica, produzida a partir de um aerolevante de uma Aeronave Remotamente Pilotada possa detectar falhas no cultivo da cana de açúcar a partir do ortomosaico gerado pelo processamento tridimensional. A coleta de informações sobre a distribuição geográfica nos dá suporte para o desenvolvimento deste trabalho, visando a subsidiar o gerenciamento de recursos privados na agricultura, permitindo uma melhoria da produtividade.

Palavras Chave: Sistema de informação geográfica. Agricultura de precisão. Aeronave remotamente pilotada.

1. Introdução

O crescimento de produtividade dos cultivos na agricultura está diretamente ligado a metodologias mais eficientes (MAPA, 2011). Uma delas é a Agricultura de Precisão, que demanda o conhecimento detalhado e prévio de informações geográficas e georreferenciadas dessas atividades. Tem-se uma redução das perdas de produção e, além disso, tem-se o conhecimento de fatores que contribuem nos resultados obtidos.

Segundo Zhang e Kovacs (2012), os Veículos Aéreos Não Tripulados (VANTs) são ferramentas importantes na aquisição de dados e informações para uma Agricultura de Precisão. Eles têm a vantagem de possuírem, geralmente, pequenas dimensões, são controladas remotamente, e possuem sensores embarcados que registram respostas espectrais de alvos em solo.

A legislação que regulamenta o uso desses equipamentos, segundo Silva et al. (2020) e ANAC (2017), utiliza a denominação de Aeronave Remotamente Pilotada (RPA - *Remotely Piloted*

Aircraft). Nesta pesquisa, foi adotada a nomenclatura de RPA para este tipo de aeronave, visto que é a forma mais recente ao qual foi atribuída.

Antuniassi e Salvador (2002) mostram que os VANTs têm contribuído para maximizar a produtividade através da prática da Agricultura de Precisão na identificação de anormalidades e na condução de tratos culturais em lavouras comerciais.

Segundo o Ministério da Agricultura Pecuária e Abastecimento (MAPA, 2011), Agricultura de Precisão compreende um conjunto de técnicas e metodologias que visam aperfeiçoar o manejo das culturas e a utilização dos insumos agropecuários, proporcionando máxima eficiência econômica.

Falhas no plantio são fatores que contribuem com o decréscimo da produtividade na cana de açúcar. Denota-se como falha, a projeção da distância entre duas canas consecutivas ao longo da linha de plantio.

Ao longo dos anos, foi empregada metodologias manuais para a mensuração das falhas,

sendo bastante trabalhosa a extração dessas informações, além de estabelecerem uma quantificação de forma probabilística (Stolf et al., 2016).

Essa pesquisa desenvolveu uma proposta para extração semi-automática de falhas do plantio de cana de açúcar utilizando processamento de imagens e ortomosaicos gerados a partir de dados obtidos por RPAs. Essa semi-automatização busca contribuir para o controle da produção do plantio com a identificação de possíveis locais com problemas no solo ou decorrentes da irrigação da área.

2. Material e métodos

Este trabalho foi realizada na Zona Rural do município de Paudalho (Figura 1), estado de Pernambuco, localizado na Zona da Mata Norte, fazendo limite ao Norte com Tracunhaém, ao Sul com Camaragibe, São Lourenço da Mata, Chã de Alegria e Glória de Goitá a Leste com Abreu e Lima e Paulista e a Oeste com Lagoa de Itaenga e Carpina.



Figura 1 – Área de estudo.

O município se estende por 277,51 km², está inserida na bacia hidrográfica do rio Ipojuca e, possui uma população total de 51.374 habitantes de acordo com o último censo tendo uma densidade demográfica de 185,1 habitantes por km² (IBGE, 2020).

A principal atividade econômica do município é composta pela plantação de cana de açúcar. A área selecionada para os estudos apresenta, em quase todo seu território, as atividades de cultivo de cana de açúcar e uma pequena porção de Mata Atlântica que representa menos de 5% da área selecionada (IBGE, 2020).

As etapas do trabalho são elencadas a seguir.

- 1) Obtém-se as imagens por RPA.
- 2) Gera-se o ortomosaico.
- 3) Faz-se a vetorização das linhas de plantio manualmente (Figura 2). É uma etapa importante para a análise, pois é a partir delas que se obtém o comprimento total do que foi cultivado, e de onde se dará a análise das falhas de forma estatística.
As linhas de plantio representam a totalização do que foi plantado em termos de distâncias. Esta etapa recebe como dado de entrada, uma imagem contendo a plantação de cana de açúcar, e como resultado de saída, as linhas de cana de açúcar que a compõem. A grande dificuldade desta etapa, como comentam Stolf et al. (2016) é a falta de padrão das linhas e do tamanho das plantas.
- 4) Após a vetorização manual das linhas de plantio, tem-se a etapa de Processamento Digital das Imagens (PDI). Utiliza-se a transformação do

modelo de cores RGB (*Red, Green and Blue*) para IHS (*Intensity, Hue and Saturation*) da imagem obtida pelo RPA. Esse tipo de transformação pode ser visto em Centeno (2007), Crósta (1993) e Richards, (1993).

- 5) A partir da componente H da transformação IHS do ortomosaico, aplica-se a classificação não supervisionada por k-médias. Nesse tipo de classificador utiliza-se a técnica onde os pixels de uma imagem são atribuídos às classes espectrais sem que haja qualquer tipo de conhecimento sobre a existência ou nome dessas classes. Os procedimentos de classificação automática não supervisionada, como o k-médias, substituem a análise ou a interpretação visual da imagem por técnicas quantitativas e não subjetivas, que identificam automaticamente os padrões de cobertura terrestre existente em uma cena. O algoritmo k-médias é um procedimento iterativo que busca minimizar a variância interna dos agrupamentos que são formados durante o processo de particionamento dos dados e assim obter as classes (clusters) da classificação (Crósta, 1993; Richards, 1993; Centeno, 2007).
- 6) A partir da componente H da transformação IHS do ortomosaico, faz-se também a classificação supervisionada por Máxima Verossimilhança (Crósta, 1993; Richards, 1993; Centeno, 2007), e se utiliza a mesma quantidade de classes que a do método de k-médias.
- 7) Compara-se os resultados da classificação por k-médias e por Máxima Verossimilhança e o quantitativo das falhas por tamanho.




Figura 2 – Linhas de plantio vetorizadas.

Utilizou-se o software SPRING para a obtenção da componente H da transformação IHS, e também para a classificação k-médias, e Máxima

Verossimilhança (Maxver). Utilizou-se o QGIS para a vetorização das linhas de plantio, e também para obter o quantitativo das falhas por tamanho

3. Resultados e discussão

Na Figura 3 apresenta-se a componente H (Hue) da transformação IHS, e onde as partes mais claras, representam a vegetação (camada de interesse), com valores de nível de cinza próximos a 80, e um desvio padrão que irá depender do tipo de plantação. Nessa componente H, também se tem algumas pequenas áreas em branco e outras partes bem escuras. Essas áreas representam o solo exposto

(áreas amareladas, alaranjadas ou avermelhadas nos ortomosaicos) e que na componente H ficam tons de cinza próximos ao branco ou próximos ao preto.

Quando se transforma a imagem, do modelo RGB para o IHS, tem-se um destaque das falhas da vegetação na banda resultante H, e esse resultado é o dado de entrada para a classificação automática não supervisionada k-médias e também para a supervisionada por Máxima Verossimilhança.




Figura 3 – Banda H (matiz) resultante da transformação RGB.

Para a classificação k-médias utilizou-se a componente H, dez iterações e testou-se os resultados para três e quatro classes. Os resultados foram muito similares havendo diferenças basicamente nas sombras formadas pela altura da cana de açúcar.

Portanto, decidiu-se utilizar apenas três classes (vegetação, sombra, solo) com um total de 10 iterações. Na Figura 4 é mostrada apenas a classe vegetação (em azul) extraída por essa classificação e sobreposta ao ortomosaico.




Figura 4 – Vegetação extraída do algoritmo k-médias.

Utilizou-se também a classificação supervisionada por máxima verossimilhança (Maxver). As amostras foram previamente selecionadas, e supôs-se que a distribuição das classes era do tipo gaussiana. Na Figura 5, tem-se apenas a classe vegetação (em vermelho) sobreposta a imagem do ortomosaico. (Figura 5).

Para o talhão de estudo, foram discretizados os elementos presentes na área, compreendendo de solo exposto e vegetação (cana de açúcar). Foram

definidas 3 classes para a extração das informações: Classe 1: Solo exposto mais claro, Classe 2: Solo exposto mais escuro e Classe 3: Vegetação (cana de açúcar).

Para cada classe foram coletadas dez amostras de pixels no terreno. Para a classe da vegetação, regiões com sombras foram consideradas como elementos de vegetação, já que tais sombras aparecem ao bordo das linhas de plantio.




Figura 5 – Vegetação extraída do algoritmo Maxver.

Pelo resultado da classificação não supervisionada e supervisionada, foi possível extrair a informação da vegetação presente na área estudada. Os produtos RASTER obtidos pelas classificações foram transformados em produtos vetoriais. Utilizou-se para isso o software QGIS. Nesta etapa é realizada a transformação RASTER para polígono que está disponível em plataforma GIS. Esta ferramenta produz os polígonos resultantes da classificação e ao mesmo tempo permite realizar uma simplificação de sua geometria.

Com a transformação concluída, a próxima etapa foi isolar os polígonos de interesse, já que o produto resultante contém toda a informação do RASTER inicial. Com a tabela de atributos é possível extrair os polígonos pertencentes à classe de vegetação, bem como calcular as áreas de cada polígono.

A extração das feições da vegetação neste procedimento foi simples, obtendo a exportação a partir de ferramentas de geoprocessamento, transformando ao final o RASTER obtido em polígonos. Com esses polígonos simplificados, foi possível extrair apenas os polígonos que representam a vegetação. Os polígonos gerados podem ser divididos em dois tipos: os de interesse (grandes

polígonos) e os de não interesse (pequenos polígonos e aqui chamados de partículas) para os procedimentos. Essas partículas possuem áreas muito pequenas que podem ser visualizadas através da tabela de atributos.

O produto final desta parte do geoprocessamento é a cana de açúcar que foi considerada como plantada após 90 dias do início do plantio. Existe um efeito comparativo entre a imagem original sobreposta aos polígonos extraídos da classificação para verificar visualmente a qualidade final obtida pelos produtos produzidos.

Com a separação dos polígonos, foi possível extrair, a partir das ferramentas de geoprocessamento, a diferença entre as linhas de plantio traçadas inicialmente, com os polígonos gerados, após as classificações, exibindo como resultado, as falhas de plantação. O traçado final foi obtido após a aplicação de funções disponíveis em ambiente GIS. Foi aplicado o corte das linhas de plantio usando como máscara de recorte os polígonos obtidos pelas classificações. Com as linhas resultantes, foram calculados os comprimentos de cada uma.

O produto final de todo este procedimento são as falhas no plantio de cana de açúcar. A Figura

6(a) e a Figura 6(b) mostram, respectivamente, a área total com as falhas de cada algoritmo utilizado e, o detalhamento como o resultado final. O resultado dos

vetores resultantes que representam as falhas (em vermelho), nos respectivos classificadores, pode ser visto comparando as figuras descritas a seguir.




Figura 6 – Falhas resultantes do plantio. (a) Falhas, em vermelho, resultantes do plantio usando o algoritmo k-médias. (b) Falhas, em vermelho, resultantes do plantio usando algoritmo Maxver.

A etapa seguinte compreendeu da análise quantitativa das falhas em relação a cada classificação usada na pesquisa. A Tabela 1, mostra a quantidade de vezes que a falha é contabilizada. Foi considerada para a montagem das tabelas, o limite de 200 centímetros (2 metros) como tamanho máximo da falha, pois aqui procura-se mostrar a parte significativa em relação ao quantitativo.

A Tabela 1 mostra a quantidade de vezes que um determinado tamanho de falha acontece na região estudada em relação a cada classificação. A representatividade equivale ao tamanho total de falhas para cada comprimento e o percentual ao tamanho total das linhas vetorizadas as quais foram

calculadas anteriormente, enquanto a Tabela 2 mostra a diferença entre os quantitativos dos comprimentos das falhas e sua representatividade.

Na Tabela 2 que mostra a diferença entre os classificadores k-médias e MaxVer. Observa-se que, na medida em que o tamanho da falha vai aumentando, a diferença entre os classificadores diminui, implicando que, a ocorrência de falhas com tamanhos maiores é menos expressiva quantitativamente, que as falhas de tamanhos menores. Como estudado em sessões anteriores nesta pesquisa, a definição de que o tamanho de falha a ser considerado seja de 50 cm confere em bons resultados para os dois classificadores aqui utilizados.

Tabela 1 – Quantitativo das falhas por tamanho.

Comprimento (cm)	K-Médias			Supervisionada		
	Quantidade	Representatividade (m)	%	Quantidade	Representatividade (m)	%
10	1909	190,90	3,97%	1585	158,50	3,29%
20	1504	300,80	6,25%	1266	253,20	5,26%
30	1214	364,20	7,57%	1050	315,00	6,55%
40	993	397,20	8,26%	876	350,40	7,28%
50	811	405,50	8,43%	742	371,00	7,71%
60	683	409,80	8,52%	622	373,20	7,76%
70	570	399,00	8,29%	520	364,00	7,57%
80	479	383,20	7,97%	449	359,20	7,47%
90	408	367,20	7,63%	387	348,30	7,24%
100	358	358,00	7,44%	322	322,00	6,69%
110	310	341,00	7,09%	281	309,10	6,42%
120	273	327,60	6,81%	255	306,00	6,36%
130	234	304,20	6,32%	229	297,70	6,19%
140	207	289,80	6,02%	208	291,20	6,05%
150	188	282,00	5,86%	189	283,50	5,89%
160	156	249,60	5,19%	165	264,00	5,49%
170	140	238,00	4,95%	149	253,30	5,27%
180	129	232,20	4,83%	137	246,60	5,13%
190	116	220,40	4,58%	124	235,60	4,90%
200	109	218,00	4,53%	115	230,00	4,78%

Tabela 2 – Diferença entre os classificadores.

Comprimento (cm)	K-Médias	Supervisionada	Diferenças	Diferenças por tamanho (m)	%
	Quantidades				
10	1909	1585	324	32,40	0,67%
20	1504	1266	238	47,60	0,99%
30	1214	1050	164	49,20	1,02%
40	993	876	117	46,80	0,97%
50	811	742	69	34,50	0,72%
60	683	622	61	36,60	0,76%
70	570	520	50	35,00	0,73%
80	479	449	30	24,00	0,50%
90	408	387	21	18,90	0,39%
100	358	322	36	36,00	0,75%
110	310	281	29	31,90	0,66%
120	273	255	18	21,60	0,45%
130	234	229	5	6,50	0,14%
140	207	208	1	1,40	0,03%
150	188	189	1	1,50	0,03%
160	156	165	9	14,40	0,30%
170	140	149	9	15,30	0,32%
180	129	137	8	14,40	0,30%
190	116	124	8	15,20	0,32%
200	109	115	6	12,00	0,25%

As diferenças de alturas entre as curvas (Figura 7) foram representadas na Tabela 2 pelo campo “Diferenças”. Podemos visualizar que tamanhos maiores que 50 cm (que foram considerados nesta pesquisa como falhas), entre as duas curvas diminuem a medida que o tamanho das falhas aumenta.

A Figura 7 apresenta o quantitativo das falhas observadas quando se usa o classificador k-médias e quando se usa o MaxVer. Observa-se que o eixo x do gráfico, representa o comprimento das falhas e o eixo y, representa os quantitativos encontrados.

Para o gráfico de k-médias (Figura 7), observou-se uma grande quantidade de unidades de falhas menores que 10 cm. Esses tamanhos foram considerados como ruídos e não constaram nas tabelas anteriores no qual partiu-se de tamanhos maiores que 10 cm. É justamente nesses tamanhos que a curva tem a queda mais acentuada.

Para o gráfico do MaxVer (Figura 7), a quantidade de ruídos (tamanhos menores que 10 cm) foi bem menor, o padrão da curva apresentou maior suavização à medida que os tamanhos foram aumentando.




Figura 7 – Quantidade das falhas para os algoritmos MaxVer (Supervisionada) e k-médias.

No gráfico pode-se perceber a questão referente às falhas maiores que 2 m, cujos dados são pouco representativos. As tendências das curvas (Figura 7) foram muito parecidas à medida que o comprimento aumentou.

4. Conclusão

As bases cartográficas geradas pelos RPAs foram: Ortomosaico, Modelo Digital de Superfície (MDS), Modelo Digital do Terreno (MDT) e Curvas de nível. Os produtos obtidos também podem servir para outros usos e ocupação do solo. Esses dados são, portanto, promissores e de baixo custo de aquisição, aliados à excelente qualidade de dados gerados, altíssima resolução espacial e temporal atreladas ao

produto, se comparado com métodos de obtenção de dados cartográficos convencionais. A base de dados poderá servir para uma gestão inteligente do plantio de forma que possibilita um melhor aproveitamento produtivo da área.

Os métodos de classificação utilizados mostraram resultados coerentes entre si e também com a realidade encontrada no campo. Isso também se deve a qualidade dos dados resultantes das classificações, ficando excelente de acordo com a altíssima resolução espacial do ortomosaico utilizado. A análise das classes foi realizada visualmente, pois a alta resolução permitiu constatar a acurácia visual dos vetores extraídos de cada classificação.

De acordo com os resultados obtidos nesta pesquisa, a cobertura linear das linhas de plantio que

foram vetorizadas foi de 4811 metros, com uma área de plantio de aproximadamente 0,7 hectares. Na área estudada houve uma grande identificação de falhas que ocorreu em média de 29% considerando as duas classificações da área o que representa uma grande fatia do que foi inicialmente plantado. O tamanho linear médio das falhas foi de 3,09 m, considerando 50 cm como falha.

Os resultados obtidos com o uso dos algoritmos MaxVer e k-médias, mostrou que procedimentos de extração de falhas no plantio de cana de açúcar são de extrema confiança. Não somente no cultivo de cana de açúcar, os procedimentos podem ser aplicados, mas outros cultivos também nos possibilitam aplicar as técnicas de processamento de imagem com a técnica de IHS, aqui expostas.

Referências

- ANAC. Agência Nacional de Aviação Civil, 2017. Regras sobre Drones. Regulamento Brasileiro de Aviação Civil Especial – RBAC – E n. 94.
- Antuniassi, U.R., Salvador, A., 2002. Análise de imagens aéreas para mapeamento de plantas daninhas em sistemas de agricultura de precisão. Simpósio Internacional de Agricultura de Precisão, Viçosa.
- Centeno, J.A.S., Ribeiro, S.R.A., 2007. Um método simplificado de fusão de imagens. Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis.
- Crósta, A.P., 1993. Processamento Digital de Imagens de Sensoriamento Remoto. UNICAMP, Campinas.
- IBGE. Instituto Brasileiro de Geografia e Estatística, 2020. Brasil/Pernambuco/Paudalho. Disponível: <https://cidades.ibge.gov.br/brasil/pe/paudalho/panorama>. Acesso: 30 out. 2020.
- MAPA. Ministério da Agricultura Pecuária e Abastecimento, 2011. Agricultura de precisão. Boletim Técnico. Brasília.
- Richards, J.A., 1993. Remote Sensing Digital Image Analysis. 2nd Ed. Wiley, New York.
- Silva, R.S., Silva, R.S.M., Regis, J.A.A., Teixeira, J.R., 2020. Acesso ao espaço aéreo brasileiro por aeronaves não tripuladas. Revista do CIAAR 1, 23-40.
- Stolf, R., Garcia, T.B., Neris, L.O., Trindade Junior, O., Reichardt, K., 2016. Avaliação de falhas em cana de açúcar segundo o método de Stolf utilizando imagens aéreas de alta precisão obtidas por VANT. STAB 34, 32-39.
- Zhang, C., Kovacs, J.M., 2012. The application of small unmanned aerial systems for precision agriculture: a review. Precision Agriculture 13, 693-712.