

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**MÉTODO NÃO DESTRUTIVO PARA PREDIÇÃO DA
MATURAÇÃO DE AMENDOIM (*Arachis hypogaea* L.)
UTILIZANDO SENSORIAMENTO REMOTO**

Adão Felipe dos Santos

Engenheiro Agrônomo

2019

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**MÉTODO NÃO DESTRUTIVO PARA PREDIÇÃO DA
MATURAÇÃO DE AMENDOIM (*Arachis hypogaea* L.)
UTILIZANDO SENSORIAMENTO REMOTO**

Adão Felipe dos Santos

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientadores: Prof. Dr. George Vellidis

Profa. Dra. Priscila Lupino Gratão

Profa. Dra. Brenda Valeska Ortiz

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

2019

Santos, Adão Felipe
S237m Método não destrutivo para predição da maturação de
amendoim (*Arachis hypogaea*) utilizando sensoriamento
remoto / Adão Felipe dos Santos. – – Jaboticabal, 2019,
107 p.: il., tabs., fotos

Tese (doutorado) - Universidade Estadual Paulista,
Faculdade de Ciências Agrárias e Veterinárias, 2019

Orientador: Rouverson Pereira da Silva
Coorientadores: George Vellidis

1. Agricultura de precisão. 2. Amendoim. 3. Drones. 4.
Satélites. 5. Sensoriamento remoto. I. Título.

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



UNIVERSIDADE ESTADUAL PAULISTA

Campus de Jaboticabal



CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: MÉTODO NÃO DESTRUTIVO PARA PREDIÇÃO DA MATURAÇÃO DE AMENDOIM
(*Arachis hypogaea*) UTILIZANDO SENSORIAMENTO REMOTO


AUTOR: ADÃO FELIPE DOS SANTOS
ORIENTADOR: ROUVÉRSO PEREIRA DA SILVA
COORIENTADORA: PRISCILA LUPINO GRATÃO
COORIENTADORA: BRENDA VALESKA ORTIZ
COORIENTADOR: GEORGE VELLIDIS

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA
(PRODUÇÃO VEGETAL), pela Comissão Examinadora:


Prof. Dr. ROUVÉRSO PEREIRA DA SILVA
Departamento de Engenharia Rural / FCAV / UNESP - Jaboticabal


Prof. Dr. LUIS CARLOS CIRILO CARVALHO
Universidade Estadual de Santa Cruz-UESC / Ilhéus/BA


Prof. Dr. CRISTIANE PILON (Videoconferência)
University of Georgia / Athens/Georgia


Prof. Dr. LEONARDO CAMPOS DE ASSIS
Instituto de Ciências e Tecnologia do Ambiente-Uniube / Uberaba/MG


Prof. Dr. WILLIAMS CÉSAR CARREGA
APTA / Pindorama/SP

Jaboticabal, 18 de julho de 2019

DADOS CURRICULARES DO AUTOR

ADÃO FELIPE DOS SANTOS – nascido em Patos de Minas, Minas Gerais, no dia 16 de janeiro de 1991, filho de Lázaro Rodrigues dos Santos (*in memorian*) e Ilda Rodrigues Galvão (*in memorian*), natural de Lagoa Grande - MG. Cursou o Ensino Fundamental na Escola Estadual Santa Terezinha, deste município, e Ensino Médio na Escola Estadual João Batista de Carvalho concomitantemente com o curso Técnico em Agricultura e Zootecnia no Centro Federal de Educação Tecnológica de Bambuí, na cidade de Bambuí - MG, tendo finalizado no ano de 2008. Ingressou no Ensino Superior no ano de 2009 no curso de Engenharia Agrônoma pela Universidade Federal do Tocantins (UFT), Câmpus de Gurupi, obtendo o título de Engenheiro Agrônomo, em outubro de 2014. Durante a graduação foi bolsista de Iniciação Científica (CNPq e UFT) por três anos, na área de Genética e Melhoramento de Soja. Participou do projeto Rondon no ano de 2011, Operação Tuiuiú, como integrante da equipe de Ciências Agrárias. Em março de 2015, iniciou o curso de Mestrado em Agronomia (Produção Vegetal), com concentração na área de Máquinas e Mecanização Agrícolas, pela Universidade Estadual Paulista “Júlio de Mesquita Filho” – Câmpus de Jaboticabal, São Paulo, no Laboratório de Máquinas e Mecanização Agrícola (LAMMA), onde realizou a dissertação envolvendo o uso do piloto automático com sinal RTX na colheita de amendoim. Em agosto de 2016 iniciou o curso de Doutorado (Produção Vegetal), no mesmo laboratório e instituição, onde realizou pesquisas utilizando sensoriamento remoto para identificar a maturação de amendoim. Em 2018 realizou estágio sanduiche durante 6 meses na Universidade da Georgia, Campus de Tifton, na oportunidade, desenvolveu pesquisas utilizando drones para predizer a maturação de amendoim juntamente com a equipe do Prof. Dr. George Vellidis.

“A vida é como uma câmera. Foque no que é importante, capture bons momentos, desenvolva a vida a partir de negativos. E, se as coisas não derem certo, tire outra foto. ”

(Autor desconhecido)

“A felicidade não se resume na ausência de problemas, mas sim na sua capacidade de lidar com eles. ”

(Albert Einstein)

Aos meus pais Lázaro Rodrigues dos Santos (*in memorian*), Ilda Rodrigues Galvão (*in memorian*) e aos meus tios que me criaram com todo o amor, carinho e educação que se pode dar a um filho, Justina Rodrigues Caetano e Antônio Rodrigues Caetano (*in memorian*).

A vocês, DEDICO!

À todas as minhas irmãs, sobrinhos (as), familiares e amigos, OFEREÇO!

Agradecimentos

Em primeiro lugar agradeço a Deus por ter sempre me amparado nas minhas escolhas para que não me arrependesse e nem desistisse delas, por mais difíceis que fossem.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Câmpus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa e oportunidade de realizar um curso de pós-graduação.

À Universidade da Georgia, Campus de Tifton, onde eu realizei os 6 meses de doutorado sanduiche, bem como à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de doutorado sanduiche.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Às minhas irmãs, Simonia Aparecida dos Santos, Maria Aparecida dos Santos, Eva Maria dos Santos e Maria Amélia dos Santos e seus filhos, pela paciência e pela ausência em suas vidas, durante todos esses anos de estudos até aqui. Obrigado por vocês acreditarem em mim!

Ao meu estimado orientador Prof. Dr. Rouverson Pereira da Silva, que eu tenho uma admiração e consideração imensa pelo seu trabalho, bem como pela referência que é para todos nós, orientandos. Saiba que aprendi muito com você durante todos esses anos de convivência, tanto pelo lado profissional e principalmente no pessoal. Muito obrigado por todas as oportunidades que me proporcionou, as quais foram importantes para que eu pudesse alimentar a confiança em mim mesmo. Estamos encerrando um ciclo entre orientador e orientando, mas iniciando outro como colegas de trabalho. Conte comigo sempre que precisar, eterno orientador, que muitas vezes é um pai.

Ao meu coorientador da Universidade da Georgia (UGA), Prof. Dr. George Vellidis, por ter me dado à oportunidade de fazer parte do seu time durante o período do doutorado sanduiche. Muito obrigado por todos os ensinamentos, paciência e confiança que foram depositadas em mim para execução do trabalho. Na

oportunidade e não menos importante, também ressalto o meu muito obrigado a Prof. Dra. Cristiane Pilon, fisiologista de amendoim da UGA, que sempre abriu as portas da sua sala para que pudéssemos discutir os resultados que foram encontrados nos experimentos realizados nos EUA.

À minha coorientadora Prof. Dra. Priscila Lupino Gratão que não mediu esforços para poder me ajudar a encontrar respostas para os resultados obtidos dos experimentos no Brasil, bem como nos conselhos toda vez que fui até a sua sala.

Aos Professores. Dr. Carlos Eduardo Angeli Furlani e Cristiano Zerbato, aos Técnicos David Trevizoli, Marquinho e Valdecir Aparício por toda ajuda, conhecimento e experiências trocadas, e a todos os outros funcionários do Departamento de Engenharia Rural.

A toda família da República TOca Fogo, Edgard Silva, Mailson Oliveira, João Godinho, Luan Oliveira, Everton Carvalho, Antonio Tassio, Emmanuel Pereira, Emiliano Brandão, Renato Soares, juntamente com todos aqueles que fazem e fortalecem o nosso círculo de amizade, Taynara Valeriano, Stefany Souza, Maria Albertina, Kárita Almeida, Larissa Nogueira, Letícia Santos e Karol Emiliano Meu muito obrigado por compartilharem comigo desse momentos únicos da minha vida e por suportarem o meu bom-humor matinal e entre outros.

Aos meus amigos e parceiros do Laboratório de Máquinas e Mecanização Agrícola, Alex Gonzaga, Aline Alcântara, Bruno Rocca, Danilo Tedesco, Elizabeth Kazama, Francieli Ferreira, Francieli Morlin, Francisca Nivanda, Francisca Edcarla, Jean Lucas, Lucas Gírio, Mailson Oliveira, Marco Antonio, Patricia Menezes, Paulo Cordeiro, Renata Queiroz, Samira Almeida, Tiago Tavares e Watus Costa, e principalmente à Lígia Negri, a qual foi parceira durante todas as avaliações. Sem a ajuda de vocês não seria possível a realização deste trabalho.

À Lorena Lacerda e Leticia Moreno pela amizade, parceria e toda ajuda durante o doutorado sanduiche, sem vocês provavelmente eu não teria conseguido realizar todas as análises que fizemos. Muito obrigado também pelos finais de semana de descontração em Tifton.

Aos amigos americanos David Daughtry, Chelsey Daughtry e Chyanny Poppe os quais conheci durante o doutorado sanduiche na Universidade da Georgia, que se tornaram uma verdadeira família para mim nos EUA.

Aos colegas de departamento da UGA, Kade Fue Arianna Toffanin, Vasileios Liakos, Dimitris Pavlou, Ahmed Rabia, Aaron Bruce, Matthew Gruver, Anna Orfanou, Stefano Gobbo, Ben Holden e aos brasileiros Beatriz Fabreti, Vinícius Perino e Joara Candian. Muito obrigado por me ensinar um pouco da cultura de cada um de vocês.

Aos meus amigos Aquiles Pinheiro, Priscila Fonseca, Marcela Vidica e Maria Tereza, com os quais mantenho contato desde a graduação e que sei que sempre posso contar.

Aos proprietários da Fazenda Santa Cândida, em especial ao Netto Souza por terem disponibilizado a área experimental e facilitar a realização deste trabalho.

À Cooperativa Agroindustrial de amendoim, Cooplane, representada na pessoa do Pablo e Thais, do setor de tecnologia da mesma, muito obrigado por toda a parceria durante o desenvolvimento deste trabalho

À PlanetScope por disponibilizar o acesso gratuito às imagens de satélite por meio da licença educacional.

Enfim, a todos que de alguma forma contribuíram para que eu chegasse até aqui, o meu muito obrigado! Vocês sempre serão agraciados de alguma forma.

SUMÁRIO

Página

RESUMO.....	xiii
ABSTRACT	xiv
CAPÍTULO 1 – Considerações Gerais	1
Introdução	1
Hipóteses	3
Objetivos	3
Revisão bibliográfica	4
Panorama da cultura do amendoim	4
Fisiologia do amendoim	6
Flores	6
Folhas	8
Vagens	8
Métodos para avaliar a maturação de amendoim	9
Sensoriamento remoto	15
Índices de vegetação	19
Controle Estatístico de Processo (CEP).....	21
Referências bibliográficas	23
Capítulo 2: Qualidade dos dados obtidos por drone e satélites de alta resolução no monitoramento da maturação da cultura do amendoim	29
Resumo.....	29
Abstract	30
Introdução	30
Material e Métodos.....	32
Resultados	36
Discussão.....	44
Conclusões.....	47
Referências	48
Capítulo 3: Using aerial remote sensing to map in-field variability of peanut maturity	53

Abstract	53
Introduction.....	53
Materials and Methods	56
Results and discussion.....	60
Conclusion.....	66
Acknowledgements	67
Conflict of Interest	67
References	67
Capítulo 4: É possível prever a maturação de amendoim utilizando imagem de satélite?	72
Resumo	72
Abstract	73
Introdução	74
Material e métodos.....	76
Área de estudo	76
Imagens de satélite	76
Análise da maturação.....	78
Análise dos dados	79
Resultados	79
Discussão.....	86
Conclusão	88
Referências bibliográficas	88
Capítulo 5: Considerações finais.....	92

MÉTODO NÃO DESTRUTIVO PARA PREDIÇÃO DA MATURAÇÃO DE AMENDOIM (*Arachis hypogaea* L.) UTILIZANDO SENSORIAMENTO REMOTO

RESUMO

A utilização de técnicas de sensoriamento remoto teve expressivo aumento na agricultura nos últimos anos para muitas culturas, contudo, ainda são escassos os trabalhos que envolvem a cultura de amendoim, principalmente os que visam solucionar um dos seus principais problemas, a predição da maturação. Dessa forma, foram desenvolvidos trabalhos no Brasil e nos EUA visando verificar o potencial uso do sensoriamento aéreo e orbital na predição da maturação de amendoim. No primeiro capítulo desta tese, encontra-se a revisão de literatura. No segundo, realizou-se uma análise de variabilidade utilizando cartas de controle para identificar diferenças no comportamento da reflectância espectral e dos índices de vegetação obtidos por imagens de drone e do satélite PlanetScope, em que se chegou à conclusão que as duas plataformas apresentam comportamento similares ao longo do tempo. No terceiro capítulo, foram utilizadas duas áreas comerciais nos EUA, irrigada e não irrigada, e as imagens foram obtidas por meio de drone. Observou-se que os índices de vegetação que tiveram comportamento similar nas duas áreas foram aqueles em que se modificou a equação original, substituindo a banda do *red* pelo *red edge* (NLI e MNLI). No quarto capítulo, utilizou-se uma área comercial no Brasil, sendo as imagens utilizadas para extrair a reflectância obtidas do satélite PlanetScope. Os melhores índices de vegetação, com menores erros na predição da maturação foram o NDVI e o SR. Por fim, no capítulo cinco, tem-se as considerações finais com algumas recomendações e os próximos passos da pesquisa.

PALAVRAS-CHAVE: Predição da maturação, índices de vegetação, colheita de precisão, PlanetScope, Drones.

A NON-DESTRUCTIVE METHOD TO PREDICT PEANUT (*Arachis hypogaea* L.) MATURITY USING REMOTE SENSING

ABSTRACT

The use of remote sensing techniques has had a significant increase in agriculture in recent years for many crops; however, the work involving peanut cultivation is still scarce, especially in order to solve one of the main problems of the crop, the prediction of maturity. Thus, work was developed in Brazil and the USA to verify the potential use of aerial and orbital remote sensing in the prediction of peanut maturity. The first chapter of this thesis is the literature review. In the second, a variability analysis was performed using control charts to identify differences in reflectance response and vegetation indices obtained by drone images and PlanetScope satellite, in which it was concluded that the two platforms have similar response over the period of time. In the third, two commercial areas were used in the USA, irrigated and non-irrigated, and the images were obtained by drone. It was observed that the vegetation indices that had similar response in both areas were those in which the original equation was modified, replacing the red band by the red edge (NLI and MNLI). In the fourth chapter, a commercial area was used in Brazil, with the images used to extract the reflectance obtained from PlanetScope satellite. The best vegetation indices, with the lowest errors in the prediction of maturity, were NDVI and SR. Finally, in chapter five, final considerations with some recommendations and the next steps of the research are stated.

KEYWORDS: Prediction of maturity, vegetation indices, precision agriculture, PlanetScope, Drones.

CAPÍTULO 1 – Considerações Gerais

Introdução

Esta tese está estruturada em cinco capítulos, que abordam técnicas de sensoriamento remoto aéreo para prever a maturação de amendoim. Este estudo se mostra relevante, pois traz uma nova abordagem para o setor acadêmico e comercial no monitoramento da maturação de amendoim, principalmente no Brasil.

Atualmente, produtores de todo o mundo utilizam o método *Hull-Scrape* para indicar qual o momento para o início da colheita de amendoim. Apesar de ser utilizado largamente em todos os países produtores de amendoim, o método *Hull-Scrape* é destrutivo, altamente subjetivo e não representa a variabilidade na maturação da área como um todo. Dessa forma, visando melhorar a estimativa do método de maturação, acredita-se que o sensoriamento remoto possa ser uma ferramenta capaz de prever a maturação de forma não destrutiva.

No primeiro Capítulo, é apresentado o referencial teórico que embasa a hipótese de que é possível utilizar o sensoriamento remoto como forma não-destrutiva de prever a maturação da cultura do amendoim, bem como a existência de vários outros trabalhos que estão tentando reduzir a subjetividade do método *Hull-Scrape*.

Como o sensoriamento remoto aéreo pode ser obtido por meio de drones e satélites, no segundo capítulo foi realizada uma análise da qualidade dos dados obtidos pelas duas plataformas (drone e satélite), sendo as imagens obtidas do satélite PlanetScope, satélite de alta resolução (~3 m) e de um drone de uma câmera multiespectral sequoia. A ferramenta utilizada foi o controle estatístico de processo, o qual permite inferir a qualidade de um processo. Os dados utilizados nessa análise foram provenientes de uma área comercial irrigada dos Estados Unidos.

No terceiro capítulo, são apresentados os resultados da utilização do sensoriamento remoto com uma câmera multiespectral sequoia acoplada a um drone em duas áreas comerciais dos EUA (área irrigada e não irrigada). Como a câmera possui quatro bandas espectrais (*green*, *red*, *near infrared* e *red edge*), a gama de índices de vegetação utilizados foi maior que nos demais capítulos, sendo eles, NDVI¹, GNDVI, NLI, MNLI e SR, NDRE, MSR e além desses, foram modificados os NLI, MNLI e SR, sendo a modificação representada pela troca da banda do vermelho pelo red edge.

No quarto Capítulo, os dados utilizados são provenientes de uma área comercial no Brasil, não irrigada, em que os índices de vegetação foram obtidos através de imagens do satélite PlanetScope. Neste Capítulo, foram utilizados os índices de vegetação NDVI, GNDVI, NLI, MNLI e SR. Por fim, no quinto capítulo, são apresentadas as considerações finais da tese, demonstrando os melhores resultados obtidos de forma objetiva e coesa, bem como algumas recomendações e os próximos passos da pesquisa.

¹ NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; NLI: non-linear index; MNLI: modified non-linear index; SR: simple ration.

Hipóteses

O sensoriamento remoto aéreo e orbital pode ser utilizado para prever a variabilidade da maturação do amendoim em larga escala, de maneira não destrutiva.

Existe diferença na qualidade dos dados obtidos por diferentes plataformas de sensoriamento remoto aéreo e orbital. Os índices de vegetação podem ter comportamentos diferentes na predição da maturação do amendoim quando obtidos em áreas irrigadas e não irrigadas.

Objetivos

Verificar o potencial uso do sensoriamento remoto na predição não destrutiva da maturação de amendoim.

Indicar qual índice de vegetação possui melhor correlação com a maturação de amendoim em áreas irrigada e não irrigada nos USA.

Comparar a variabilidade da reflectância obtida por imagens de drone e de satélite utilizando cartas de controle.

Revisão bibliográfica

Panorama da cultura do amendoim

Considerada a quarta oleaginosa mais cultivada no mundo, a cultura do amendoim (*Arachis hypogaea* L.) é semeada em larga escala no continente africano, asiático e nas américas, com o objetivo de produzir grãos, óleo e farelo, entre outros produtos (Ferrari-Neto et al., 2012). Também é considerada a segunda leguminosa em importância no mundo, sendo cultivada, principalmente, como importante fonte de proteína vegetal e de óleo, com grãos que podem apresentar até 50% de lipídeos (Nakagawa e Rosolem, 2011).

Apesar de dada importância, a produção mundial de amendoim não é tão expressiva quando comparada com outras culturas. Em uma visão macro, são produzidas cerca de 42 milhões de toneladas em todo o mundo, sendo a China, Índia e Nigéria os maiores produtores, com produção de 17,0, 4,7 e 3,2 milhões de toneladas, respectivamente (USDA, 2018). Ainda, segundo o levantamento da USDA, na América do Sul somente a Argentina e o Brasil produzem amendoim, sendo que a Argentina produz o dobro que o Brasil, devido à maior quantidade de áreas destinadas para a produção de amendoim, entretanto a produtividade do Brasil é superior.

A produção da safra de 2017/2018 no Brasil foi de 511,5 mil toneladas, o que representou aumento de 10% em relação à safra anterior (Conab, 2018). Das regiões produtoras, destaque para a região Sudeste onde se encontram as maiores áreas e, consequentemente, a maior produção. Ainda segundo dados da Conab (2018), o estado de São Paulo corresponde a 90% da produção nacional com produtividade média de 3.969 kg ha⁻¹.

O sistema de produção adotado no Brasil faz uso intensivo de práticas de preparo do solo convencional, devido ao fato de a cultura do amendoim ser utilizada

como sucessão com a cana-de-açúcar, o que coincide com o período de renovação dos canaviais (Ormond et al., 2018). Sobretudo, alguns trabalhos vêm sendo desenvolvidos com o intuito de verificar o potencial da aplicação de sistemas conservacionistas na produção de amendoim (Bolonhezi et al., 2007; Ormond et al., 2018). Além disso, no Brasil existem duas safras de semeadura da cultura, sendo uma no período das águas (mais expressiva, de novembro a março) e outra no período da seca (março a junho), porém, nenhuma delas adota sistema de produção irrigado.

De modo contrário ao sistema de produção do Brasil, nos Estados Unidos a produção de amendoim pode ser encontrada em áreas irrigadas e em preparo conservacionista do solo. O uso de práticas conservacionistas para a produção de amendoim teve aumento de 8 para 25% de 2004 para 2013 (USDA, 2017). Esse expressivo aumento na mudança de práticas de manejo se deve principalmente aos efeitos que este proporciona ao solo e, principalmente, à redução nos custos (Monfort et al., 2004). Estes fatores, associados às políticas de incentivo aos produtores de amendoim e a pesquisa, faz com que os EUA seja o quarto maior produtor mundial de amendoim, correspondendo a 2,48 milhões de toneladas (USDA, 2018). A produção total de amendoim é dividida em dez estados, sendo a Georgia responsável por cerca de 55% da produção nacional (NASS, 2017).

As altas produções no estado da Georgia são concentradas nas regiões Sul e Sudeste, as quais apresentam maior aptidão de solo e clima. Apesar de boa precipitação média anual, suficiente para o desenvolvimento da cultura do amendoim, estima-se que 45-55% das áreas produtoras na Georgia utilizem irrigação suplementar. A combinação desses fatores permite com que a semeadura de

amendoim possa ser realizada em meados de abril até início de julho (Peanut Production Guide, 2018).

Fisiologia do amendoim

A característica mais marcante do desenvolvimento das plantas de amendoim, que as distingue da maioria das outras oleaginosas, é a floração aérea, a autopolinização, a fertilização e a formação de ginóforos (“esporões”), seguidas por alongamento e penetração gravitrópica no solo e, posteriormente, frutificação subterrânea (Zhu et al., 2013). Para desenvolver tais processos, as principais estruturas visíveis das plantas de amendoim são: folhas, responsáveis por todo o aparato fotossintético; flores, local onde se encontram estruturas para fecundação; ginóforo, estrutura que tem por finalidade direcionar as vagens para o solo e translocar fotoassimilados e, por fim e não menos importante, o sistema radicular, que capta água e nutrientes.

Flores

A planta de amendoim possui o estigma e a antera juntos dentro da mesma estrutura na flor (quilha), o que permite a autofecundação. A polinização ocorre quase simultaneamente após a abertura das flores (antras), algumas horas após o nascer do sol. Após a fertilização, o embrião aguarda sua transferência para o solo (Shushu e Cutter, 1990). Isto é realizado por meio da formação do ginóforo, meristema intercalar localizado adjacente ao óvulo basal, que se alonga em direção à superfície do solo pelo movimento de geotropismo (Smith, 1950). Após a penetração do ginóforo

no solo, finaliza-se o processo de alongamento e inicia-se o processo de desenvolvimento dos frutos em sua extremidade (Pattee e Mohapatra, 1987).

Por ser uma planta de hábito de crescimento indeterminado, isso faz com que ela emita flores em diferentes estádios do ciclo reprodutivo da cultura. Entretanto, as plantas possuem um pico de florescimento que acontece entre as 9 e 12 semanas após a semeadura (Figura 1), ponto em que não deve acontecer restrição hídrica. No entanto, é possível observar que as primeiras flores ocorrem logo nas 5 primeiras semanas após a semeadura (Smith, 1954).




Figura 1. Padrão de florescimento das plantas de amendoim tipo *Runner* e *Spanish*.
(Adaptado de Smith, 1954).

Como resultado dessa alta variabilidade na floração, tem-se grande variabilidade de maturação das vagens em uma mesma planta, o que, conseqüentemente, interfere na qualidade das sementes e dificulta a decisão para o início da colheita (Sanders et al., 1982).

Folhas

Quanto às folhas de amendoim, essas são constituídas pela cutícula, epiderme superior, parênquima paliçádico, parênquima esponjoso e epiderme inferior. As folhas de amendoim possuem estrutura tetra-foliar com dois pares de folículos opostos (Singh, 2004). Os estômatos são encontrados na superfície adaxial e abaxial, no entanto, o posicionamento dos estômatos na parte abaxial tem sido atribuído à maximização da transmissão de luz através da epiderme superior e minimizando a perda de umidade quando os estômatos estão abertos (Campbell, 1996). As folhas exibem diariamente movimentos “*nyctiotropic*”, que consistem na junção dos folhetos adaxiais com o pecíolo que inclinam para baixo durante a noite (Rao e Murty, 1994).

Nas folhas, estão localizados os cloroplastos que contêm pigmentos fotossintéticos, incluindo a clorofila, a qual é diretamente correlacionada com a taxa fotossintética das plantas (Buttery e Buzzell, 1977). A estrutura do tecido mesófilo esponjoso e, em menor grau, do tecido paliçádico determina o comportamento da radiação infravermelha que entra através da epiderme. Essas estruturas são responsáveis pela alta refletância infravermelha da vegetação saudável, principalmente no infravermelho próximo (Campbell, 2002).

Vagens

O desenvolvimento das vagens de amendoim é responsivo à luz, uma vez que os processos de alongamento do ginóforo, desenvolvimento da vagem e do embrião na planta de amendoim são, principalmente, relativos a condições de luz (presença e ausência), estímulo mecânico e substâncias de crescimento (Moctezuma, 2003). Assim, a presença de luz aumenta a taxa de alongamento do ginóforo e inibe a formação das vagens. De modo contrário, a ausência impede o alongamento do

ginóforo e promove o desenvolvimento do ovário na vagem (Ziv e Zamski, 1975; Zamski e Ziv, 1976; Thompson, Ziv e Deitzer, 1985). Diferenças no processo de desenvolvimento das vagens quando os ginóforos ficaram aéreos comparados com aqueles que penetraram no solo foram observadas por Zhu et al. (2013), que concluíram que o desenvolvimento das vagens abaixo do solo é crucial para a cultura do amendoim.

Métodos para avaliar a maturação de amendoim

A maturação de amendoim é avaliada pelos produtores, extensionistas e pesquisadores de todo o mundo com base no método Hull-Scrape e no quadro de maturação (Williams e Drexler 1981). O quadro de maturação permite avaliar a maturação das vagens de amendoim por meio da coloração do exocarpo, que pode variar de branco, amarelo 1, amarelo 2, laranja, marrom e preto, sendo o quadro composto por 25 colunas. Cada vagem é classificada com base na coloração da sua região lombar (*saddle region* - Figura 3) e, posteriormente é colocada em uma das 25 colunas do quadro.




Figura 3. Visualização lateral e superior da “*saddle region*” da vagem de amendoim, que é utilizada para classificar a maturação. (Adaptado de Colvin et al., 2014)

Ao colocar as vagens no quadro, elas devem formar uma curva parecida com um sino (linha branca – Figura 4), e quanto mais deslocada à direita do quadro estiver a curva, mais próxima estará a cultura da colheita. Essa curva também é utilizada para calcular a estimativa de dias para o arranquio, considerando-se as vagens presentes nas classes marrom e preta. Isso acontece quando se tem pelo menos três vagens classificadas em cada coluna dessas categorias de cor, ou seja, quando elas atingem a linha de projeção (Figura 4).




Figura 4. Quadro de maturação de amendoim baseado no método de Williams e Drexler (1981). As vagens são classificadas de acordo com a região lombar da vagem em classes de cores e depois, em subcategorias de cores dentro de cada classe individual. Previsões de data de arranquio são fornecidas dentro das classes de cor marrom e preta (inferior direito) e são obtidas avaliando a inclinação geral das vagens classificadas (slope e linha de projeção).

Apesar de ser usado em larga escala, o quadro de maturação é altamente subjetivo, pois a interpretação depende da habilidade de quem está avaliando a

maturação (Colvin et al., 2014). Para solucionar o problema, diversos pesquisadores têm buscado métodos alternativos, principalmente utilizando análise de imagem digital. Entretanto, a análise das vagens por meio de imagens, por mais que reduza a interferência do olho humano, pode ainda ocorrer o erro de avaliar apenas um lado da vagem, bem como na interferência da iluminação no momento da tomada das fotos.

Um dos primeiros trabalhos usando imagem digital foi relatado por Ghate et al. (1992), os quais desenvolveram um sistema que classificava o amendoim em três categorias, sendo as vagens consideradas como imaturas, com maturação média e maduras, por meio da textura visual do tegumento da casca do amendoim (revestimento externo protetor da semente). Boldor et al. (2002) desenvolveram um sistema computacional para classificar as vagens de amendoim por meio da coloração do mesocarpo, e classificar em seis subclasses as vagens que estão na classe preta. Eles concluíram que o sistema é de fácil implementação e que não necessitam de mão-de-obra especializada, e que é possível utilizar outros equipamentos para a captura das imagens reduzindo o custo com equipamentos.

Nesse sentido, Colvin et al. (2014), utilizando um modelo de scanner comercial (Hewlett-Packard, 7500A Wide Format), avaliaram diferentes cultivares de amendoim em diferentes orientações, com a região lombar para baixo e completamente aleatório, desenvolveram um software de classificação digital de cores (Digital Image Model - DIM) para identificar as classes de cores das vagens e posteriormente calcular a porcentagem de maturação. Os autores concluíram que o método possui potencial para as cultivares analisadas e que é mais barato, quando comparado a outros métodos que utilizaram imagem para análise da maturação (Boldor et al., 2002; Chung et al., 1998; Tollner et al., 1998; Ghate et al., 1993).

Bindlish et al. (2017) analisaram em condições de laboratório o uso de imagens obtidas por uma câmera montada a 55 cm das vagens de amendoim com iluminação artificial para estimar a maturação e o tamanho das vagens. Eles encontraram boa correlação dos resultados, no entanto, ressaltam que a utilização de imagens para verificar a maturação é fortemente influenciada pela iluminação externa e que, em condições de campo, são necessários mais estudos para reduzir tal interferência. No sentido de aperfeiçoar a análise utilizando imagens e inclusão de tecnologia de fácil acesso, Maldonado et al. (2015) desenvolveram o aplicativo *Peanut Maturity Estimator* (PME) para *smartphones* e *tablets*, que faz a estimativa da maturação por meio de uma foto tirada usando a câmera do celular e o aplicativo apresenta o resultado em porcentagem de maturação. Entretanto, uma limitação do PME é que ele está disponível apenas para plataforma IOs. Outro método utilizando câmera de celular foi testado por Liang et al. (2018), que verificaram que o tempo gasto para remoção do exocarpo pode interferir na análise da maturação utilizando imagem, sendo que o ideal é 5-6 minutos para cultivares do grupo Runner e 7-9 minutos para cultivares do grupo Virginia.

Outro método para melhoraria do início do gerenciamento da colheita de amendoim com base na maturação é a utilização da estimativa em graus dias (GD) (Rowland et al., 2006). O método GD apresenta boa acurácia e reduz a subjetividade do método *hull-scrape*. Nos EUA, a estimativa de maturação por meio do GD pode ser obtida utilizando a plataforma desenvolvida pela USDA, *Field Agronomic Resource Manager* (Peanut FARM), que utiliza dados de estações meteorológicas que ficam próximas da área a ser analisada que foi cadastrada no site do Peanut FARM. Com base no GD, é mostrado para o produtor quando ele deve fazer amostras para verificar

a maturação de amendoim e, conseqüentemente, iniciar a colheita (Peanut FARM, 2019). Contudo, apesar da facilidade do método GD, ele ainda necessita da análise utilizando o quadro de maturação.

Visando facilitar a decisão da porcentagem de vagens maduras e imaturas, Rowland et al. (2006) estabeleceram o *Peanut Maturity Index* (PMI), o qual considera a soma de todas as vagens classificadas nas classes marrom e preta dividida pelo número total de vagens utilizadas na amostra. Os valores de PMI variam de 0 até 1, sendo indicado o início da colheita 0.7. Apesar de facilitar para os produtores, a classificação da maturação utilizando o PMI ainda é subjetiva, visto que o ainda depende da interpretação do analista.

Com a expansão da utilização de técnicas de sensoriamento remoto em diversas culturas, acredita-se que essa possa ser uma alternativa para eliminar a subjetividade do quadro de maturação. Alguns trabalhos já sinalizaram que é possível obter boa correlação do sensoriamento remoto proximal com a maturação de amendoim, entretanto ainda existem divergências sobre qual é o melhor índice de vegetação a ser utilizado.

Utilizando sensor terrestre proximal que capta diferentes comprimento de ondas (*CropScan Multispectral Radiometer* -CropScan Inc, Minnesota), Rowland et al. (2008) encontraram que a reflectância do dossel das plantas de amendoim na região do espectro de 830 e 850 nm mostrou forte correlação com a maturação da cultura, indicando que o uso de índices de vegetação que se concentram nessa faixa espectral devem ser explorados como preditores de maturidade da cultura. De modo similar, utilizando um espectro radiômetro portátil (*ASD FieldSpec Pro Analytical Spectral*

Devices, Boulder, CO), Carley et al. (2008) encontraram que a maturação de amendoim teve correlação com todas as bandas utilizadas, exceto o índice de vegetação de diferença normalizada (NDVI), quando a refletância foi comparada com a porcentagem de vagens maduras.

Utilizando a reflectância do dossel das plantas de amendoim adquirida por imagens de drone, Monsef et al. (2019) construíram um modelo de previsão da maturação de amendoim. No entanto, o modelo não forneceu acurácia aos 60 dias após a semeadura, entretanto, a acurácia aumentou na medida em que as plantas permaneceram no campo. Os autores atribuíram esse fato à diferença entre a clorofila “a” e “b” que se torna mais significativa em amendoins maduros do que em imaturos. Dessa forma eles sugerem que as coletas dos dados iniciem dois meses após a semeadura, quando é possível diferenciar as taxas de clorofila “a” e “b” por meio da reflectância foliar, e deve-se aumentar a frequência de coleta quanto mais próximo da colheita. Contudo, os autores não mensuraram a diferença entre os valores de clorofila “a” e “b”, deixando claro que existe uma lacuna no conhecimento relacionado aos processos fisiológicos da maturação das vagens de amendoim.

Utilizando imagens de satélites de alta resolução (QuickBird), Robson et al. (2007) identificou que o NDVI pode ser um método promissor para identificar a variabilidade na maturação e incidência de aflotoxina na cultura do amendoim. Esses resultados sugerem que os produtores podem usar imagens de satélites para auxiliar na tomada de decisão para gerenciamento da colheita, colhendo primeiro as áreas que apresentam maior porcentagem de maturação.

Diante do exposto, fica evidente que ainda não existe um consenso na comunidade científica a respeito de quando é a melhor época para se iniciar a coleta de dados para prever a maturação de amendoim, via sensoriamento remoto, bem como quais os índices de vegetação que possuem correlação com a maturação, tornando esse assunto passível de muitas outras pesquisas, principalmente no que tange à interação de aspectos fisiológicos e sensoriamento remoto para indicar quando se deve iniciar a colheita de amendoim reduzindo a subjetividade do quadro de maturação.

Sensoriamento remoto

O sensoriamento remoto na agricultura vem sendo utilizado desde 1970, sendo os Estados Unidos o primeiro país a empregar essa tecnologia. A partir dessa época, e após o lançamento do primeiro satélite em órbita da série LANDSAT, o país é o que mais tem investido em pesquisas nessa área. No Brasil, o desenvolvimento de geotecnologias é realizado por meio do Instituto Nacional de Pesquisas Espaciais (INPE) que é responsável por fazer do Brasil o país destaque no desenvolvimento dessa área no hemisfério sul desde 1970 (Formaggio e Sanches, 2017). Contudo, o Brasil começou a intensificar o uso de geotecnologias na agricultura somente após a necessidade de produção de mais alimentos com menor uso de área, bem como devido à facilidade de acesso aos produtos com geotecnologias, graças a difusão da Agricultura de Precisão de norte a sul.

A principal característica do sensoriamento remoto é a capacidade de obter informações de um determinado alvo, por meio de sensores, sem a necessidade de contato direto, sendo essas informações obtidas a partir da reflexão e emissão de

energia eletromagnética de cada alvo (Crepani, 1993). Os sensores captam a energia eletromagnética de cada alvo por meio da radiação de fótons que são carregados pelo espaço através de ondas eletromagnéticas de diferentes comprimentos (Figura 5), de modo que quanto menor a frequência, maior o comprimento de ondas e, conseqüentemente, a sua energia (Heege, 2013). Cada alvo possui uma resposta diferente em determinado comprimento de onda, o que torna possível de diferenciá-los, por exemplo, o solo e a vegetação (Figura 5). Observa-se que a vegetação possui variação na reflectância de acordo com a banda espectral, ao passo que o solo é pouco influenciado, principalmente em comprimentos de ondas maiores que $1,3 \mu\text{m}$.

De modo geral, o sensoriamento remoto é baseado na interação da radiação com o alvo, o que faz possível de se obter diversas respostas com rapidez e precisão. A radiação que incide sobre o alvo pode ser proveniente do próprio sensor utilizado, sendo esse considerado como sensor ativo, ou da luz solar, sendo esse tipo de sensor conhecido como sensores passivos, que são sensores embarcados em satélites e câmeras multiespectrais (Steinvall et al., 2013; Molin et al., 2015).




Figura 5. Espectro eletromagnético da radiação eletromagnética e a resposta do solo e da vegetação nos diferentes comprimentos de ondas. Fonte: (Adaptado, FLORENZANO, 2002)

Quando a radiação eletromagnética entra em contato com as plantas ela pode ser refletida, absorvida ou mesmo transmitida. Esses conceitos são importantes para a associação das respostas das plantas com os dados obtidos pelo sensoriamento remoto.

O processo de **absorbância** da radiação eletromagnética ocorre quando as bandas do espectro visível do azul e do vermelho são absorvidas para o processo de fotossíntese da planta. Já na **reflectância**, a planta absorve apenas uma parte da radiação eletromagnética, sendo a restante refletida. Essa é a etapa mais importante do sensoriamento remoto, pois não é possível mensurar o quanto uma planta está absorvendo, porém, é possível medir quanto ela está refletindo que está ligado ao seu

consumo, ou seja, se está consumindo muito reflete pouco, se está consumindo pouco, reflete muito. A **transmitância** é o processo no qual as folhas superiores da planta transmitem a radiação eletromagnética (REM) para as folhas que estão nos terços médios e abaixo da planta (DroneEng, 2019).

A assinatura espectral das plantas é influenciada por diversos fatores que podem ser associados com áreas específicas do espectro de luz. Por exemplo, no espectro visível (400-700 nm) prevalecem a associação com pigmentos, tais como, clorofila, carotenoides e antocianinas. Na região do infravermelho próximo (NIR, 700-1000 nm), a morfologia e estrutura foliar tende a influenciar a assinatura espectral, enquanto que comprimento de ondas do infravermelho curto (SWIR, 1000-2500 nm) são influenciados pela água e metabolitos (Behman et al., 2014, Matese and Di Genaro 2014). Uma parte do espectro eletromagnético que vem sendo bastante explorada nos últimos anos é o "Red-Edge" (centrado em torno de 750 nm, RE) que é a porção estreita da curva entre as regiões do vermelho e do NIR, onde a vegetação causa uma reflexão única, porque a luz do vermelho é absorvida principalmente pela clorofila e a radiação NIR é refletida (Scotford and Miller, 2005), o que vem resultando em alta performance de índices de vegetação que utilizam essa faixa do espectro.

É a partir desse conhecimento que as pesquisas vêm sendo desenvolvidas com intuito de se estimar parâmetros agronômicos com base na resposta espectral de cada cultura, utilizando comprimentos de ondas específicos. Para tanto, atualmente, as imagens (dados) dos sensores remotos podem ser obtidas por diversos tipos de plataforma, tais como satélites, veículos aéreos não tripulados (VANTs), também conhecidos como drone (UAV), máquinas agrícolas autopropelidas, e dentre outras (Shiratsuchi et al., 2014).

Índices de vegetação

Por ser um método não destrutivo, as imagens do sensoriamento remoto durante a safra podem ser úteis na identificação de áreas de diferença de produção para uma investigação detalhada durante a estação de crescimento (Liu et al., 2018). Isso é feito com o auxílio dos Índices de Vegetação (IVs), que são algoritmos simples e eficazes para avaliação quantitativa e qualitativa da condição de cobertura vegetal, entre outras abordagens e aplicações na agricultura (Chen e Gillieson, 2009). Os IVs transformam bandas espectrais para uma única variável e, assim, minimizam os efeitos do solo, topografia e ângulo de visão na resposta espectral da característica desejada (Jackson and Huete 1991).

Dentre os inúmeros IVs, o Índice de Vegetação de Diferença Normalizada (NDVI) criado por Rouse et al. (1973) é o mais conhecido e amplamente utilizado para caracterizar e monitorar as culturas (Hill et al., 2010), pois possui boa correlação com diversos parâmetros agronômicos. Segundo Eitel (2008), o NDVI está correlacionado com algumas variáveis biofísicas da planta, como a área foliar e a massa de folhas verdes, o teor de água das folhas e a clorofila total. Diversos autores utilizaram o NDVI e encontraram correlação com o teor de nitrogênio foliar (Amaral et al., 2015), altura da planta e o número de ramos por planta de algodão (Souza et al., 2017), produtividade de trigo (Marti et al., 2007), milho (Shanahan et al., 2001; Oliveira et al., 2019). Entretanto, o NDVI oferece limitações quando a cultura apresenta elevada condição de biomassa, o que faz com que tenha tendência a saturar (Gitelson, 2019). Gitelson et al. (1996a) substituiu a faixa de onda espectral verde para a faixa de onda espectral vermelha no NDVI e mostrou que este índice era

mais responsivo ao conteúdo de clorofila foliar que o NDVI original, e assim, os autores deram o nome de GNDVI para esse índice.

IVs menos sensíveis à saturação foram desenvolvidos e são aplicados em diversas outras finalidades, como por exemplo, o *Simple Ratio* (SR) que está relacionado às mudanças na quantidade de biomassa, teor e concentração de pigmentos e estresse hídrico foliar (Baret and Guyot 1991; Hatfield and Prueger, 2010). Além disso, a relação da reflectância de NIR/Vermelho (formula matemática do SR) indica a saturação da maioria dos IVs existentes, como o NDVI por exemplo. Na medida que essa relação diminui, ficando entre 7-9, os valores de saturação tendem a diminuir (Gitelson, 2019). Contudo, os IVs derivados da região RE são mais sensíveis à absorção de clorofila e toleram valores que podem variar de moderado a alto (Gitelson et al., 1996b) superando o efeito da saturação. Taskos et al. (2015), ao compararem IVs que usam a banda do RE, verificaram que o NDRE apresentou maior resistência a saturação do que o NDVI.

Levando em consideração que os fenômenos agrícolas não seguem um comportamento padrão, ou seja, são não-lineares, Goel e Qin (1994) e Gong et al. (2003) utilizaram o Non-Linear Index (NLI) e Modified Non-Linear Index (MNLI), respectivamente. Esses IVs linearizam a relação com parâmetros de superfície que tendem a ser não-lineares e podem apresentar melhores correlações, quando comparados com IV lineares, conforme observado por George et al. (2018).

Por fim, é comum pesquisadores testarem diferentes IVs para identificar e validar qual deles possui maior correlação com a variável de estudo. Hatfield and Prueger (2010) utilizaram diferentes IVs (SR, NDVI, PAR, SAVI, LAI e EVI) para

caracterizar os estádios de crescimento de soja, milho, canola e trigo. Eles concluíram que os IVs estudados mostram diferenças durante a estação de crescimento e essas diferenças foram em função do estágio de crescimento das plantas.

Dessa forma, é fundamental que se teste diferentes IVs para verificar quais deles possuem melhor correlação para prever a maturação de amendoim, uma vez que a assinatura espectral das plantas de amendoim pode sofrer alteração quando elas atingem a maturidade fisiológica, principalmente na quantidade de nutrientes foliar (Rowland et al., 2008).

Controle Estatístico de Processo (CEP)

Segundo Montgomery (2009), o Controle Estatístico de Processos (CEP) é uma abordagem muito utilizada na melhoria dos processos. O autor ressalta que com esta ferramenta é possível promover prevenção de defeitos, aumento da produtividade; e ajustes de um processo, bem como a melhoria de processos produtivos. Um processo pode ser definido como qualquer combinação dos fatores denominados 6M's (Mão-de-obra, Matéria-prima, Métodos, Medição, Máquinas e Meio-ambiente), que colaboram e interagem de certa forma para atingir a qualidade de determinado produto ou serviço (SAMOHYL e ALVES, 2005).

A utilização do CEP no monitoramento de processos produtivos possibilita a verificação da ocorrência de vários tipos de erros, sendo o mais comum utilizado no meio agrícola o erro Tipo I, que considera como estando fora dos limites de controle, todo e qualquer ponto maior ou menor que a média, mais três vezes o desvio-padrão (MINITAB, 2007).

Dentre as ferramentas disponíveis para o CEP destacam-se as cartas de controle e os gráficos sequenciais (*run charts*). Os gráficos sequenciais são uma maneira de verificar a variabilidade dos resultados (MINITAB, 2007), podendo o processo permanecer ou não previsível e, caso seja necessário, mudanças ou alterações no decorrer do processo devem ser realizadas para sua melhoria.

Com a utilização desses gráficos é possível identificar o tipo de variação a que o mesmo está submetido ao longo do próprio, ou seja, a ocorrência de padrões de não aleatoriedade (Oscilação, Tendência, Agrupamento e Mistura) que são decorrentes da ação dos fatores 6M's, ou também consideradas como causas especiais, que devem ser tomadas medidas para a sua eliminação.

A constatação de causas especiais pode ser melhor compreendida quando se utilizam os gráficos sequenciais e as cartas de controle conjuntamente (Perla, Provost e Murray, 2011), uma vez que a ocorrência de pontos fora dos limites de controle, inferior e superior, (erro Tipo I) indica a possibilidade de existência de causas especiais, em que se deve interferir no processo de produção, pois o mesmo se torna não previsível ou fora de controle. Entretanto, caso os pontos permanecessem dentro dos limites, o processo é considerado estável (MONTGOMERY, 2000).

A utilização desse tipo de monitoramento em Agricultura de Precisão ainda é incipiente, porém, frente aos conceitos estabelecidos, acredita-se que o CEP possui alto potencial na identificação de áreas que necessitam ser verificadas, uma vez que os pontos de controle funcionam como alarme para correção de problemas.

Referências bibliográficas

- Amaral, L.R., Molin, J.P., Portz, G., Finazzi, F.B., Cortinove, L. (2015). Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. *Precision Agriculture*, 16(1):15-28.
- Baret, F., Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35(2-3):161–173.
- Behman, L.J., Steinrücken, J., Plümer, L. (2014). Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93 (7):98-111.
- Bindlish, E., Abbott, A.L., Balota, M. (2017). Assessment of Peanut Pod Maturity, IEEE Winter Conference on Applications of Computer Vision, 688-696.
- Boldor, D., Sanders, T., Swartzel, K., Simunovic, J. (2002). Computer-assisted color classification of peanut pods. *Peanut Science*, 29(1):41-46.
- Bolonhezi, D., Mutton, M.Â., Martins, A.L.M. (2007). Sistemas conservacionistas de manejo do solo para amendoim cultivado em sucessão à cana crua. *Pesquisa Agropecuária Brasileira*, 42(7):939-947.
- Buttery, B.R., Buzzell, R.I. (1977). The relationship between chlorophyll content and rate of photosynthesis in soybeans. *Canadian Journal of Plant Science*, 57(1):15.
- Campbell, J.B. (1996). Introduction to remote sensing. second edition. The Guilford Press, New York. 622 p.
- Campbell, J.B. (2002). Introduction to remote sensing. third edition. The Guilford Press, New York. 622 p.
- Carley, D., Jordan, D., Dharmasri, L., Sutton, T., Brandenburg, R., Burton, M. (2008). Peanut response to planting date and potential of canopy reflectance as an indicator of pod maturity. *Agronomy Journal*, 100(2):376–380.
- Chen, Y., Gillieson, D. (2009). Evaluation of Landsat TM vegetation indices for estimating vegetation cover on semi-arid rangelands: a case study from Australia. *Canadian Journal of Remote Sensing*, 35(5):435-446.
- Chung, S.Y., Vercellotti, J.R., Sanders, T.H. (1998). Evidence of stress proteins and a potential maturity marker in peanuts. *Journal of Agricultural and Food Chemistry*, 46(11):4712-4716.

Colvin, B., D. Rowland, J., Ferrell, Faircloth, W.H. (2014). Development of a digital analysis system to evaluate peanut maturity. *Peanut Science*, 41(1):8-16.

CONAB. Companhia Nacional de Abastecimento. BOLETIM DA SAFRA DE GRÃOS, safra 2018/2019, nono levantamento: julho/2019. Brasília: Conab, 2019.

Crepani, E. (1993). Princípios básicos de sensoriamento remoto. São José dos Campos: CNPq/INPE, 45p.

Eitel, J.U.H. (2008). Combined spectral index to improve ground-based estimates of nitrogen in dryland wheat. *Agronomy Journal*, 100(6):1694-1702.

Ferrari Neto, J., Costa, C.H.M., Castro, G.S.A. (2012). Ecofisiologia do amendoim. *Scientia Agraria Paranaensis*, 11(4):1-13.

Florenzano, T. G (2002). Imagens de satélite para estudos ambientais. São Paulo: Oficina de Textos.

Formaggio, A.R., Sanches I.D.A. (2017). Sensoriamento Remoto em agricultura. São Paulo: Oficina de Textos, 284p.

George, R., Padalia, H., Sinha, S.K., Kumar, A.S. (2018) Evaluation of the Use of Hyperspectral Vegetation Indices for Estimating Mangrove Leaf Area Index in Middle Andaman Island, India. *Remote Sensing Letters*, 9(11):1099-1108.

Ghate, S., Evans, M., Kvien, C., Rucker, K. (1993). Maturity detection in peanuts (*Arachis hypogaea* L.) using machine vision. *Transactions of the ASAE*, 36(6):1941-1947.

Gitelson, A.A., Kaufman, Y.J., Merzlyak, M.N. (1996a). Use of green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3):289-298.

Gitelson, A.A., Merzlyak, M.N. (1996b). Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, 148(3-4):494-500.

Gitelson, A.A. (2019) Remote estimation of fraction of radiation absorbed by photosynthetically active vegetation: generic algorithm for maize and soybean, *Remote Sensing Letters*, 10:3, 283-291.

Goel, N.S., Qin, W. (1994). Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. *Remote Sensing Review*, 10(4):309-347.

Gong, P., Pu, R., Biging, G.S., Larrieu, M.R. (2003). Estimation of Forest Leaf Area Index Using Vegetation Indices Derived from Hyperion Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing*, 41:(6),1355-1362.

Hatfield, J., Prueger, H. (2010). Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. *Remote Sensing*, 2(2):562-578

Heege, H.J. (2013). Precision in crop farming. London: Springer, 300p.

Maldonado Jr, W., Lyra, T.A.M.; Zerbato, C., Silva, R.P., Barbosa, J. C. (2015). Estimativa do grau de maturação do amendoim utilizando imagens digitais. In: XI Encontro sobre a cultura do amendoim, FCAV/UNESP, Jaboticabal- SP. Anais do XI Encontro sobre a cultura do amendoim.

Hill, J., Udelhovem, T., Vohland M., Stevens, A. (2010). The use of laboratory spectroscopy and optical remote sensing for estimating soil properties. In: Oerke, E.C., Gerhards, R., Menz, G., Sikora, R.A. Precision crop protection - the challenge and use of heterogeneity. Springer p67-70.

Jackson, R.D., Huete, A.R. (1991). Interpreting Vegetation Indices. *Preventive Veterinary Medicine*. 11(3-4):185-200.

Liang, W., Kirk, K.R., Thomas, J. (2018). Estimation of Peanut Maturity Using Color Image Analysis. 2018 ASABE Annual International Meeting, Detroit, Michigan.

Liu, H., Whiting, M.L., Ustin, S.L., Zarco Tejada, P. J., Huffman, T., Zhang, X. (2018). Maximizing the relationship of yield to site-specific management zones with object-oriented segmentation of hyperspectral images. *Precision Agriculture*, 19(2):348.

Marti, J., Bort, J., Slafer, G., Araus, J. (2007). Can wheat yield be assessed by early measurements of normalized difference vegetation index?. *Annals of Applied Biology*, 150(2):253-257.

Matese, A., Di Genaro, S.F. (2015). Technology in precision viticulture: a state of the art review. *International Journal of Wine Research*, 7(7):69–81.

MINITAB. MINITAB Release 16: Meet MINITAB 16. MINITAB StatGuide; MINITAB Help. [S.I.]: Minitab., 2007.

Moctezuma, E. (2003). The peanut gynophore: A developmental and physiological perspective. *Canadian Journal of Botany*, 81(3):183-190.

Molin, J.P., Amaral, L.R., Colaço, A.F. (2015). Agricultura de precisão. 1ª ed. São Paulo: Oficina de Textos.

Monfort, W.S., Culbreath, A.K., Stevenson, K.L., Brenneman, T.B., Gorbet, D.W., Phatak, S.C. (2004). Effects of reduced tillage, resistant cultivars, and reduced fungicide inputs on progress of early leaf spot of peanut (*Arachis hypogaea*). *Plant Disease*, 88(8):858-864.

Monsef, H.A., Smith, S.E., Rowland, D.L., Rasol, N.A.E. (2019). Using multispectral imagery to extract a pure spectral canopy signature for predicting peanut maturity. *Computers and Electronics in Agriculture*, 162(1):561-572.

Montgomery, D.C. (2000). Introduction to statistical quality control. 4. ed. New York: John Wiley & Sons, p. 300-377.

Montgomery, D.C. (2009). Introdução ao controle estatístico da qualidade. 4. ed. Rio de Janeiro: LTC. p. 100-200.

Nakagawa, J., Rosolem, C.A. (2011). O amendoim: tecnologia de produção. Botucatu, FEPAF. 325p.

Oliveira, M.F., Ormond, A.T.S., Noronha, R. H.F., Santos, A. F., Zerbato, C., Furlani, C. E. A. (2019). Prediction Models of Corn Yield by NDVI in Function of the Spacing Arrangement. *Journal of Agricultural Science*, v. 11(6):493-500.

Ormond, A.T., Santos, A.F., Alcantara, A.S., Zerbato, C., Furlani, C.E.A. (2018). Tillage interference in the quality of peanut mechanized harvest. *Engenharia Agrícola*, 38(2):251-259.

Perla, R.J., Provost, L.P., Murray, S.K. (2011). The run chart: a simple analytical tool for learning from variation in healthcare processes. *BMJ Quality and Safety*, 20(1):46-51.

Rao, V. R., Murty, U.R. (1994) Botany — morphology and anatomy. In: J. Smartt, editor, The Groundnut Crop., Springer Netherlands, 64p.

Robson, A., Phinn, S., Wright, G. (2006). Using field spectroscopy and QuickBird imagery for the assessment of peanut crop maturity and aflatoxin risk. *Journal of Spatial Science*, 51(2):151-162.

Rouse, W., Haas H., Schell A., Deering W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. In: Proc. Earth Res. Tech. Satellite-1 Symp., Goddard Space Flight Cent., Washington, DC., pp. 309–317.

Rowland, D.L., Sorensen, R.B., Butts, C.L. Faircloth, W.H. (2006). Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33:125-136.

Rowland, D.L., Sorensen, R.B., Butts, C.L., Faircloth, W.H., Sullivan, D.G. (2008). Canopy characteristics and their ability to predict peanut maturity. *Peanut Science*, 35(1):43-54.

Samohyl, R.W., Alves, C.C. (2005). O monitoramento de processos industriais via gráficos de controle CUSUM. *Revista UNIVILLE*, 10(2):72-80.

Sanders, T.H., Shubert, A.M., Pattee, H.E. (1982). Maturity methodology and postharvest physiology. In: Pattee, H.E., Young, C.T., editors. *Peanut science and technology*. Yoakum: American Peanut Research and Education Society, Inc; p. 625-627.

Scotford, I.M., Miller, P.C.H. (2005). Applications of spectral reflectance techniques in Northern European cereal production: a review. *Biosystems Engineering*, 90(3):235-250.

Shanahan F., Schepers, S.D., Varvel, F. E., Wilhelm, W., Tringe, S., Schlemmer, R., Major, J. (2001). Use of remote sensing imagery to estimate corn grain yield. *Agronomy Journal*, 93(3):583-589.

Shiratsuchi, L.S., Brandão, Z.N., Vicente, L.E., Victoria, D.C., Ducati, J.R., Oliveira, R.P., Vilela, M.F. (2014). Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: Bernardi, A.C.C., Naime, J.M., Resende, A.V., Bassoi, L.H., Inamasu, R.Y. (2014). *Agricultura de precisão: resultados de um novo olhar*. Brasília: EMBRAPA, 2014. Cap. 4. p.58-73.

Shushu, D.D., Cutter, E.G. (1990). Growth of the gynophore of the peanut *Arachis hypogaea*. 2. Regulation of growth. *Canadian Journal of Botany*, 68(5):965-978.

Singh, A.L. (2004). Growth and physiology of Groundnut. pp 178-212. In: *Groundnut Research in India* (Eds. M. S. Basu and N. B. Singh) National Research center for roundnut (ICAR), Junagadh, India.

Smith, B.W. (1950). *Arachis hypogaea*: Aerial flower and subterranean fruit. *American Journal of Botany*, 37(10):802-815.

Souza, H.B., Baio, F.H.R., Neves, D.C. (2017). Using Passive And Active Multispectral Sensors On The Correlation With The Phenological Indices Of Cotton. *Engenharia Agrícola*, 37(4):782-789.

Steinvall, O., Chevalier, M.E.T., Gustafsson, O. (2013). Active and passive short-wave infrared and near-infrared imaging for horizontal and slant paths close to ground. *Applied Optics*, 52(20):4763-4778.

Taskos, D.G., Koundouras, S., Stamatiadis, S., Zioziou, E., Nikolaou, N., Karakioulakis, K., Theodorou, N. (2015). Using active canopy sensors and chlorophyll meters to estimate grapevine nitrogen status and productivity. *Precision Agriculture*, 16(1):77-98.

Thompson, L.K., Ziv, M., Deitzer, G.F. (1985). Photocontrol of peanut (*Arachis hypogaea* L.) embryo and ovule development in vitro. *Plant Physiol*, 78(2):370-373.

Tollner, E.W., V. Boudolf, R.W. McClendon, and Y.C. Hung. (1998). Predicting peanut maturity with magnetic resonance. *Trans. ASABE*. 41(4):1199-1205.

USDA. (2017). ARMS data. USDA-ERS, Washington, DC. <https://www.ers.usda.gov/data-products/arms-farm-financial-and-crop-production-practices/arms-data/> (acessado 12 Feb. 2019).

Williams, E.J., Drexler, J.S. (1981). A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2):134-141.

Ziv, M., Zamskj, E. (1975). Geotropic responses and pod development in gynophore explants of peanut (*Arachis hypogaea* L.) cultured in vitro. *Annals of Botany*, 39(3):579-583.

Zamski, E., Ziv, M. (1976). Pod formation and its geotropic orientation in the peanut, *Arachis hypogaea* L., in relation to light and mechanical stimulus. *Annals of Botany*, 40(3):631-636.

Zhu, W., Zhang, E., Li, H., Chen, X., Zhu, F., Hong, Y., Liao, B., Liu, S., Liang, X. (2013). Comparative proteomics analysis of developing peanut aerial and subterranean pods identifies pod swelling related proteins. *Journal of Proteomics*, 91(1):172-187.

Capítulo 2: Qualidade dos dados obtidos por drone e satélites de alta resolução no monitoramento da maturação da cultura do amendoim

Resumo

O sensoriamento remoto pode ser obtido por diversas formas, dentre elas a aérea e orbital tem sido empregada em larga escala na agricultura para identificar a variabilidade das lavouras. Dessa forma, sabendo-se que essas duas plataformas possuem diferença na resolução espacial de uma mesma área, objetivou-se verificar a qualidade dos dados obtidos por meio de drone utilizando câmera multiespectral sequoia (0,095 m) e imagens do satélite de alta resolução PlanetScope (~3 m) no monitoramento da variabilidade da maturação das vagens de amendoim utilizando ferramentas do controle estatístico de processo. As cartas de controle foram eficazes no monitoramento da variabilidade dos índices de vegetação e na detecção das variações. Detectou-se redução da reflectância na banda do RED aos 107 dias após a semeadura. Os índices de vegetação que foram mais sensíveis a redução da biomassa foram o NDVI, NLI e o GNDVI. Dentre os índices de vegetação, o SR foi o que apresentou melhor qualidade na predição da maturação de amendoim.

Palavras-chave: Sensoriamento remoto, Índice de vegetação, UAV, Agricultura de precisão

Quality of drone data and high-resolution satellites in monitoring maturity of peanut crop.

Abstract

Remote sensing can be obtained in different ways, including aerial (drones) and orbital (satellites). These have been widely used in agriculture to identify crop variability. Thus, knowing that these two platforms have a difference in spatial resolution of the same area, the proposal this paper was to verify the spatial quality of data obtained by drone using a Sequoia multispectral camera (0.095 m) and high resolution satellite images PlanetScope (~ 3 m) in monitoring the variability of peanut pod maturation using statistical process control tools. Control charts were effective in monitoring vegetation index variability and variation detection. Red reflectance reduction in the RED band was detected at 107 days after sowing. The vegetation indices that were most sensitive to biomass reduction were NDVI, NLI and GNDVI. Among the vegetation indices, SR was the one that presented better quality in the prediction of the peanut maturity.

Keywords: Remote Sensing, Statistical Process Control, UAV, Precision Agriculture

Introdução

A acurácia no processo de identificação da maturação de amendoim para determinar o início da colheita é uma das mais importantes decisões que os produtores de todo o mundo devem fazer. Isto não é diferente no estado da Georgia, que é responsável por 55% da produção total dos EUA, o que representa para o Estado uma receita bruta de 578,5 milhões de dólares/ano (National Agricultural Statistical Service - USDA, 2018).

Por ser uma planta de hábito de crescimento indeterminado, isso dificulta a tomada de decisão para algumas operações agrícola, tais como a colheita, visto que em uma mesma planta pode ter vagens com diferentes estágios de maturação (Boote, 1982). Dessa forma, se as plantas forem colhidas com a maioria das vagens imaturas

pode resultar em redução da qualidade das sementes e conteúdo de óleo (Fincher et al., 1980), ao passo que, vagens com elevada maturação aumentam os níveis de perdas durante a colheita (Lamb et al., 2004) independente da tecnologia embarcada nas máquinas para a colheita (Santos et al., 2018). Assim, o ponto ótimo para colheita com base na coloração do mesocarpo é quando as plantas apresentam maturação de 70-75% (Williams e Drexler, 1981), sendo nessa faixa onde se encontra o maior retorno econômico (Sanders et al., 1995).

Entretanto, o método para obter a maturação é subjetivo e trabalhoso, e por isso, diversos pesquisadores têm trabalhado em desenvolver métodos alternativos para reduzir essa subjetividade. Colvin et al. (2014) e Liang et al. (2018) desenvolveram um método de análise digital das vagens para estimar a maturação de amendoim, que é baseado na análise das cores do mesocarpo. Rowland et al. (2008) simplificaram o método de avaliação da maturação que utiliza o quadro de maturação, estabelecendo o índice de maturação PMI. Além disso, esses autores demonstraram que o uso de graus dias possui potencial para prever a maturação das vagens de amendoim e indicar o momento da colheita.

Apesar desses novos métodos, o *hull-scrape* (Williams e Drexler, 1981) ainda é o mais usual entre os produtores. Todavia, todos estes métodos não demonstram a variabilidade da maturação em larga escala, o que muitas vezes superestima ou subestima a maturação das plantas. Métodos alternativos utilizando técnicas de sensoriamento remoto para o monitoramento da variabilidade nas propriedades do dossel têm se tornado de fácil acesso e com alta precisão e vêm sendo utilizados para correlacionar diversos parâmetros agrônômicos e biofísicos (Gitelson, 2004), como clorofila (Clevers et al., 2017), biomassa (Campos et al., 2018), produtividade (Lobell e Azzari, 2017) e maturação de culturas como soja (Yu et al., 2016) e trigo (González-Gómez et al., 2018).

O uso do sensoriamento remoto na cultura do amendoim já foi reportado como potencial para detecção de doenças (Chen et al., 2019) e predição da maturação (Carley et al., 2008; Rowland et al., 2006; Monsef et al., 2019). Entretanto, diante da grande quantidade de índices de vegetação (IV) existente na literatura e dos diferentes sensores que podem ser utilizados para coleta de dados, é fundamental que se tenha conhecimento a respeito da qualidade da reflectância que cada plataforma pode

prover. Embora o sensoriamento remoto mostre vantagens significativas, como cobertura fácil e rápida de grandes áreas com alta resolução, há várias restrições ao usar esses métodos associados a condições climáticas, tempo de aquisição e elaboração de imagens e processamento de dados (Stamatiadis et al., 2010).

A qualidade dos dados adquiridos pelos sensores pode ser analisada por meio de cartas de controle, as quais permitem analisar os resultados ao longo do tempo por meio de gráficos que possuem rigor estatístico. Este tipo de análise vem sendo adotado para monitorar a qualidade de processos agrícolas (Santos et al., 2018; Tavares et., 2018). Entretanto, não se encontram resultados publicados comparando a qualidade dos dados obtidos por drone (UAV) e imagem de satélite para nenhuma cultura empregando esta ferramenta.

Acredita-se que a utilização das cartas de controle no monitoramento da qualidade dos IV obtidos por UAV e imagem de satélites poderá ajudar na compreensão da associação de processos fisiológicos das plantas de amendoim com o comportamento da assinatura espectral. Além disso, poderá possibilitar indicar qual plataforma possui melhor qualidade na aquisição de dados para correlacionar com a maturação de amendoim e direcionar futuros trabalhos.

Para verificar se é possível a utilização desta ferramenta para melhoria na qualidade da interpretação de dados provenientes do sensoriamento remoto, o foco deste estudo foi verificar a aplicabilidade das ferramentas do controle de qualidade no monitoramento da qualidade dos dados obtidos por drone e satélites em cinco avaliações ao longo de um ciclo produtivo da cultura do amendoim. Além disso, verificar se as duas plataformas possuem qualidade de dados similares que possam ser usadas para prever a maturação de amendoim.

Material e Métodos

O experimento foi conduzido em uma área comercial irrigada de amendoim em Coffee County, Georgia, Estados Unidos. A cultivar utilizada foi Georgia-06G (Branch, 2007). Foram utilizadas imagens de satélite históricas para seleção das parcelas experimentais. Cada área experimental foi constituída de 1 ha, totalizando 24 células em grade.

Semanalmente, após os 96 dias da semeadura, seis plantas de amendoim foram coletadas de uma área aproximada de 10 metros de raio, localizada no centro de cada célula. De cada planta, foram retiradas todas as vagens de amendoim até atingir cerca de 200 vagens por ponto amostral, não necessariamente foram utilizadas todas as plantas, uma vez que o número de vagens próximo de 200, pode ser obtido com menos de seis plantas. Em seguida, as vagens de amendoim passaram pelo processo de remoção do exocarpo, utilizando um jato de água sob pressão, de modo a expor o mesocarpo. As vagens foram colocadas no quadro de maturação e cada classe de cor foi registrada (Williams e Drexler, 1981). A porcentagem de vagens maduras foi obtida utilizando o método *Peanut Maturity Index* (PMI), que foi calculado para cada amostra de acordo com Rowland et al. (2006).

Aquisição das imagens

Drone

Durante cada dia de coleta, uma câmera Parrot Sequoia (Paris, França) embarcada na aeronave remotamente pilotada 3DR solo (Berkley, EUA) foi usada para capturar imagens multiespectrais em 4 diferentes bandas, Verde (530-570 nm), Vermelho (640-680 nm), Infravermelho (770-810 nm) e Red Edge (730-740 nm). Entretanto, neste trabalho somente foram utilizadas as bandas do vermelho, verde e infravermelho próximo (NIR).

Todos os voos da aeronave (96, 108, 117, 123 e 135 DAS) ocorreram entre 2 h do meio dia solar, com altitude de 90 m e sobreposição de 70%. Em 90 m, a resolução espacial da câmera foi 0,095 m. Antes e depois de cada voo, utilizou-se um painel de calibração radiométrica, do qual foram tiradas imagens que, posteriormente, foram utilizadas para calibrar as imagens capturadas sobre a área. Alvos preto e branco (1 x 1 m) foram colocados em cada vértice da área para servir como pontos de controle do solo (PC). As coordenadas dos PC foram gravadas com o GNSS Trimble R8 (Sunnyvale, EUA). O software Pix4D foi utilizado para criar os ortomosaicos de refletância em cada uma das quatro bandas, os quais foram gerados após a correção radiométrica (imagens do painel de calibração) e correção geométrica (pontos de controle). Após criar os ortomosaicos de reflectancia, o software ArcGIS

(Redlands, US) foi utilizado para extrair o valor médio da refletância do pixel de cada uma das 24 células em ambos os campos.

Satélite PlanetScope

As imagens de satélite utilizadas foram obtidas a partir de dados de satélites da plataforma PlanetScope CubeSat, que são caracterizados como 3U CubeSats (10 x 10 x 30 cm) com massa de aproximadamente 4 kg. O PlanetScope é uma constelação de satélites que compreende diferentes tipos de satélites de alta resolução. Atualmente, o PlanetScope possui 148 satélites em órbita solar, os quais possuem capacidade de coletar imagens diariamente em qualquer lugar do globo terrestre com resolução de 3-5 m (Planet Team, 2019). Os satélites da PlanetScope possuem quatro bandas espectrais, sendo três no visível, Blue (455-515 nm), Green (500-590), Red (590-670 nm) e uma no infravermelho próximo, NIR (780-860 nm).

Neste trabalho foram utilizadas quatro imagens do satélite PlanetScope em diferentes datas, todas adquiridas no estágio reprodutivo da cultura do amendoim. As características de cada imagem são mostradas na Tabela 1.

Tabela 1. Características das imagens do satélite PlanetScope em diferentes datas

Datas	DAS ⁽¹⁾	Horário (UTC)	Elevação solar	Azimute solar	Resolução (m)
11/09/2018	96	15:46	52,9°	131,2°	4,0
22/09/2018	108	15:50	50,7°	138,1°	3,9
01/10/2018	117	15:42	47,3°	139,6°	4,0
06/10/2018	123	15:50	46,8°	144,0°	4,0
18/10/2018	135	15:40	42,0°	144,9°	3,5

⁽¹⁾ Dias após a semeadura.

As imagens do PlanetScope passam por uma série de calibrações radiométricas básicas, envolvendo correções para distorções do sensor e ajustes para variações do ângulo do sol em ambiente computacional, o que permite que os valores de radiométricos de cada pixel sejam convertidos em valores de variância e reflectância posteriormente. Apesar disso, realizou-se a correção para o topo da atmosfera (TOA) em cada imagem, sendo assim atenuado o efeito da atmosfera nos

diferentes dias amostrados. A correção foi realizada utilizando o código desenvolvido em linguagem Python. A descrição dos processos realizados para extração e correção da imagem e obtenção da reflectância e dos índices de vegetação são apresentados na Figura 1.




Figura 1. Esquema representativo dos passos adotados para correção da imagem e extração da reflectância em cada banda espectral e obtenção dos índices de vegetação.

Índices de vegetação utilizados (IV)

Cinco IVs usados por outros trabalhos foram selecionados para avaliação a maturação de amendoim (Tabela 2).

Tabela 2. Índices de vegetação (IV) utilizados para predizer a maturação de amendoim.

IV *	Equação	Referência
NDVI	$(\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})$	Rouse et al. (1974)
GNDVI	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson e Merzlyak (1996)
NLI	$(\text{NIR}^2 - \text{RED}) / (\text{NIR}^2 + \text{RED})$	Goel and Qin, (1994)
MNLI	$(\text{NIR}^2 - \text{RED})(1 + L) / (\text{NIR}^2 + \text{RED} + L)^{**}$	Gong et al. (2003)
SR	NIR / RED	Jordan (1969)

NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; NLI: non-linear index; MNLI: modified non-linear index; SR: simple ration; NIR: infravermelho próximo; RED: vermelho; Green: verde; **L = 0.5

Análise dos dados

A análise da variabilidade da reflectância e dos IVs da cultura do amendoim foi realizada por meio do controle estatístico de processo, com auxílio do programa Minitab® (Minitab, 2007). As ferramentas do controle de qualidade utilizadas foram as cartas de controle por variáveis e gráficos sequenciais (*run charts*).

Os gráficos sequenciais permitem verificar a variabilidade dos resultados, identificando a ocorrência de padrões de não aleatoriedade (Oscilação, Tendência, Agrupamento e Mistura) que são decorrentes da ação de causas especiais.

O modelo de carta de controle selecionado foi o Individual de Amplitude Móvel (I-MR: Individual-Moving Range) que contém dois gráficos: o superior, correspondendo aos valores individuais amostrados em cada ponto e o inferior, obtido pela amplitude calculada entre duas observações sucessivas conforme Eq. (1) e (2) com $\alpha = 0.01$.

$$UCL = \bar{X} + 3\sigma \quad (1)$$

$$LCL = \bar{X} - 3\sigma \quad (2)$$

Em que UCL é o limite superior de controle; $\bar{x}$ é a média geral da variável; σ é desvio padrão; e LCL é o limite inferior de controle.

Resultados

A variabilidade da reflectância das plantas de amendoim de todos os índices de vegetação (IV) testados neste trabalho em área irrigada está sujeita à ação de causas especiais, independentemente da plataforma utilizada para coleta dos dados (drone ou satélite). Tal fato é decorrente da ocorrência de padrões de agrupamento em todos os IV ao longo do tempo para ambas plataformas, bem como da detecção de padrão de tendência para o MNLI utilizando drone (Tabela 3).

Tabela 3. Resumo da análise de padrão por meio de gráficos sequenciais (*run chart*) para os índices de vegetação obtidos por meio de drone e satélite.

Índices de vegetação ^{1/}	Padrões			
	Agrupamento	Mistura	Tendência	Oscilação
Imagem de drone				
NDVI	0,000**	1,000	0,398	0,602
GNDVI	0,000**	1,000	0,219	0,781
NLI	0,000**	1,000	0,098	0,902
MNLI	0,000**	1,000	0,000**	1,000
SR	0,000**	1,000	0,151	0,849
Imagem de satélite				
NDVI	0,000**	1,000	0,695	0,305
GNDVI	0,000**	1,000	0,695	0,305
NLI	0,000**	1,000	0,695	0,305
MNLI	0,000**	1,000	0,695	0,305
SR	0,000**	1,000	0,695	0,305

^{1/} NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; NLI: non-linear index; MNLI: modified non-linear index; SR: simple ration; **Significativo a $p < 0,05$.

O padrão de agrupamento foi observado na primeira e na última avaliação, com redução dos valores dos IVs, na medida em que se aproximou o momento da colheita. Aos 96 dias após a semeadura (DAS), o agrupamento dos valores para cada IV pode ser constatado pela proximidade dos pontos uns dos outros, agrupados acima ou abaixo da média na carta de valores individuais (Figura 2), ou seja, houve baixa variabilidade na área experimental. Por outro lado, no agrupamento dos dados observado aos 135 DAS, tem-se uma amplitude de variação maior para todos os IVs, exceto para o SR (Figuras 2 a 4), que teve comportamento inverso aos demais índices (menor amplitude de variação no final e maior no começo das avaliações). O resultado da menor variabilidade na última avaliação no SR é associado ao aumento da reflectância na banda do RED e redução no NIR, neste estágio de avaliação (135 DAS), uma vez que a razão entre essas duas bandas compõe o IV.

Com a redução na reflectância da banda do RED aos 107 DAS, notou-se que, o NDVI e o NLI (Figuras 2 A e B) não foram capazes de detectar a variação entre 96 até 117 DAS. Esses IVs apresentaram reduzida amplitude de variação até os 117 DAS, o que indica que estavam saturados, enquanto que o GNDVI (Figura 1C) reduz gradualmente os valores desde os 96 DAS até os 123 DAS. Contudo, nota-se acentuada queda nos valores desses IVs de 123 para 135 DAS, o que pode estar

relacionado à redução da biomassa vegetal, ocasionada pelo aparecimento gradual da doença pinta preta [*Passalora personata* (teleomorfo: *Mycosphaerella berkeleyi*)] (117-123 DAS).




Figura 2. Análise da variabilidade dos índices de vegetação utilizando drone NDVI (A), NLI (B) e GNDVI (C) por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

($\alpha = 0.05$) UCL upper control limit, LCL lower limit of control, $\bar{x}$ average, MR mean of the mobile range.

Em relação à utilização de imagens de satélites de alta precisão no monitoramento da lavoura de amendoim (Figura 3), obtiveram-se valores de IV mais baixos que aqueles obtidos pelo drone, o que, no entanto, não desqualifica a sua utilização, uma vez que o NDVI, NLI e o GNDVI tiveram o mesmo comportamento

quando obtidos por drone. Entretanto, é possível notar na carta de amplitude móvel (Figura 3) que esses IV acompanharam a variação da cobertura vegetal, na medida em que essa houve modificação, de modo que a variabilidade na carta de amplitude móvel aumentou na medida em que se aproximou da última avaliação (135 DAS). Além disso, observa-se que os dados obtidos por imagens de satélites apresentaram apenas padrão de agrupamento, com nenhuma variação dos valores para os outros parâmetros da análise das *run charts* (Tabela 3).




Figura 3. Análise da variabilidade dos índices de vegetação NDVI (A), NLI (B) e GNDVI (C) utilizando imagem de satélite de alta resolução por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

UCL: Limite Superior de Controle, LCL: Limite Inferior de Controle, $\bar{x}$ média, MR: Amplitude móvel. ($\alpha = 0.05$)

Esses resultados permitem verificar a sensibilidade desses IVs em relação à redução da biomassa vegetal, indicando que eles podem ser utilizados no monitoramento de doenças como a pinta preta e, conseqüentemente, direcionar produtores na tomada de decisão, e ainda no gerenciamento da colheita mecanizada, uma vez que a colheita mecanizada necessita de biomassa para melhoria na qualidade da operação. Além disso, indica que o monitoramento pode ser realizado por meio de imagens de drone ou de satélite de alta resolução.

Dentre todos os IV utilizando drone, o SR (Figura 4A) foi o que apresentou melhor resposta ao longo do tempo, reduzindo na medida em que as plantas permaneceram no campo. De modo similar, o MNLI (Figura 4B), apresentou comportamento de redução ao longo do tempo. Entretanto, aos 135 DAS, a variabilidade (distância entre os limites de controle) da reflectância entre as parcelas foi maior do que o SR, indicando que o MNLI ainda foi capaz de captar diferença na variabilidade das plantas de amendoim mesmo quando essas estavam próximas da colheita.




Figura 4. Análise da variabilidade dos índices de vegetação SR (A) e MNLI (B) utilizando drone por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

UCL: Limite Superior de Controle, *LCL*: Limite Inferior de Controle, $\bar{x}$ média, *MR*: Amplitude móvel. ($\alpha = 0.05$)

Quando o SR e MNLI foram obtidos através de imagens de satélite, a variabilidade foi menor (Figura 5), com valor máximo do limite superior igual a 8,25

aos 96 DAS para o SR. Além disso, nota-se que, para ambos os IVs, a variabilidade entre uma data amostral e outra é uniforme com base nos limites de controle (UCL) cartas de amplitude móvel, exceto aos 108 DAS que houve notada redução no valor do IV.




Figura 5. Análise da variabilidade dos índices de vegetação SR (A) e MNLI (B) utilizando imagem de satélite por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

UCL: Limite Superior de Controle, LCL: Limite Inferior de Controle, $\bar{x}$ média, MR: Amplitude móvel. ($\alpha = 0.05$)

Quanto ao comportamento de cada banda espectral ao longo do tempo, foi possível observar que as plantas de amendoim reduziram a reflectância no comprimento de onda do visível aos 107 DAS (Figuras 6 A e B). Acredita-se que estes resultados tenham relação com o processo de produção de fotoassimilados para formação e enchimento de grãos das vagens, uma vez que o comportamento do NIR sofreu baixa alteração dos 107 para os 117 DAS (Figura 6 C). Além disso, após esse período, o PMI das vagens apresentou maiores valores médios em todos os estágios subsequentes de avaliação (Figura 6D).

Dessa forma, esses resultados mostram que a reflectância das plantas de amendoim em área irrigada tende a aumentar na banda do visível (vermelho e verde) após os 107 DAS e reduzir na banda do NIR após 117 DAS, resultando em altos valores de PMI na medida em que as plantas permanecem no campo.





Figura 6. Análise da variabilidade em cada banda espectral Red (A), Green (B), NIR (C) e PMI (D) utilizando imagem de drone por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

UCL: Limite Superior de Controle, *LCL*: Limite Inferior de Controle, $\bar{x}$ média, *MR*: Amplitude móvel. ($\alpha = 0.05$)


As cartas de controle para os dados utilizando imagem de satélite permitem verificar que na banda do visível existe redução na reflectância aos 108 e 117 DAS no Red e no Green (Figuras 7A e B). No entanto, aos 123 e 135 DAS, ela volta a ficar com valores médio próximos aos de 96 DAS no Red, contudo, com maior variabilidade entre as parcelas (carta de amplitude móvel), o que pode estar diretamente relacionado com a maturação das vagens, visto que o NIR aos 135 DAS apresenta variabilidade similar ao 96 DAS. Entretanto, vale ressaltar que houve alta variabilidade

na banda do Green aos 123 e 135 DAS, com pontos que extrapolam os limites de controle.



(A)

(B)



(C)

Figura 7. Análise da qualidade dos das bandas espectrais Red (A), Green (B) e NIR (C) utilizando imagem de satélite de alta resolução por meio das cartas de controle individual e amplitude móvel ao longo do tempo.

UCL: Limite Superior de Controle, *LCL*: Limite Inferior de Controle, $\bar{x}$ média, *MR*: Amplitude móvel. ($\alpha = 0.05$).

Discussão

A baixa variabilidade dos IVs (NDVI, GNDVI e NLI) nas primeiras avaliações (96 até 117 DAS) pode estar relacionada com a quantidade de biomassa produzida pelas plantas de amendoim, uma vez que cultivares do grupo *runner* possuem hábito de crescimento rasteiro, tendo como principal característica a cobertura de toda a superfície do solo por meio da emissão de ramos laterais, o que aumenta o índice de área foliar (IAF). Este incremento de IAF resulta em interceptação de 95% da luz solar aos 53 DAS (Duncan et al., 1978), o que, conseqüentemente, aumenta a taxa fotossintética das plantas, ocasionando maior sensibilidade de índices como o NDVI às altas taxas bioquímicas e fisiológicas da cultura, levando à saturação (Gitelson, 2004 e Thenkabail et al., 2000). De modo similar, o GNDVI e NLI também apresentaram pequena variação até aos 117 DAS, de 0,76 a 0,83 para o GNDVI e de 0,82 a 0,91 para o NLI. Entretanto, após essa data, as plantas começaram o processo de senescência das folhas do baixeiro de forma acentuada, característica comum da incidência da doença pinta preta em amendoim.

No presente trabalho, os valores médios de NDVI variaram de 0,93 para 0,88 entre a primeira avaliação (96 DAS – Figura 3A) e a penúltima (123 DAS) utilizando drone. A variação do NDVI foi pequena, o que fez com que ele não apresentasse boa qualidade na previsão da maturação de amendoim. Carneiro (2018) também encontrou saturação do NDVI no estágio reprodutivo da cultura do amendoim (75 DAS) com valores médios de 0,89 entre os estádios R2 e R4.

Com esses resultados, foi possível observar com base nas cartas de controle que o NDVI e o NLI não conseguiram expressar pequenas alterações na variabilidade ao longo do tempo (elevada quantidade de biomassa), mas, no entanto, na medida em que a taxa da reflectância do NIR/RED diminui, variando de 8-9, o NDVI reduziu a sensibilidade. Esse comportamento de menor sensibilidade na saturação devido à taxa de reflectância NIR/RED é facilmente notado nas cartas de controle no SR, em que esse IV diminuiu na medida em que essa taxa diminui. Gitelson (2019) ressalta que uma das principais razões na redução da sensibilidade do NDVI é quando a taxa NIR/RED fica na faixa de 7-10, para condições de alta densidade foliar. Quanto ao GNDVI, este foi sensível quando houve reduzida alteração na variabilidade, o que é

explicado pela reflectância na banda do verde ter sido maior que a do vermelho, fazendo com que o GNDVI acompanhasse a redução da reflectância.

De modo contrário, quando esses IV foram obtidos por meio de imagem de satélite, estes foram menores do que quando utilizando drone, e todos acompanharam a redução da variação, fato que pode ser atribuído a menor taxa de reflectância (NIR/RED), o que pode não ter ocasionado saturação dos IV. Apesar de apresentarem valores de reflectância menores, o comportamento após os 117 DAS foram similares para ambas as plataformas (drone e satélite).

A ocorrência da doença pinta preta no final do ciclo da cultura de amendoim pode interferir na associação dos resultados com a maturação das vagens, uma vez que, quando o dossel da cultura é infestado pela doença, a reflectância tende a diminuir, devido à mudança na quantidade de pigmentos, tais como clorofila, carotenoides e xantofilas (Devadas et al., 2009). Contudo, tal interferência tende a acontecer nas bandas do visível e do NIR (Sankaran et al., 2010; Chen et al., 2019), tão logo a utilização de outras bandas espectrais como o Red-Edge por exemplo, podem ter melhor relação com o processo de maturação, e, consequentemente, reduzir a subjetividade do método *Hull-scrape*.

Apesar da interferência na reflectância na banda do visível (vermelho), especialmente no final do ciclo, as cartas de controle para o SR indicam que o monitoramento do dossel das plantas de amendoim utilizando esse IV pode ser eficiente, uma vez que ele mostrou melhores indicadores de qualidade ao longo do tempo. Esta mudança da variabilidade pode ser constatada pela variação das amplitudes entre os limites inferior e superior de controle (Figura 8 A) para cada avaliação ao longo do tempo. No início das avaliações (96 DAS), esta amplitude foi de 5,16, reduzindo progressivamente a 4,6°, até atingir 2,12 aos 135 DAS (Figura 8 A).

Este comportamento indica que o SR tende a saturar com menor facilidade, e pode estar associado com a maturação das vagens de amendoim, visto que o PMI também reduziu a variabilidade, passando de 0,25 aos 96 DAS para 0,21 aos 135 DAS (Figura 8 B).




Figura 8. Análise de regressão para amplitude de variação do índice de vegetação SR (A) e índice de maturação (B), ao longo das semanas avaliadas.

Quanto à reflectância em cada banda espectral, a redução na variabilidade da reflectância do vermelho aos 107 dias pode estar relacionada ao pico de florescimento das plantas de amendoim, que acontece aproximadamente aos 70 DAS (Boote, 1982). Após esse estágio de desenvolvimento, as plantas de amendoim reduzem o crescimento do dossel (emissão de folhas novas) e aumentam a translocação de nutrientes para a produção e desenvolvimento das vagens (Smith, 1954), o que pode ter ocasionado a alta variabilidade na maturação aos 107 DAS.

Drone x Imagem de satélite de alta resolução

No que diz respeito à utilização de cada plataforma, ambas possuem qualidade similar no monitoramento da qualidade da vegetação de plantas de amendoim. Contudo, nota-se que as imagens utilizando drone tiveram um número menor de parcelas em alguns dias, o que foi ocasionado pela interferência de nuvens que apareceram logo após o início do voo. Por outro lado, as imagens do satélite PlanetScope permitiram que todas as parcelas fossem utilizadas na análise, o que aumenta a confiabilidade. Entretanto, ao escolher as imagens para serem utilizadas, foram selecionadas somente aquelas que possuíam menos que 1% de nuvens na cena.

A ocorrência da doença na área experimental permitiu, de forma indireta, verificar que as imagens do satélite PlanetScope possuem alto potencial no

monitoramento de doenças que causam desfolha das plantas de amendoim, principalmente no final do ciclo. Sendo que aos 135 DAS, os valores de NDVI ficaram na média (0,5), próximos a valores que são considerados por Rouse (1974) como superfície com pouca cobertura vegetal (0,25 – 0,40). O que indica que produtores podem tomar algumas providências visando garantir uma colheita de amendoim com melhor qualidade, visto que a biomassa vegetal sobre a esteira vibratória do arrancador-invertedor auxilia na redução de perdas (Santos et al., 2016, Ferezin et al., 2019).

A utilização do satélite PlanetScope no monitoramento da lavoura de amendoim é interessante, visto que o tempo de revisitação do satélite é de 1 dia, isso garante o monitoramento diário da lavoura, quando comparado com outros satélites que o tempo de revisita em uma mesma área pode ser de até 5 dias (Vrieling et al., 2018). Por outro lado, o monitoramento por meio de imagens de satélites pode reduzir a qualidade quando na presença de nuvem densa, o que se faz necessário aplicar filtros para redução da interferência de nuvens (Champion, 2016; Tseng et al., 2008).

Conclusões

Com base nas análises das ferramentas de controle de qualidade (cartas de controle e gráficos sequenciais), as duas plataformas apresentaram comportamento similar para o monitoramento da cultura do amendoim, indicando potencial uso dessas ferramentas no monitoramento da vegetação em associação com o sensoriamento remoto.

Dentre os IVs utilizados nesse trabalho, o SR apresentou melhor qualidade em detectar a variabilidade ao longo do tempo, bem como potencial em predizer a maturação das vagens de amendoim. Contudo, vale ressaltar que o comportamento desse índice pode ter sido afetado pela ocorrência de doenças foliares próximo ao final do ciclo da cultura.

As plantas de amendoim reduziram a refletância na banda do RED aos 107 DAS, provavelmente pelo aumento da taxa fotossintética para produção de fotoassimilados, destinados à produção e enchimento das vagens no pico de frutificação.

Os IVs NDVI, NLI e GNDVI apresentaram sensibilidade em relação à redução da biomassa vegetal, indicando que eles podem ser utilizados no monitoramento da ocorrência da doença pinta preta, por meio de imagens de drone ou de satélite de alta resolução.

Referências

Boote, K. J. (1982) Growth stages of peanut (*Arachis hypogaea* L.). Peanut Science, v.9 (1), pp. 35–40, 1982.

Branch, W. D. (2007) Registration of ‘Georgia-06G’ peanut. Journal Plant Register, 1,120.

Campos, I., Gonzalez-Gomez, L., Villodre, J., Calera, M., Campoy, J. et al. (2018) Mapping within-field variability in wheat yield and biomass using remote sensing vegetation indices. Precision Agriculture

Carley, D., Jordan, D., Dharmasri, L., Sutton, T., Brandenburg, R., Burton, M. (2008) Peanut response to planting date and potential of canopy reflectance as an indicator of pod maturity. Agronomy Journal 100 (2), 376–380.

Carneiro, F.M (2018) Sensores de dossel no monitoramento da variabilidade das culturas da soja e do amendoim. Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias– Unesp. 107p.

Champion, N. (2016) Automatic detection of clouds and shadows using high resolution satellite image time series. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B3, 475–479.

Chen T, Zhang J., Chena, Y., Wan, S., Zhang, L. (2019) Detection of peanut leaf spots disease using canopy hyperspectral reflectance. Computers and Electronics in Agriculture, 156, 677–683.

Clevers, J.G.P W., Kooistra, L., Brande, M.M.M.V (2017) Using Sentinel-2 Data for Retrieving LAI and Leaf and Canopy Chlorophyll Content of a Potato Crop. Remote Sensing, 9(5), 405.

Colvin, B., Rowland, D., Ferrell, J., Faircloth, W. (2014) Development of a digital analysis system to evaluate peanut maturity. *Peanut Science*, 41(1), 8-16.

Devadas, R., Lamp, D.W., Simpfendorfer, S., Backhouse, D. (2009) Evaluation ten spectral vegetation indices for identifying rust infection in individual wheat leaves. *Precision Agriculture*, 10, 459–470.

Duncan, W.G., Mc Cloud, D.E., Mc Graw, R.L., Boote, K.J. (1978) Physiological aspects of peanut yield improvement. *Crop Science*. 18(6), 1015-1020.

Ferezin, E., Silva R.P., Santos, A.F., Zerbato, C. (2018) Development of an electrohydraulic drive system for the vibrating conveyor belt of the peanut digger-inverter. *PlosOne* 13(10).

Fincher, P.G., Young, C.T., Wynne, J.C. and Perry, A. (1980). Adaptability of the arginine maturity index method to Virginia type peanuts in North Carolina. *Peanut Science*, 7(2), 83-87.

Gitelson A.A (2004) Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology* 161(2), 165–173.

Gitelson, A.A. (2019) Remote estimation of fraction of radiation absorbed by photosynthetically active vegetation: generic algorithm for maize and soybean, *Remote Sensing Letters*, 10(3), 283-291.

Gitelson, A.A., Merzlyak, M.N. (1996) Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*. 148(3-4), 494–500.

Goel, N.S., Qin, W. (1994). Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. *Remote Sensing Review* 10(4), 309–347.

Gong, P., Pu, R., Biging, G.S., Larrieu, M.R. (2003) Estimation of Forest Leaf Area Index Using Vegetation Indices Derived from Hyperion Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing* 41(6), 1355 - 1362.

González-Gómez, L., Campos, I., Calera, A. (2018). Use of different temporal scales to monitor phenology and its relationship with temporal evolution of normalized difference vegetation index in wheat. *Journal of Applied Remote Sensing*, 12(2).

Jordan, C.F. (1969) Derivation of leaf area index from quality of light on the forest floor. *Ecology*, 50(4), 663–666.

Lamb, M.C., Masters, M.H., Rowland, D., Sorensen, R.B., Zhu, H., Blankenship, P.D. Butts, C. L. (2004) Impact of sprinkler irrigation amount and rotation on peanut yield. *Peanut Science*. 31(2),108-113.

Liang, Wei-zhen., Kirk, K. R., Thomas, J. (2018) Estimation of Peanut Maturity Using Color Image Analysis. 2018 ASABE Annual International Meeting, Detroit, Michigan.

Lobell, D. B., Azzari, G. (2017) Satellite detection of rising maize yield heterogeneity in the U.S. Midwest. *Environmental Research Letters*, 12(1) 1-9.

Minitab. 2007. Minitab Release 16: Meet Minitab 16. Minitab StatGuide; Minitab Help. Minitab, State College, PA.

Monsef H. A., Smith S.E., Rowland D. L., Rasol N. A. E. (2019). Using multispectral imagery to extract a pure spectral canopy signature for predicting peanut maturity. *Computers and Electronics in Agriculture*, 162(7), 561-572.

Planet Team. (2017). Planet — Planet Imagery Products. Retrieved May 25, 2018, from <https://www.planet.com/docs/spec-sheets/sat-imagery/>

Rouse, J.W., Haas, J.R.H. Schell, J.A. and Deering, D.W. (1974). In Proc. ERTS-1 Symp., Greenbelt, MD. 10–15 Dec. 1974. NASA, Washington, D.C. 1974. Monitoring vegetation systems in the Great Plains with ERTS. 309-317.

Rowland, D.L., R.B. Sorensen, C.L. Butts, W.H. Faircloth. (2006) Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33(2),125-136.

Sanders, T.H., A.M., Schubert, Pattee, H.E. (1995) Maturity methodology and postharvest physiology in Peanut Science and Technology, pp. 624–654, American Peanut Research and Education Society.

Sankaran, S., Mishra, A., Ehsani, R., Davis, C., (2010) A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*. 72(1), 1–13.

Santos, A.F., Kazama, E.H., Ormond, A.T., Tavares, T.D., Silva, R.P. (2016) Quality of mechanized peanut digging in function of the auto guidance. *African Journal of Agricultural Research*, 11(48), 4894-4901.

Santos, A.F., Silva, R.P., Zerbato, C., Menezes P. C., Kazama, E. H., Paixão C. S. S., Voltarelli, M, A. (2018) Use of real-time extend GNSS for planting and inverting peanuts *Precision Agriculture*. pp 1–17.

Stamatiadis, S., Taskos, D., Tsalida, E., Christoforides, C., Tsalidas, C., and Schepers, J. S. (2010). Comparison of passive and active canopy sensors for the estimation of vine biomass production. *Precision Agriculture*, 11, 306–315.

Tavares, T.O., Borba, M. A. P. Oliveira, B. R. Silva, R. P. Voltarelli, M. A. Ormond, A. T. S. (2018). Effect of Soil Management Practices on the Sweeping Operation during Coffee Harvest. *Agronomy. Journal*. 110:1689-1696.

Thenkabail PS, Smith RB, De Pauw, E (2000) Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment* 71:158–182.

Tseng, D.C., Tseng, H.T., Chien, C. L. (2008). Automatic cloud removal from multi-temporal SPOT images. *Applied Mathematics and Computation*, 205(2), 584–600.

Vrieling, A., Meroni, M., Darvishzadeh, R., Skidmore, A. K., Wang, T., Zurita-Milla, R., Oosterbeek, K., O'Connor, Brian., Paganini, M. (2018). Vegetation phenology from Sentinel-2 and field cameras for a Dutch barrier island. *Remote Sensing of Environment*. 215, p 517-529.

Williams, E.J., Drexler, J.S. (1981) A non-destructive method for determining peanut pod maturity. *Peanut Science*, 8(2), 134–141.

Yu, N., Li, L. N., Schmitz, L.F. Tian, Greenberg, J.A., Diers, B.W. (2016) Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sensing of Environment*, 187, pp. 91-101.

Capítulo 3: Using aerial remote sensing to map in-field variability of peanut maturity

Abstract

Peanut maturity is generally measured by collecting plants from four or five locations within a field and manually performing the peanut hull-scrape method. Although the hull-scrape method is a relevant indicator of maturity, it is labor intensive and a few samples do not provide a substantial understanding of the spatial variability of maturity at the field scale. During the 2018 growing season, a study was conducted to assess if vegetation indices (VIs) could be used as indicators of peanut maturity at the field scale. The study was conducted in a 24-ha block of two commercial fields (dryland and irrigated conditions). The block was divided into 24 1-ha cells. For the final six weeks of the growing season, plant samples were collected from each cell and the hull scrape method was used to rate maturity. At the sample dates, an unmanned aerial vehicle (UAV) equipped with a multispectral camera was used to measure spectral reflectance from the peanut canopy. The reflectance data were used to evaluate several VIs as potential indicators of peanut maturity. NDVI, GNDVI and SR showed moderate correlation with maturity only for the irrigated field. The Red Edge (RE) band (730-740 nm) was the most sensitive. In both fields, the most responsive VIs were the Nonlinear Index (NLI) and the Modified Nonlinear Index (MNLI) when Red reflectance was replaced by RE reflectance.

Keywords: Vegetation Index, Multispectral Images, Reflectance, Red Edge, UAV

Introduction

Peanut (*Arachis hypogaea* L.) crop produces its fruit, known as a peanut pod, underground. After fertilization of the flower, a stalk commonly referred to as peg elongates with the ovary and grows down into the soil. The tip of the peg then develops into a mature peanut pod (Smith, 1950). Because peanut is an indeterminate crop, it produces flowers for extended periods during the growing season, using energy for

development and maturity of the pods. As a result, peanut pods of varying maturity are present on the plant as harvest time approaches. Harvesting a field at peak maturity results in highest seed quality and yields. Immature pods generally have seeds with lower oil content and thus decreased quality (Fincher et al., 1980). On the other hand, harvesting plants with overly mature pods result in yield losses up to 40% because the pods detach from the pegs staying in the soil (Lamb et al., 2004). Determining optimum maturity is difficult as there are no obvious aboveground indicators.

Williams and Drexler (1981) observed that as peanut pods mature, the pods' mesocarp (second layer of the pod's skin) changes color from white to black and further developed the Hull-Scrape Method for determining peanut maturity. This method has been widely used for peanut producers in the US and other countries. A pod sample that is representative for the entire field is collected for mesocarp exposure and arrangement in the maturity profile board according to color (Doc 1). A maturity profile is created and optimum maturity occurs when the leading edge of the sample profile reaches the slope line on the board.

An additional method to the hull-scrape technique for predicting maturity is the peanut maturity index (PMI; Rowland et al. 2006) developed for runner-type peanuts. The PMI is calculated by dividing the number of mature pods (brown + black) by the sum of the total pods in the sample. Optimal maturity occurs when a sample has a PMI of 0.7. Overall, the hull-scrape method is labor intensive, subjectively based on a person's ability to place pods in the correct color category, and subjected to field micro-variability that may affect maturity of individual plants. Alternatives to estimate pod

maturity across the entire fields rather than individual plants would assist producers to make more accurate harvest decisions.

Researchers across the globe have established that variability exists in all aspects of crop response within most fields, such as biomass and leaf nitrogen content (Amaral et al., 2015), cotton plant height (Souza et al., 2017), wheat yield (Marti et al., 2007) and corn (Shanahan et al., 2001; Oliveira et al., 2019). This also holds true for the rate at which peanut matures in different areas of a field (Vellidis and Beasley, 2013). The use of remote sensing to predict peanut maturity at a field scale has been explored in the past. Rowland et al. (2008) found that the reflectance in the near infrared (NIR) band was more strongly correlated with peanut maturity when compared to other bands. Changes in peanut reflectance in the red edge (RE) band as pods approach maturity indicate that these wavelengths are also sensitive to pod maturity (Robson et al., 2006). Vegetation Index (VI) have been shown to be a good tool for monitoring maturity in various crops such as soybean (Yu et al., 2016).


Sanders et al. (2002), Robson et al. (2006), Carley et al. (2008) and Rowland et al. (2008) evaluated VIs as indicators of peanut maturity, but they were unable to identify an index that consistently predicted peanut maturity. Vellidis and Beasley (2013) used a tractor-mounted optical reflectance sensor to evaluate the response of VIs to peanut maturity on a plot-scale. The authors found that Non Linear Index (NLI) was the better predictor of maturity for many peanut varieties. However, elucidation is still required on whether VIs can successfully be used to predict pod maturity in peanut plants. Therefore, the objective of this study was to determine whether reflectance obtained through use of remote sensing can potentially be used as an indicator of

variability in pod maturity at field scale and identify VIs that most accurately predict maturity in peanut plants cultivated under dryland and irrigated field conditions.


Materials and Methods

The study was conducted in two commercial peanut fields in Georgia, USA, a rainfed located in Coffee County (31°27'38.20"N, 82°38'15.10"W) and an irrigated field located in Calhoun County (31°32'44.64" N, 84°28'12.24" W). The peanut cultivar used was Georgia-06G, a runner type with dark green foliage that typically requires about 2500 degree days (140 days after planting) to reach maturity (Branch, 2007). Historical satellite images of the field were analyzed to select a block of the field with the greatest soil variability. The block was divided into 24 1-ha grid cells.

Precipitation and maximum and minimum temperatures during the peanut crop season was sufficient for peanut development, mainly in the peak of flowering for both fields (Fig. 1).



(A)



(B)

Figure 1: Precipitation (bars) and maximum (solid line) and minimum (dashed line) temperatures during the 2018 peanut growing season in the irrigated (A) and dryland (B) fields.

Ten peanut plants were collected from a radius of approximately 10 m from the center of the grid cells weekly starting at 96 days after planting (DAP) for six consecutive weeks until final harvest at 138 DAP. From each plant, all peanut pods were removed until reaching about 200 pods per sampling point. Then, the pods were pressure-washed to expose the mesocarp, placed on the peanut profile board and the

number of pods in each color class was recorded (Williams and Drexler, 1981). The PMI was further calculated for each sample according to Rowland et al. (2006).

At each sampling time, a Parrot Sequoia (Paris, France) camera attached to a 3DR solo (Berkeley, EUA) quadcopter UAV was used to capture multispectral images in 4 different bands, Green (530-570 nm), Red (640-680 nm), NIR (770-810 nm) and RE (730-740 nm). All UAV flights were done within 2 h of solar noon from an altitude of 90 m with 70% overlap. At 90 m, the spatial resolution of the camera was 0.95 m. The tower app was used to create the flight plans. Before and after each flight, the camera was used to take images of a calibration panel that were later used to calibrate the images acquired over the field. Black and white 1 × 1 m targets were located at the corners of the 24-ha block to serve as ground control points (GCPs). The geographic coordinates of the four GCPs and the 24 block were recorded with a Trimble R8 GNSS (Sunnyvale, EUA).

The Pix4D software was used to create mosaics of reflectance maps in each one of the four bands and to perform radiometric calibration and georeferencing corrections. After the mosaics were created, ArcGIS (Redlands, EUA) software was used to extract an average reflectance value for the pixels in each of the 24 grid cells in both fields.

Seven VIs that have been used in other studies to predict crop maturity were selected for evaluation (Table 1).

Table 1. Vegetation indices used to estimate peanut maturity.

Vegetation Indices ¹	Formula ²	Reference
NDVI	(NIR - RED) / (NIR + RED)	Rouse et al. (1974)
GNDVI	(NIR - Green) / (NIR + Green)	Gitelson and Merzlyak (1996)
NLI	(NIR ² -RED)/(NIR ² +RED)	Goel and Qin, (1994)
MNLI	(NIR ² -RED)(1+L)/(NIR ² +RED+L)*	Gong et al. (2003)
NDRE	(NIR-RED)/(NIR+RED)	Fitzgerald et al. (2010)
SR	NIR/RED	Jordan (1969)
MSR _{RE}	(NIR/ RE - 1) / [(NIR/ RE) ^{1/2} +1]	Wu et al. (2008)

¹NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; NLI: non-linear index; MNLI: modified non-linear index; NDRE: normalized difference red edge index; SR: simple ration; MSR_{RE}: modified simple ration red edge index.

² Spectral bands: near infrared (NIR); red and green. * adjustment factor (L = 0.5).

Data analysis

Pearson's correlation ($p < 0.001$) was used to verify the correlation between the VIs and peanut maturity using the Minitab Software (Minitab, 2007).

The general performance of the models was evaluated by comparing the differences in determination coefficient (R^2) and root mean square error (RMSE). Higher R^2 values and lower RMSE indicate that a VI has higher precision in estimating peanut maturity. RMSE values were classified as high (> 0.20), medium (< 0.20 and > 0.15) and low (< 0.15). The RMSE was calculated using the following Eq. 1:

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (P_i - O_i)^2} \quad (Eq. 1)$$

where P_i and O_i are the predicted and the observed values, respectively, and n is the number of samples.

In order to verify which spectral band had the greatest contribution in the analysis, a principal component analysis (PCA) was performed and, based on the PCA analysis, the NIR and red edge bands explained 51.24% of the data variation, the modification of the IV, NLI, MNLI and SR, replacing the red band by the Red Edge (RE), according to Table 2.

Table 2. Modified vegetation indices used to estimate peanut maturity.

Vegetation indices ¹	Formula
MNLI _{RE}	$(\text{NIR}^2 - \text{RE})(1 + L) / (\text{NIR}^2 + \text{RE} + L)^*$
NLI _{RE}	$(\text{NIR}^2 - \text{RE}) / (\text{NIR}^2 + \text{RE})$
SR _{RE}	NIR / RE

¹ MNLI_{RE}: modified non-linear red edge index; NLI_{RE}: non-linear red edge index; SR_{RE}: simple ration red edge index.

² Spectral bands: RE red edge; near infrared (NIR); red and green. * adjustment factor (L = 0.5).

Results and discussion

In general, the original IV presented high variability between the irrigated and dryland fields, which resulted in different response for most of them, except the MSR (Figure 2). According to the classification range established in material and methods section for RMSE values, the IVs that presented low values were SR, GNDVI, NDVI and MLNI (RMSE <0.150), mean values NLI₍₇₃₀₋₇₄₀₎, MNLI₍₇₃₀₋₇₄₀₎ and MSR (RMSE = 0.154, 0.163 and 0.171, respectively) and high values SR and NDRE (RMSE > 0.200) in irrigated field (Figure 2). In a dryland area, only the MNLI₍₇₃₀₋₇₄₀₎ presented low RMSE values. The MNLI, NDRE, MSR, SR and SR₍₇₃₀₋₇₄₀₎ presented mean values error (RMSE between 0.150 and 0.200).

Comparing the performance of VI's between the two fields, the GNDVI and NDVI presented the highest variability with RMSE values in the irrigated area of 0.222 and 0.240, respectively. On the same classification of error, the NLI and MNLI₍₇₃₀₋₇₄₀₎, showed a similar RMSE value (0.205). Other important difference is noted in the R² value. The highest VI's precision to estimate peanut maturity in the irrigated field were using SR, GNDVI, and NDVI, with all these VI's showing R² > 0.70. Whilst in the dryland field, the highest precision value to predict peanut maturity was obtained when using NLI₍₇₃₀₋₇₄₀₎, MNLI₍₇₃₀₋₇₄₀₎, and NDRE (R² > 0.57).

According to the accuracy and precision of the model (RMSE e R^2) for both areas indicate that NLI (730 740), showed the highest overall performance in maturity prediction due to its low variation of the R^2 and RMSE between the fields with different water regimes. On the other hand, the SR (730 740) had lower R^2 and higher RMSE values in the two areas compared with the original index, indicating that the original VI had a more efficient response in the prediction of peanut maturity than the modified index.




Figure 2. Comparison of the mean values of linear adjustment R^2 and RMSE over the six weeks evaluated (empty bars and diamonds refer to the R^2 and RMSE values of the irrigated area respectively, and full bars and lozenges refer to the dryland field). Modified vegetation indices are presented followed by wavelength 730-740.

All VIs analyzed showed a significant and negative Pearson correlation ($p < 0.001$) with peanut maturity (Table 3). NDVI and GNDVI indicated a weak to moderate Pearson correlation in the irrigated field whereas a strong correlation was observed for these indices in the dryland area (Figure 3). Under dryland conditions, the R^2 for the regression lines were notably low (NDVI= 0.066 and GNDVI= 0.200) and

RMSE were high (0.240 and 0.222 for NDVI and GNDVI, respectively; Figure 3). Significant variation in the NDVI and GNDVI values were not observed in the dryland field throughout the weeks the flights were performed. This indicates that these indices saturated, and were not able to capture variation in the plant canopy and pod maturity.

Table 3. Pearson correlation between VIs and peanut maturity.

Vegetation Index	Dryland	Irrigated
GNDVI	-0.4470**	-0.8837**
NDVI	-0.2566*	-0.8545**
SR	-0.6047**	-0.9329**
MSR	-0.7112**	-0.7197**
MNLI	-0.5610**	-0.7982**
NLI	-0.5659**	-0.8272**
NLI (730-740)	-0.8189**	-0.7813**
MNLI (730-740)	-0.7917**	-0.7494**
SR (730-740)	-0.6850**	-0.7091**

**Pearson correlation significant at $p < 0.001$ and *significant at $p < 0.05$

The NDVI and GNDVI saturation over the six-week evaluation on the dryland field was caused by the elevated green biomass. The high plant density increases the leaf area index (LAI). NDVI has been extensively used to estimate LAI for different crops, and it has been observed that NDVI increases with increased LAI values until it reached a saturation point (Gitelson 2004; Corti et al., 2018). GNDVI is an alternative index to NDVI that has a linear response to increases in chlorophyll content, and is less sensitive to saturation than NDVI (Gitelson and Merzlyak, 1997).

Carley et al. (2008) found similar results to those observed in this study, in which NDVI was not significantly correlated with maturity of Virginia-type peanut. In contrast, Sanders et al. (2002) identified NDVI as a promising index to predict peanut maturity in runner and Valencia peanut types. Controversial results can be explained by the different spectral responses of different cultivars. Aparicio et al. (2000) found that spectral correlations between NDVI and wheat maturity were positively correlated only

in the second half of the grain filling stage under field irrigation. It is confirming that each cultivar and species has its unique spectral response, which enables researchers to use remote sensing in plant breeding programs (Trachsel et al., 2019).

The plant density in the irrigated field was lower and the field had less soil variability than the dryland area. Hence, NDVI and GNDVI showed highest correlation with peanut maturity ($R^2 > 0.7$ e Pearson correlation > -0.85 ; Figure 2 and Table 2). GNDVI values decreased with progress of plant growth and pod maturity (Figure 3b). It can be correlated with reduced LAI and reflectance in NIR band due to foliar damage. Also, in this field the Michael Hurricane may have caused increased defoliation. Conversely, Rowland et al. (2008) observed an increase in GNDVI calculated from peanut reflectance data.




Figure 3. Regression analysis between Peanut Maturity Index (PMI) and NDVI (A) and GNDVI (B).

Solid line: irrigated field; dashed line: Dryland field.

MNLI and NLI had a similar response for both field conditions (Figures 4A and B). NLI varied from 0.25 to 0.55 in the dryland field and from 0.55 to 0.86 in the irrigated area. A unique characteristic of the peanut crop is the reduction in LAI as plants stay in the field due to an increase in leaf disease incidence. The NLI reduced the reflection contrast and saturation by using the squared values of the near infrared band reflectivity, which then linearized the relationship with LAI (Feng et al., 2019). On the other hand, in the irrigated field NLI and MNLI had higher R^2 and lower RMSE. Vellidis and Beasley (2013) reported NLI as a potential index to predict maturity, with the slope

of NLI consistently decreasing and approaching zero at maturity. However, a consistent change in slope for the NLI values was not observed in the current study.




Figure 4. Regression analysis between Peanut Maturity Index (PMI) and MLNI (A), NLI (B), NDRE (C), MSR_{RE} (D), and SR (E).

Full line: irrigated field; dotted line: Dryland field.

Among all seven indices, none of the original VIs provided an inflection point or indicator of peanut maturity other than a steady decline in value in both fields. Nevertheless, NDRE, MSR and SR had the highest performance in predicting peanut maturity in the irrigated field (Figures 4 C, D and E).

The utilization the RE band conferred a higher stability of MNLI and NLI vegetation indices under the two field conditions. MNLI and NLI had similar R^2 values, with both being higher than 0.562. The statistical parameters suggested that these two indices can be used to estimate peanut maturity in irrigated and non-irrigated areas. $NLI_{(730-740)}$ values from -0.51 to -0.41 indicated that peanuts had a maturity index of 65% or higher in dryland fields, while in the irrigated field this same percentage of maturity was represented by values from -0.30 to -0.25.

A correlation ($p < 0.001$) between $MNLI_{(730-740)}$ values and maturity index was also observed, with values from -0.28 to -0.23 representing a maturity index of 70% for dryland and -0.18 to -0.15 for irrigated fields (Figures 5A and B). These results indicate that including RE reflectance in the VIs adds significant power to their ability to track maturity in peanut. This is likely because RE reflectance is more sensitive to small physiological changes in the plant leaves as the pods mature (Robson et al., 2006). However, vegetation indices such as SR did not show any improvement from the addition of the RE band. The R^2 values were lower than 0.5 and RSME was higher than 0.198, which had a less efficient performance than its original version.

The improved performance of the modified VIs can be related to the penetration capacity of RE wavelengths into the leaf and their ability to respond to small changes in chlorophyll *a* even in conditions of elevated biomass (Li et al., 2014) in which many other VIs are prone to saturate. However, changes in chlorophyll *a* absorption can be caused by many different factors including water stress and disease and is not necessarily directly related to maturity.

After replacing red reflectance with RE reflectance, $NLI_{(730-740)}$ showed an even higher correlation with maturity (Pearson = -0.8181) and an R^2 of 0.671 (Figure 5a). This modified version of NLI was the highest performing VI among the ten VIs evaluated. A similar trend was observed for $MNLI_{(730-740)}$, resulting in higher correlation and R^2 values than their original versions (Figure 5b). The improved performance of

VIs using RE band instead of the red band was also pointed by Hatfield et al. (2008). The authors found that indices containing the RE band were more sensitive to different nitrogen contents in the corn leaf. In addition, the saturation of common indices, such as NDVI, can be attenuated when combining wavelengths that penetrate more the canopy such as NIR and RE (Van Niel and McVicar, 2004). However, the application of these indices in different crops must be done with caution, since differences in leaf structure, reflectance and contents of chlorophylls a and b vary from crop to crop (Dong et al., 2019).




Figure 5: Regression analysis between Peanut Maturity Index (PMI) and two modified vegetation index, $NLI_{(730-740)}$ (A) and $MNLI_{(730-740)}$ (B).

Conclusion

The use of remote sensing has a great potential to predict peanut maturity, thus improving farmers' efficiency in selecting the most accurate time to harvest peanuts. An additional advantage is the possibility to generate maturity maps and use them to improve harvest logistics by selecting which parts of the field should be harvested first. The majority of VIs studied were correlated to maturity although most had low R^2 values. NDVI and GNDVI did not indicate a consistency in predicting peanut maturity. $NLI_{(730-740)}$ and $MNLI_{(730-740)}$ were strongly related to PMI and may be promising

indicators of peanut maturity. However, a specific VI value cannot yet be used to predict optimal peanut maturity. Additional research is needed to replicate this work in more fields over two or more years with different varieties to confirm these results. A larger number of data collection days may also assist in evaluating the trend lines of the VIs. Nevertheless, the results are encouraging and indicate that remote sensing may provide an alternative to the Hull-Scrape Method for maturity prediction in peanuts.

Acknowledgements

This project was funded by the Georgia Agricultural Commodity for Peanuts in partnership with the Brazilian Research Funding Agency CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior). We thank Mr. Drew Walker for allowing us to conduct the study in his field.

Conflict of Interest

The authors declare that they have no conflict of interest.

References

- Amaral L. R, Molin J. P, Portz G, Finazzi FB, Cortinove L. (2015) Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. *Precision Agriculture*, 16:15-28.
- Aparicio, N., Villegas, D., Casadesus, J. Araus, J.L., Royo. C. (2000) Spectral vegetation indices as nondestructive tools for determining durum wheat yield. *Agronomy Journal*, 92:83–91.
- Branch, W. D. (2007) Registration of ‘Georgia-06G’ peanut. *Journal Plant Register*, 1,120.
- Carley, D. S., Jordan, D. L., Dharmasri, L. C., Sutton, T. B., Brandenburg, R. L. and M. G. Burton. (2008) Peanut Response to Planting Date and Potential of Canopy Reflectance as an Indicator of Pod Maturation. *Agronomy Journal*, 100:376-380

- Corti, M., Cavalli, D., Cabassi, G., Gallina, P.M., Bechini, L., (2018) Does remote and proximal optical sensing successfully estimate maize variables? A review, *European Journal of Agronomy*, 99, 37-50.
- Dong, T., Liu J., Shang, J., Qian, B., Ma, B., Kovacs, J.M., et al. (2019). Assessment of red-edge vegetation indices for crop leaf area index estimation. *Remote Sensing of Environment*, 222:133–143.
- Feng, W., Wu, Y., He, L., Ren, X., Wang, Y. Hou, G., Wang, Y., Liu, W., Guo, T. (2019) An optimized non-linear vegetation index for estimating leaf area index in winter wheat. *Precision Agriculture*, 1-20.
- Fincher, P.G., Young, C.T., Wynne, J.C. and Perry, A. (1980) Adaptability of the arginine maturity index method to Virginia type peanuts in North Carolina. *Peanut Science* 7:83-87.
- Fitzgerald, G., Rodriguez, D., O’Leary, G., (2010) Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index – the canopy chlorophyll content index (CCCI). *Field Crops Research*. 116:318–324.
- Gitelson, A. A. (2004) Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology*, 161:165–173.
- Gitelson, A. A., and Merzlyak, M. N. (1997) Remote estimation of chlorophyll content in higher plant leaves. *International Journal of Remote Sensing*, 18, 2691–2697.
- Gitelson, A.A., Merzlyak, M.N. (1996) Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, 148, 494–500.
- Goel, N. S. and Qin, W. (1994) Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. *Remote Sensing Review*, 10: 309–347.
- Gong, P., Pu, R., Biging, G.S., Larrieu, M. R. (2003) Estimation of Forest Leaf Area Index Using Vegetation Indices Derived from Hyperion Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing*, 41:1355 - 1362.

- Hatfield, J.L., Gitelson, A.A., Schepers, J.S., Walthall, C.L., (2008) Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*. 100, 117–131.
- Jordan, C.F. (1969). Derivation of leaf area index from quality of light on the forest floor. *Ecology*. 50:663–666.
- Lamb, M.C., Masters, M.H., Rowland, D., Sorensen, R.B., Zhu, H., Blankenship, P.D., et al. (2004) Impact of sprinkler irrigation amount and rotation on peanut yield. *Peanut Science*. 31:108-113.
- Li, F., Miao, Y., Feng, G., Yuan, F., Yue, S., Gao, X., et al. (2014) Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. *Field Crops Research*. 157, 111–123.
- Marti, J., Bort, J., Slafer, G.A., Araus, J.L. (2007) Can wheat yield be assessed by early measurements of normalized difference vegetation index? *Annals of Applied Biology*, 150(2), 253-257.
- Oliveira, M. F., Ormond, A.T. S., de Freitas Noronha, R. H., Santos, A. F., Zerbato, C., Furlani, C. E. A. (2019) Prediction Models of Corn Yield by NDVI in Function of the Spacing Arrangement. *Journal of Agricultural Science*, 11(6).
- Robson, A.J., Wright, G., Phinn S. (2006) Using field spectroscopy and quickbird imagery for the assessment of peanut crop maturity and aflatoxin, *Journal of Spatial Science*, 51:2, 151-162.
- Rouse, J.W., Haas, J.R.H. Schell, J.A. and Deering, D.W. (1974) In Proc. ERTS-1 Symp., Greenbelt, MD. 10–15 Dec. 1974. NASA, Washington, D.C. 1974. Monitoring vegetation systems in the Great Plains with ERTS. 309-317.
- Rowland, D.L., R.B. Sorensen, C.L. Butts, and W.H. Faircloth. (2006) Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33:125-136.
- Rowland, D.L., Sorensen, R.B., Butts, C.L. Faircloth, W.H., and Sullivan, D.G. (2008) Canopy characteristics and their ability to predict peanut maturity. *Peanut Science*, 35:43-54.

- Sanders, J.C., Reynolds, D.B., Wilson, D.G., and Bruce, L.M. (2002) Utilizing remote sensing to determine crop maturity. *Proceedings - Southern Weed Science Society*, 55:147-147.
- Shanahan F., Schepers, S.D., Varvel, F.E., Wilhelm, W., Tringe, S., Schlemmer, R., Major, J. (2001) Use of remote sensing imagery to estimate corn grain yield. *Agronomy Journal*, 93:583-589
- Smith, B. W. (1950) *Arachis hypogaea*: Aerial flower and subterranean fruit. *American Journal of Botany*. 37: 802–815. doi:10.2307/2437758.
- Souza, H.B., Baio, F.H.R., Neves, D.C. (2017) Using passive and active multispectral sensors on the correlation with the phenological indices of cotton Engenharia. *Agrícola*, 37:782-789.
- Trachsel S, Dhliwayo T, Gonzalez Perez L, Mendoza Lugo JA, Trachsel M. (2019) Estimation of physiological genomic estimated breeding values (PGEBV) combining full hyperspectral and marker data across environments for grain yield under combined heat and drought stress in tropical maize (*Zea mays* L.). *PLoS ONE* 14(3): e0212200.
- Van Niel, T.G., McVicar, T.R., (2004) Current and potential uses of optical remote sensing in rice-based irrigation systems: a review. *Australian Journal of Agricultural Research*. 55:155–185.
- Vellidis, G. and Beasley, J. (2013) Using vegetation indices to determine peanut maturity. Report to the Georgia Agricultural Commodity Commission for Peanuts. 2013 Research Reports – <http://www.gapeanuts.com>. Last accessed: 02 march 2019.
- Williams, E.J. and Drexler, J.S. (1981) A non-destructive method for determining peanut pod maturity. *Peanut Science*. 8:134-141.
- Wu, C., Niu, Z., Tang, Q. Huang, W. (2008) Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation, *Agricultural Forest Meteorology*, 148, 8-9, 1230-1241,

Yu, N., Li, L. N., Schmitz, L.F. Tian, Greenberg, J.A., Diers, B.W. (2016). Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sensing of Environment*, 187, pp. 91-101.

Supplementary Documents:



Doc 1. Peanut Profile Board used for rating peanut maturity (left) and with a sample of pressure-washed peanuts with exposed mesocarp (right).

Capítulo 4: É possível prever a maturação de amendoim utilizando imagem de satélite?

Resumo

Um dos principais problemas no processo produtivo da cultura do amendoim é a identificação da maturação, a qual é realizada por um método destrutivo e que apresenta alto grau de subjetividade. Visando apontar soluções para redução desse problema, verificou-se a possibilidade de estimar a maturação das vagens de amendoim utilizando o sensoriamento remoto orbital como método não destrutivo alternativo. Foram adquiridas imagens de satélite de alta resolução (~3m) provenientes da plataforma PlanetScope de uma área comercial de amendoim no estado de São Paulo, Brasil, durante o estágio reprodutivo da cultura (92, 107, 113, 117 dias após a semeadura - DAS). A área foi dividida em 54 parcelas de 900 m² cada (30 x 30 m). As imagens foram selecionadas após a coleta de plantas no campo para verificar a maturação utilizando o método Hull Scrape. As imagens passaram pelo processo de correção atmosférica e, em seguida, extraiu-se a reflectância em cada banda (red, green e NIR). A banda do NIR e todos os índices de vegetação (IV) tiveram correlação de Pearson ($p < 0,001$) em todas as datas analisadas, exceto aos 117 DAS. Os IVs que apresentaram melhor acurácia foram o NDVI e o SR aos 117 DAS. Os resultados indicaram que é possível utilizar imagens de satélite de alta resolução na predição da maturação de amendoim e que quando as plantas apresentam aumento na maturação os IVs tendem a diminuir, bem como a reflectância no NIR.

Palavras-chaves: PlanetScope, sensoriamento remoto, índice de vegetação, colheita de amendoim.

Can peanut maturation be predicted using satellite imagery?

Abstract

One of the main problems in the production process of the peanut crop is the prediction of maturity, which is performed by a destructive method and presents a high subjectivity. To point out solutions to reduce this problem, we verified if it is possible to estimate the maturity of peanut pods using an alternative non-destructive method as orbital remote sensing. High-resolution satellite images (~ 3m) were obtained from the PlanetScope platform of a commercial peanut area in the state of São Paulo, Brazil, during the reproductive stage of the peanut crop (92, 107, 113, 117 days after sowing - DAS). The area was divided into 54 plots of 900 m² each (30 x 30 m). The images were selected after the collection of plants in the field to verify maturity using the Hull Scrape method. The images went through the atmospheric correction process and then the reflectance was extracted in each band (red, green and NIR). The NIR band and all vegetation indices (IV) had a Pearson correlation ($p < 0.001$) in all the analyzed dates, except 117 DAS. The IVs that presented the best accuracy was NDVI and SR at 117 DAS. The results indicated that it is possible to use high-resolution satellite images for the prediction of peanut maturity. Also, when plants showed an increase in maturation the IVs tended to decrease as well as the reflectance in the NIR.

Keywords: PlanetScope, Remote sensing, Vegetation index, peanut crop.

Introdução

A produção de amendoim no Brasil está concentrada em 90% no estado de São Paulo, sendo que boa parte das áreas destinadas ao cultivo da cultura são provenientes de áreas de reforma de canavial (Conab, 2019), tornando a janela de cultivo de amendoim dependente de cultivares de ciclos curtos, o que exige que os produtores tenham agilidade na execução das operações agrícolas.

Por ser uma cultura de ciclo indeterminado, as plantas de amendoim apresentam diferentes estádios de maturação em uma mesma planta (Boote, 1991), o que reduz a precisão no gerenciamento da colheita, uma vez que vagens com elevado grau de maturação podem aumentar as perdas na colheita (Santos et al., 2018) e baixa maturação reduz a qualidade do produto (Sanders et al., 1982). A maturação é normalmente estimada utilizando o método destrutivo denominado Hull-Scrape (Williams e Drexler, 1981), que é considerado subjetivo e trabalhoso (Carley et al., 2008; Rowland et al., 2006; Colvin et al., 2014).

A utilização de métodos que sejam não destrutivos para predizer a maturação pode aumentar consideravelmente a eficácia no gerenciamento da colheita de amendoim, principalmente quando se tem uma janela de cultivo curta e pouca mão de obra para realizar o método de estimativa da maturação desenvolvido por Williams e Drexler (1981). Dentre as alternativas que estão disponíveis, o uso de tecnologias como o sensoriamento remoto aéreo orbital, podem contribuir para reduzir a subjetividade do método e mostrar a variabilidade existente dentro de uma mesma área, de uma forma não-destrutiva.

Anteriormente, o uso de imagens de satélites não fornecia boa resolução espacial e, portanto, o sensoriamento remoto orbital não era utilizado em larga escala

para monitorar áreas de produção agrícolas (Atzberger 2013). Contudo, com o advento da Agricultura de Precisão, satélites de alta resolução estão ganhando espaço no cenário agrícola, permitindo o monitoramento das lavouras diariamente (Houborg et al., 2016; Mulla, 2013). Diversas plataformas, como a PlanetScope, utilizam nano satélites, os quais entregam imagens com resolução que podem variar de 3 a 5 m, com tempo de revisitação de até duas vezes por dia (Planet team, 2019; Poursanidis et al., 2019).

A utilização de imagem de satélite na agricultura possui diversas finalidades, como a previsão da data de semeadura (Sadeh et al., 2019), potencial hídrico de lavouras comerciais de uva (Helman et al., 2018), previsão de produtividade de batata (Al-Gaadi et al., 2016) e estimativa de área foliar e conteúdo de clorofila (Clevers et al., 2017). Entretanto, apesar de as imagens de satélites estarem sendo utilizadas para prever diversos parâmetros agronômicos de forma não-destrutiva, no Brasil, ainda não existem relatos da utilização das técnicas de sensoriamento remoto na predição da maturação de amendoim.

Dessa forma, acreditando que é possível obter boas respostas para estimar a maturação de amendoim, utilizando imagens de satélite de alta precisão, foi realizado o presente trabalho visando verificar se é possível de se obter a predição da variabilidade da maturação e qual índice de vegetação que possui melhor correlação com a maturação das vagens de amendoim, bem como para apontar qual é a melhor época para se realizar a predição, utilizando o método não destrutivo por meio do sensoriamento remoto orbital.

Material e métodos

Área de estudo

O experimento foi conduzido em 5 ha de uma área comercial de produção de amendoim, não irrigado, localizada no distrito de Luzitânia, Jaboticabal, São Paulo, Brasil, sob as coordenadas geográficas 21°08'11"S 48°15'09"W (WGS84). A área experimental possui altitude e declividade média de 540 m e 2,5%, respectivamente, com clima Aw segundo classificação de Koppen (Peel, 2013) e solo de textura franco-argilosa (EMBRAPA, 2013).

A semeadura do amendoim, cultivar IAC OL3 (grupo runner), de ciclo curto (aproximadamente 120 dias após a semeadura - DAS), foi realizada após a colheita da cana-de-açúcar. O espaçamento de semeadura adotado foi de 0,90 m entre linhas.

Imagens de satélite

As imagens utilizadas foram obtidas a partir de dados de Satélite da plataforma PlanetScope CubeSat, que são caracterizados como 3U CubeSats (10 x 10 x 30 cm) com massa de aproximadamente 4 kg. O PlanetScope é uma constelação de satélites que compreende diferentes tipos de satélites de alta resolução. Atualmente o PlanetScope possui 148 satélites em órbita solar, os quais possuem capacidade de coletar imagens diariamente em qualquer lugar do globo terrestre com resolução de 3-5 m (Planet Team, 2019). Os satélites da PlanetScope possuem quatro bandas espectrais, sendo uma no infravermelho próximo, NIR (780-860 nm) e três no visível, Blue (455-515 nm), Green (500-590), Red (590-670 nm).

Neste trabalho foram utilizadas quatro imagens do satélite PlanetScope todas adquiridas no estágio reprodutivo da cultura do amendoim. As características de cada imagem são mostradas na Tabela 1.

Tabela 1. Características das imagens do satélite PlanetScope em diferentes datas.

Datas	DAS ⁽¹⁾	Horário (UTC)	Elevação solar	Azimute solar	Resolução (m)
27/01/2018	92	12:47	52,7°	93°	3,9
11/02/2018	107	12:47	51,4°	86°	4,0
17/02/2018	113	12:48	50,9°	82,7°	4,0
23/02/2018	117	12:48	50,4°	79,4°	4,0

⁽¹⁾ Dias após a semeadura.

Apesar de as imagens do PlanetScope passarem por uma série de sensores e calibrações radiométricas básicas, envolvendo correções para distorções do sensor e ajustes para variações do ângulo do sol, realizou-se a correção para o topo da atmosfera (TOA). A correção foi realizada utilizando o código disponível em linguagem em Python. A descrição dos processos realizados para extração e correção da imagem e obtenção da reflectância e dos índices de vegetação são apresentados na Figura 1.




Figura 1. Esquema representativo dos passos adotados para correção da imagem e extração da reflectância em cada banda espectral e obtenção dos índices de vegetação.

Cinco IVs usados por outros trabalhos foram selecionados para avaliação da maturação de amendoim (Tabela 1).

Tabela 1. Índices de vegetação (IV) utilizados para predizer a maturação de amendoim.

IV*	Equação	Referência
NDVI	$(\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})$	Rouse et al. (1974)
GNDVI	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson et al. (1996)
NLI	$(\text{NIR}^2 - \text{RED}) / (\text{NIR}^2 + \text{RED})$	Goel and Qin, (1994)
MNLI	$(\text{NIR}^2 - \text{RED})(1 + L) / (\text{NIR}^2 + \text{RED} + L)^{**}$	Gong et al. (2003)
SR	NIR / RED	Jordan (1969)

*NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; NLI: non-linear index; MNLI: modified non-linear index; SR: simple ration; NIR: infravermelho próximo; RED: vermelho; Green: verde; **L = 0.5

Análise da maturação

Foram utilizadas 54 parcelas ao longo de quatro datas amostrais, distanciadas entre si de 30 m. Dessa forma, cada parcela tinha uma área de 900 m². No centro de cada parcela foram coletadas 8 plantas, que foram levadas para o Laboratório de Máquinas e Mecanização Agrícola (LAMMA) da UNESP/FCAV.

De cada planta, foram retiradas todas as vagens de amendoim até atingir cerca de 200 vagens por ponto amostral. Em seguida, as vagens de amendoim passaram pelo processo de remoção do exocarpo, utilizando um jato de água sob pressão, de modo a expor o mesocarpo. As vagens foram colocadas no quadro de maturação e cada classe de cor foi registrada (Williams e Drexler, 1981). A porcentagem de vagens maduras foi obtida utilizando o método *Peanut Maturity Index* (PMI), que foi calculado para cada amostra de acordo com Rowland et al. (2006).

O PMI leva em consideração a somatória de todas as vagens que forem classificadas nas classes marrom e preta dividido pelo número total de vagens. Os

valores podem variar de 0 até 1, sendo que o PMI indicado para início da colheita é de 0,7-0,75.

Análise dos dados

Os dados foram analisados individualmente, em cada data amostral, por meio da correlação de Pearson ($p < 0,05$ e $0,001$) para verificar qual é a época em que os IVs e bandas espectrais possuem maior correlação com a maturação. Além disso, realizou-se a análise conjunta da correlação de Pearson de todos os dados.

A acurácia geral dos modelos obtidos por meio de regressão linear para os IVs foi avaliada por meio da raiz do erro médio quadrático (RMSE), enquanto que a precisão foi avaliada por meio do coeficiente de determinação (R^2), sendo que valores menores RMSE e maiores de R^2 indicam que um IV tem alta acurácia e precisão, respectivamente, na estimativa da maturidade do amendoim. O RMSE foi calculado utilizando-se a Eq. 1:

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (P_i - O_i)^2} \quad (Eq. 1)$$

Em que, P_i e O_i são os valores previstos e observados, respectivamente, e n é o número de amostras.

Resultados

As bandas espectrais red e green não apresentaram correlação de Pearson com a maturação de amendoim aos 92, 107 e 117 DAS (Tabela 2). Entretanto, aos 113 dias, essas bandas espectrais apresentaram correlação negativa com a maturação ($p < 0,05$). De modo contrário, a banda do NIR apresentou correlação

positiva com a maturação das vagens de amendoim aos 92, 107 e 113 DAS ($p < 0,001$), exceto aos 117 DAS.

Ao analisar a correlação de Pearson levando em consideração todos os dados, verificou-se que todas as bandas espectrais utilizadas possuem correlação negativa com a maturação ($p < 0,001$), sendo a banda do red e green com maiores valores, ou seja, na medida que a maturação aumenta, a reflectância diminui. Esses resultados sugerem que índices de vegetação (IV) que utilizam a banda do NIR têm maior correlação com a maturação de amendoim, com alto potencial de previsão da maturação das vagens (cultivar OL3), principalmente quando o NIR for combinado com as demais bandas espectrais aos 113 DAS, data em que todas as bandas espectrais apresentaram correlação com a maturação.

Quanto aos IVs encontrados nas avaliações em cada data, verificou-se que todos eles apresentaram correlação positiva com a maturação ($p < 0,001$), exceto aos 117 DAS, quando todos os IVs foram não significativos (Tabela 2). Esses resultados, aliados aos maiores valores de correlação dos IVs (NDVI, GNDVI, SR NLI e MNLI) encontrados aos 113 DAS, reforçam a hipótese de que esta é a melhor data para prever a maturação de amendoim, cultivar OL3, utilizando imagens de satélite PlanetScope (3m).

Tabela 2 Coeficiente de correlação de Pearson (r) entre os índices de vegetação (IVs) e a maturação de amendoim aos 92, 107, 113 e 117 dias após a semeadura - DAS (n=54).

IV	92	107	113	117	Geral (n=216)
----- DAS-----					
Red	-0,073 ^{NS}	-0,205 ^{NS}	-0,287*	-0,040 ^{NS}	-0,885**
Green	-0,193 ^{NS}	-0,186 ^{NS}	-0,355*	-0,065 ^{NS}	-0,802**
NIR	0,591**	0,433**	0,617**	-0,204 ^{NS}	-0,691**
NDVI	0,580**	0,432**	0,619**	0,202 ^{NS}	-0,814**
GNDVI	0,589**	0,451**	0,614**	0,199 ^{NS}	-0,742**
SR	0,577**	0,425**	0,614**	0,187 ^{NS}	-0,811**
NLI	0,592**	0,436**	0,624**	0,211 ^{NS}	-0,773**
MNLI	0,591**	0,431**	0,619**	0,200 ^{NS}	-0,748**

**Significativo a $p < 0,001$ e * Significativo a $p < 0,05$ ^{NS} não significativo.

NDVI: normalized difference vegetation index; GNDVI: green normalized difference vegetation index; NLI: non-linear index; MNLI: modified non-linear index; SR: simple ration; NIR: infravermelho próximo; RED: vermelho; Green: verde; **L = 0.5

Na análise conjunta dos dados (n=216), todos os IV apresentaram forte correlação com a maturação ($>0,7$), contudo, os que apresentaram maior correlação foram o NDVI e o SR, com correlação negativa com coeficientes de -0,814 e -0,811, respectivamente (Tabela 2). O maior valor de correlação do SR é consequência da maior correlação do NIR com a maturação na maioria das épocas avaliadas, uma vez que esse IV é a razão simples do NIR/RED (Jordan, 1969).

Quando se compara o índice de maturação (PMI) com a reflectância das bandas no visível (red e green) por meio de regressão linear (Figura 2 A e B, respectivamente), constata-se que o comportamento das bandas foi similar, pois ambas tendem a aumentar a reflectância à medida que as plantas permanecem no campo, fato este que, consequentemente, aumenta os valores de PMI. As equações

encontradas explicam 78% e 64% dos dados observados, para as bandas do red e do green, respectivamente.

Outra importante observação pode ser notada no comportamento da banda do red, em que, quando as plantas apresentavam valores de 0,30 até 0,45 para o PMI, a reflectância na banda do red não registrou alteração expressiva entre os 107 a 113 DAS, entretanto, quando as vagens estavam com PMI próximo do recomendado para início da colheita (0,70), a reflectância em ambas bandas do visível aumentou de forma considerável, porém, houve correlação somente aos 113 DAS para a faixa do visível. De modo contrário, a reflectância na banda do NIR diminuiu com o aumento do PMI.

Os resultados de reflectância aos 92 DAS (PMI até 0,15) nas bandas do visível e do NIR (Figura 2 A, B e C, respectivamente) apresentaram comportamento inverso, o que demonstra que as plantas de amendoim estavam com boa qualidade de cobertura foliar (maiores valores de NIR), respondendo à absorção de luz para produção de fotoassimilados para o processo de formação das vagens e enchimento de grãos nesse período (baixos valores nas bandas do visível). Além disso, observa-se que, quando as plantas apresentaram PMI maiores que 0,70 (117 DAS), os comportamentos dessas bandas espectrais também tiveram comportamento inverso.




Figura 2. Correlação ao longo das quatro últimas semanas antes da colheita entre a reflectância e o índice de maturação (PMI) nas bandas do Red (A), Green (B) e NIR (C).

Quanto aos IVs, todos apresentaram redução nos valores na medida em que a maturação aumentou (Figura 3) confirmando a forte correlação negativa dos dados. O NDVI e o SR apresentaram comportamentos similares com valores de $R^2=0,66$ e RMSE mais baixos (0,133 e 0,134, respectivamente), quando comparados com os demais IVs. Já o NLI, MNLI e o GNDVI apresentaram valores de RMSE maiores que 0,141.




Figura 3. Correlação ao longo das quatro últimas semanas antes da colheita entre o índice de maturação (PMI) e os índices de vegetação NDVI (A), SR (B), NLI (C), MNLI (D) e GNDVI (E).

Verificou-se que os IVs que apresentaram maior erro (MSE) na estimativa da maturação foram o NLI e o GNDVI aos 107 e 113 DAS (Figura 4), respectivamente. Isso indica que, independente da correlação obtida para esses IVs, eles não se

apresentaram como eficientes na predição da maturação nessas épocas de avaliação, quando comparado com os demais. De modo contrário, todos os modelos de IV utilizados para prever a maturação, a partir de imagens de satélite obtiveram MSE menor que 0,009 aos 92 DAS, exceto o GNDVI (RMSE=0,013).

A acurácia na estimativa da maturação de amendoim aos 107 DAS foi reduzida, quando comparada aos 92 DAS para todos os IVs. Entretanto, os IVs MNLI, NLI, NDVI e SR melhoraram a acurácia na predição da maturação aos 117 DAS, com valores de MSE variando de 0,0250 até 0,0268 (Figura 3), contudo, a correlação de Pearson entre os IVs e a maturação nessa data foi não significativa.




Figura 4. Erro médio quadrático (RMSE) aos 92, 107, 113 e 117 DAS para os índices de vegetação na predição do índice de maturação na cultura do amendoim.

Discussão

A baixa variação na reflectância da banda do visível possui forte interferência dos processos fisiológicos relacionados à maturação de amendoim, visto que aos 80 DAS, cultivares do grupo runner iniciam o processo de maturação, que pode se estender até aos 119 DAS (Boote, 1952). No presente trabalho, este foi o momento onde houve a inversão nos valores de reflectância entre o red e o NIR, o que indica que, quando as plantas de amendoim apresentam valores de PMI acima de 0,70, a reflectância no NIR tende a aumentar e no red diminuir.

A reflectância no NIR tem sido apontada como a que possui melhor correlação com a maturação das vagens de amendoim (Robson et al., 2004). Rowland et al. (2008) encontraram forte correlação entre a reflectância e a maturação do amendoim (Georgia Green, grupo Runner) na faixa espectral de 830-850 nm. Carley et al. (2008) também encontraram correlação da maturação para uma cultivar de amendoim (VA 98R, grupo Virginia) na faixa espectral do NIR (800-1049nm). Porém, estes autores não encontram correlação para a cultivar (NC-V 11, grupo Virginia), o que sugere que cada cultivar apresenta resposta espectral diferente. Dessa forma, como no nosso trabalho utilizou-se somente a cultivar IAC OL3 (grupo Runner), tornam-se necessários experimentos com outras cultivares utilizadas pelos produtores brasileiros, de modo a identificar qual IV que possa melhor predizer a maturação do amendoim.

Com os resultados obtidos com os IVs por meio de imagens de satélite, acredita-se que seja possível de se criar um modelo não supervisionado para predizer a maturação utilizando os índices de vegetação, uma vez que as imagens do PlanetScope são adquiridas diariamente e quase no mesmo horário. Entretanto, problemas relacionados com a qualidade das imagens, tais como ocorrência de

nuvens, podem aumentar o intervalo entre as amostragens e interferir na acurácia do modelo. Monsef et al. (2019) desenvolveram um modelo para prever a maturação de amendoim utilizando imagens de drone. Os autores encontraram que a acurácia foi baixa aos 60 DAS, mas tendeu a aumentar na medida em que as plantas permaneceram no campo (120 DAS). Nesse mesmo sentido, Yu et al. (2016) utilizaram aprendizado de máquina para prever a maturação de soja e encontraram que o modelo desenvolvido obteve 93% de acurácia. No presente trabalho encontrou-se, encontramos alta acurácia ($RMSE \leq 0,130$) e precisão ($R^2 = 0,66$) para o NDVI e SR.

Quanto ao uso do NDVI na predição da maturação de amendoim, os resultados obtidos nesse trabalho são contrários aos encontrados por Carley et al. (2008), os quais não observaram correlação para nenhum dos cultivares de amendoim avaliados. Entretanto, Rowland et al. (2008) encontraram resultados similares aos do presente trabalho, sendo que o NDVI diminuiu na medida em que a maturação aumentou. Essa alta acurácia e forte correlação do NDVI podem ser explicadas pelo fato de que este IV se correlaciona com diversos parâmetros agrônômicos (Eitel, 2008), como: teor de nitrogênio foliar (Amaral et al., 2015), altura da planta e o número de ramos por planta de algodão (Souza et al., 2017), produtividade de trigo (Marti et al., 2007) e milho (Shanahan et al., 2001; Oliveira et al., 2019).

Em relação ao bom comportamento do SR na predição da maturação do amendoim, pode-se explicar pelo fato de os valores encontrados terem se situado na faixa de 4-6, que se situa abaixo da faixa considerada alta (7-10) por Gitelson (2019), faixa esta na qual acontece a redução da sensibilidade dos IVs na presença de moderada a alta quantidade de biomassa.

Conclusão

Os índices de vegetação (IV) extraídos das imagens do satélite PlanetScope obtiveram correlação com a maturação de amendoim, indicando que é possível monitorar a cultura por meio do sensoriamento remoto orbital de alta resolução e reduzir a subjetividade do quadro de maturação.

A melhor acurácia na predição da maturação utilizando imagens de satélites PlanetScope foi aos 92 e 117 DAS.

O NDVI e SR apresentaram alta acurácia e precisão, porém, esses resultados necessitam de mais estudos para confirmar se esses índices de vegetação permanecerão estáveis ao longo do tempo.

Referências bibliográficas

Al-Gaadi KA, Hassaballa AA, Tola E, Kayad AG, Madugundu R, Alblewi B, et al. (2016) Prediction of Potato Crop Yield Using Precision Agriculture Techniques. PLoS ONE 11(9): e0162219.

Amaral LR, Molin JP, Portz G, Finazzi FB, Cortinove L (2015) Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. Precision Agriculture 16(1):15-28.

Atzberger, C. 2013. "Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs." Remote Sensing, 5: 949–981. doi:10.3390/rs5020949.

Boote, K. J. (1982) Growth stages of peanut (*Arachis hypogaea* L.). Peanut Science, vol. 9, no. 1, pp. 35–40, 1982.

Carley, D., Jordan, D., Dharmasri, L., Sutton, T., Brandenburg, R., Burton, M., 2008. Peanut response to planting date and potential of canopy reflectance as an indicator of pod maturity. *Agron. J.* 100 (2), 376–380.

Clevers, J. G. P. W., Kooistra, L., Brande, M.M.M.V (2017) Using Sentinel-2 Data for Retrieving LAI and Leaf and Canopy Chlorophyll Content of a Potato Crop *Remote Sens.* 2017, 9(5), 405;

Colvin, B., Rowland, D., Ferrell, J., Faircloth, W. (2014) Development of a digital analysis system to evaluate peanut maturity. *Peanut Science*, 41(1), 8-16.

Eitel JUH (2008) Combined spectral index to improve ground-based estimates of nitrogen in dryland wheat. *Agronomy Journal* 100(6):1694-1702.

Embrapa Solos. Sistema Brasileiro De Classificação De Solos. Centro Nacional De Pesquisa De Solos: Rio De Janeiro; 2013.

Gitelson, A. A. (2019) Remote estimation of fraction of radiation absorbed by photosynthetically active vegetation: generic algorithm for maize and soybean, *Remote Sensing Letters*, 10:3, 283-291, DOI: 10.1080/2150704X.2018.1547445

Helman, D., Bahat, I., Netzer, Y., Ben-Gal, A., Alchanatis, V., Peeters, A., Cohen, Y. Using Time Series of High-Resolution Planet Satellite Images to Monitor Grapevine Stem Water Potential in Commercial Vineyards *Remote Sens.* 2018, 10(10), 1615.

Houborg, R. McCabe, M, F. High-Resolution NDVI from Planet's Constellation of Earth Observing Nano-Satellites: A New Data Source for Precision Agriculture *Remote Sens.* 2016, 8(9), 768.

Marti, J. J. Bort, G. Slafer, J. Araus Can wheat yield be assessed by early measurements of normalized difference vegetation index? *Ann. Appl. Biol.*, 150 (2007), pp. 253-257.

Monsef H. A., Smith S.E., Rowland D. L., Rasol N. A. E. (2019). Using multispectral imagery to extract a pure spectral canopy signature for predicting peanut maturity. *Computers and Electronics in Agriculture*, 162: 561-572.

Mulla, D. J. 2013. Twenty-Five Years of Remote Sensing in Precision Agriculture: Key Advances and Remaining Knowledge Gaps. *Biosystems Engineering* 114 (4): 358–371. doi: 10.1016/j.biosystemseng.2012.08.009.

Oliveira, M. F., Ormond, A.T. S., de Freitas Noronha, R. H., Santos, A. F., Zerbato, C., Furlani, C. E. A. (2019) Prediction Models of Corn Yield by NDVI in Function of the Spacing Arrangement. *Journal of Agricultural Science*, 11(6).

Peel MC, Finlayson BL, McMahon TA. Updated World Map Of The Köppen-Geiger Climate Classification. *Hydrology and Earth System Sciences Discussions*. European Geosciences Union. 2007; V. 4, N. 2, P.439-473

Planet Team. (2017). Planet — Planet Imagery Products. Retrieved May 25, 2018, from <https://www.planet.com/docs/spec-sheets/sat-imagery/>

Poursanidis, D., Traganos, D., Chrysoulakis, N., Reinartz, P. (2019) Cubesats allow high spatiotemporal estimates of satellite-derived bathymetry, *Remote Sensing* 11(11), 1299.

Robson, A., Phinn, S. Wright, G., Fox, G., 2004. Combining Near Infrared Spectroscopy and Infrared Aerial Imagery for Assessment of Peanut Crop Maturity and Aflatoxin Risk. *New Directions for a Diverse Planet*, Proceedings of the 4th International Crop Science Congress, Brisbane, Australia. p. 16.

Rowland, D.L., R.B. Sorensen, C.L. Butts, and W.H. Faircloth. (2006). Determination of maturity and degree day indices and their success in predicting peanut maturity. *Peanut Science*, 33:125-136.

Sadeh, Y., Zhua, X., Chenub, K., Dunkerleya, D. (2019) Sowing date detection at the field scale using CubeSats remote sensing *Computers and Electronics in Agriculture* 157, 568–580.

Sanders TH, Shubert AM, Pattee HE. 1982. Maturity methodology and postharvest physiology. In: Pattee HE and Young CT, editors. *Peanut science and technology*. Yoakum: American Peanut Research and Education Society, Inc; p. 625–627

Santos, A.F., Silva, R.P., Zerbato, C., Menezes P. C., Kazama, E. H., Paixão C. S. S., Voltarelli, M, A (2018). Use of real-time extend GNSS for planting and inverting peanuts Precision Agric. pp 1–17

Shanahan F., Schepers, S.D., Varvel, F. E., Wilhelm, W., Tringe, S., Schlemmer, R., Major, J. Use of remote sensing imagery to estimate corn grain yield Agron. J., 93 (2001), pp. 583-589.

Souza, H.B., Baio, F.H.R., Neves, D.C. (2017) Using Passive And Active Multispectral Sensors On The Correlation With The Phenological Indices Of Cotton Eng. Agríc., Jaboticabal, V.37, N.4, P.782-789, Jul./Ago. 2017

Williams, E. J. and J. S. Drexler, “A non-destructive method for determining peanut pod maturity,” Peanut Science, vol. 8, no. 2, pp. 134–141, 1981.

Yu, N., Li, L. N., Schmitz, L.F. Tian, Greenberg, J.A., Diers, B.W. (2016). Development of methods to improve soybean yield estimation and predict plant maturity with an unmanned aerial vehicle based platform. *Remote Sensing of Environment*, 187, pp. 91-101.

Capítulo 5: Considerações finais

A avaliação da maturação da cultura do amendoim é um processo de difícil execução, com grande demanda de tempo e mão de obra, sendo altamente subjetivo. Desta forma, o uso de plataformas de sensoriamento remoto aéreo pode vir a ser uma boa alternativa para facilitar este processo e, conseqüentemente, possibilitar a indicação do momento ideal para realização da colheita, visando a redução das perdas.

A colheita realizada com a maturação adequada permite que se obtenham menores perdas, uma vez que o ginóforo, nesta condição, tem menor resistência ao rompimento. Assim, torna-se fundamental a determinação da maturação das áreas produtoras de amendoim para aprimorar o gerenciamento da colheita mecanizada.

Neste trabalho, o uso do sensoriamento remoto aéreo apresentou alto potencial no monitoramento e predição da maturação das vagens de amendoim, indicando que é possível a produtores, cooperativas e a área acadêmica reduzirem a subjetividade do método Hull-scrape utilizando ferramentas como o sensoriamento remoto.

Verificou-se também que as plantas de amendoim apresentam variação na reflectância após os 90 dias, independentemente do método de cultivo e da plataforma que foi utilizada para coletar as imagens (drone ou satélites). As cartas de controle mostraram ser eficientes para detectar a variabilidade com potencial para auxiliar os analistas na tomada de decisão, além disso, os dados de drone e satélites apresentaram qualidade similar na predição da maturação das vagens de amendoim.

Os índices de vegetação obtidos por meio de drones carecem de mais estudos para identificar qual é o melhor IV e quando é momento mais adequado para se fazer a predição da maturação das vagens de amendoim, uma vez que os resultados encontrados nesse trabalho foram diferentes para área irrigada e não irrigada. Entretanto, mesmo com a divergência no comportamento temporal dos índices de vegetação nas áreas avaliadas, encontrou-se que índices de vegetação que combinam as bandas do NIR e do red edge demonstraram melhor estabilidade para monitorar a variabilidade e prever a maturação.

Quanto à utilização de imagens de satélites de alta precisão, no monitoramento da maturação de amendoim, como o PlanetScope, verificou-se que com a resolução espacial fornecida pelo satélite, é possível fazer a previsão da maturação aos 92 DAS, com alta acurácia, bem como aos 117 DAS. Recomenda-se que sejam realizados outros trabalhos para averiguar a capacidade de predição da maturação do amendoim, utilizando-se outras plataformas livres, com menor resolução, tais como Landsat e Sentinel.

Os resultados no presente trabalho podem ser considerados promissores para a produção de amendoim brasileira, que apresenta janela de produção reduzida, quando comparada com outras culturas. O monitoramento da variabilidade espacial e temporal da maturação das vagens, usando sensoriamento remoto aéreo pode maximizar a eficácia na determinação da maturação e, conseqüentemente, do momento de início da colheita.

Outros trabalhos devem ser realizados, no Brasil e nos EUA, para verificar se o método não destrutivo, por meio do sensoriamento remoto aéreo, pode ser utilizado em diferentes cultivares. Além disso, acredita-se que, com o sensoriamento remoto aéreo é possível estimar a produtividade de amendoim.

Dessa forma, os próximos passos desta pesquisa serão a verificação do comportamento dos índices de vegetação em diferentes cultivares e condições de cultivo, na estimativa da maturação das vagens e da produtividade do amendoim, bem como desenvolver um modelo de classificação não supervisionado que seja capaz de prever a maturação do amendoim com base em imagens.