

# Inovação e desenvolvimento tecnológico na fertilização de lavouras

Jayme Garcia Arnal Barbedo

## Introdução

O diagnóstico confiável do estado nutricional de lavouras é parte essencial da gestão de uma fazenda, uma vez que tanto o excesso quanto a falta de nutrientes podem causar danos severos e perda de produção. Atualmente, a maneira mais comum de determinar o estado nutricional é de forma visual, por meio de gabaritos de cor que não permitem avaliações quantitativamente rigorosas (Graeff et al., 2008). Avaliações mais acuradas requerem análises laboratoriais, as quais podem ser demoradas e dependem da aplicação de métodos específicos para interpretação correta dos dados (Cunha et al., 2016; Dezordi et al., 2016). Algumas alternativas indiretas estão disponíveis para alguns nutrientes, como o medidor de clorofila SPAD para predições de nitrogênio (Balasubramaniam; Ananthi, 2016), mas esse pode ser também um processo demorado (Jia et al., 2004), e as estimativas nem sempre são confiáveis (Uddling et al., 2007; Mercado-Luna et al., 2010; Nauš et al., 2010). Por esse motivo, considerável esforço tem sido dedicado ao desenvolvimento de novos métodos para detecção e estimação de problemas nutricionais em plantas (Muñoz-Huerta et al., 2013; Ali et al., 2017).

A detecção e a classificação automática de distúrbios em plantas tem recebido atenção considerável nas duas últimas décadas (Barbedo, 2013). Muitos tipos de tecnologias têm sido usados para coletar informações necessárias para automação, incluindo espectroscopia de impedância elétrica (Jinyang et al., 2016), espec-

troscopia de refletância (Elvanidi et al., 2018), microespectroscopia de infravermelho (Butler et al., 2017) e espectroscopia de fluorescência de clorofila (Schmidt et al., 2013). Imagens digitais, as quais sempre estiveram entre as principais fontes de dados, vêm se tornando a abordagem dominante à medida que técnicas de aprendizado profundo se tornam mais disseminadas (Barbedo 2018a, 2018b; Singh et al., 2018).

Grande parte das técnicas para detecção de problemas nutricionais em plantas empregam imagens capturadas por satélites (Sims et al., 2013; Huang et al., 2015), aviões (Cilia et al., 2014; Quemada et al., 2014) ou veículos aéreos não tripulados (Vants) (Li et al., 2015; Severtson et al., 2016). Porém, em anos recentes novas técnicas que fazem uso de imagens proximais vêm sendo desenvolvidas e, com o rápido desenvolvimento de veículos robóticos (Hiremath et al., 2014; Bonadies et al., 2016; Shafiekhani et al., 2017), tais técnicas podem ter um papel importante no contexto da agricultura de precisão.

Diferentes tipos de imagens têm sido aplicadas ao monitoramento do estado nutricional, incluindo fluorescência da clorofila, termais, multiespectrais e hiperspectrais. A fluorescência da clorofila é particularmente útil na análise do nitrogênio, uma vez que a concentração de clorofila tem uma relação próxima com esse nutriente (Gorbe; Calatayud, 2012). Imagens termais são úteis para a análise da atividade estomática e de vários parâmetros fisiológicos que podem ter relação com o estado nutricional da planta (Costa et al., 2013). Imagens multiespectrais

fornecem a refletância associada a algumas bandas espectrais relevantes (vermelho, verde, azul, infravermelho próximo), as quais são capazes de fornecer pistas importantes sobre o estado nutricional da planta (Borhan et al., 2017). Imagens hiperspectrais extraem informação com uma alta resolução espectral e fornecem detalhes sobre o perfil espectral da planta, revelando diferenças entre plantas saudáveis e submetidas a algum tipo de estresse (Yu et al., 2014). Apesar de as imagens citadas anteriormente poderem fornecer mais informações do que imagens vermelho-verde-azul convencionais (Bock et al., 2010), estas são usadas mais frequentemente devido ao baixo custo, à portabilidade e à disponibilidade das respectivas câmeras. Considerando que técnicas de aprendizado profundo em geral requerem maiores quantidades de dados para treinamento, essas vantagens se tornam mais proeminentes e frequentemente superam eventuais ganhos obtidos a partir de outras bandas espectrais, além do espectro visível.

Na detecção automática de deficiências nutricionais, o objetivo é identificar sinais visuais que caracterizam o problema de interesse. Nesse contexto, três problemas podem ser atacados (Barbedo, 2013):

- a) Classificação, no qual o objetivo é identificar corretamente a origem de um sintoma.
- b) Detecção, a qual visa indicar a presença da deficiência alvo pela detecção de seus sinais ou sintomas.
- c) Quantificação, a qual visa estimar a severidade da deficiência alvo.

Todos os três problemas já foram extensivamente estudados no caso de doenças, porém, no caso de deficiências nutricionais, apenas alguns poucos estudos se dedicaram ao problema de classificação (Chen et al., 2014; Asraf et al., 2017; Culman et al., 2017; Ghosal et al., 2018). O problema de classificação não tem

despertado muita atenção porque há apenas algumas poucas deficiências nutricionais relevantes do ponto de vista econômico, sendo nitrogênio o mais importante. Assim, normalmente o objetivo de detectar e quantificar uma dessas deficiências relevantes, bem como sintomas e sinais que aparentemente não estão associados a essas desordens são simplesmente ignorados. Há alguns problemas associados com essa abordagem “não sistêmica”, uma vez que sinais de deficiências nutricionais raramente aparecem isoladamente em ambientes não controlados.

A maior parte dos estudos encontrados na literatura usa as imagens para extrair índices de vegetação, os quais são então relacionados ao conteúdo nutricional usando algum modelo de regressão (normalmente linear). Apesar de menos comum, outros tipos de variáveis vêm sendo usadas como entradas para os modelos, tais como a média do espectro de refletância (Capolupo et al., 2015), bandas espectrais selecionadas (Severtson et al., 2016; Liu et al., 2018; Zhu et al., 2018), atributos de cor (Schirrmann et al., 2016; Yakushev; Kanash, 2016) e componentes principais (Wen et al., 2018). Grande parte dessas variáveis é extraída a partir de imagens multiespectrais e hiperspectrais, com exceção dos atributos de cor, os quais são extraídos de imagens RGB. No caso específico do nitrogênio, o estado nutricional frequentemente é estimado indiretamente a partir de outras variáveis, especialmente o conteúdo de clorofila e o índice de área foliar.

A organização de imagens de alta resolução em bancos de dados geoespaciais é um tópico relevante, porém foge ao escopo deste capítulo. Mais informações sobre o assunto podem ser encontradas em diversos artigos na literatura (Bordogna et al., 2016; Karmas et al., 2016; Kamilaris et al., 2018).

Este capítulo tem como objetivo apresentar algumas técnicas para o monitoramento do

estado nutricional das plantas e para a detecção de deficiências passíveis de correção. A ênfase é dada a técnicas baseadas em imagens digitais e aprendizado de máquina, as quais têm mostrado o maior potencial para uso em tecnologias que possam ser usadas efetivamente no campo. Embora a literatura não contenha muitas tecnologias e métodos que tenham sido testados em lavouras de cana-de-açúcar, esses normalmente podem ser adaptados a diferentes tipos de culturas agrícolas. Este capítulo considera tanto técnicas que fazem uso de imagens proximais, as quais normalmente são capturadas usando câmeras convencionais, quanto imagens capturadas remotamente usando veículos aéreos não tripulados (Vants), aeronaves tripuladas e satélites.

A maioria das técnicas apresentadas neste capítulo não foi testada em lavouras de cana-de-açúcar, porém todas elas são, em princípio, extensíveis para outras culturas agrícolas além daquelas para as quais elas foram testadas.

## Técnicas baseadas em imagens de satélite

Satélites são capazes de cobrir grandes áreas rapidamente, e muitos deles permitem que imagens sejam obtidas com alta resolução temporal (Huang et al., 2015). A Figura 14.1 apresenta

um exemplo de imagem obtida por satélite. Novas constelações de satélite estão sendo lançadas, e muitas oferecem resoluções espaciais melhores que 1 m e imageamentos diários de suas áreas de cobertura. Essa opção não requer infraestrutura e logística sofisticadas por parte do produtor, porém a obtenção de imagens de boa qualidade pode ser difícil em áreas muito susceptíveis à cobertura de nuvens, que muitas vezes exigem o uso conjunto de dados obtidos com radar de abertura sintética (em inglês *Synthetic Aperture Radar – SAR*) (Huang et al., 2015). Além disso, mesmo as imagens com resoluções espaciais mais elevadas ainda não permitem que plantas sejam tratadas individualmente, fazendo com que problemas nutricionais só possam ser detectados para áreas relativamente grandes.

Conforme pode ser observado na Tabela 14.1, um grande número de satélites tem sido usado em pesquisas relacionadas à nutrição vegetal, e com novos satélites de alta resolução sendo lançados com frequência, essa diversidade tende a aumentar. A maioria dos satélites carrega sensores do tipo multiespectral, em que as bandas do vermelho (R), verde (G), azul (B), infravermelho próximo (NIR) e red edge (RE) são capturadas separadamente. Alguns satélites carregam sensores hiperespectrais, em que um grande número de bandas estreitas é capturado para

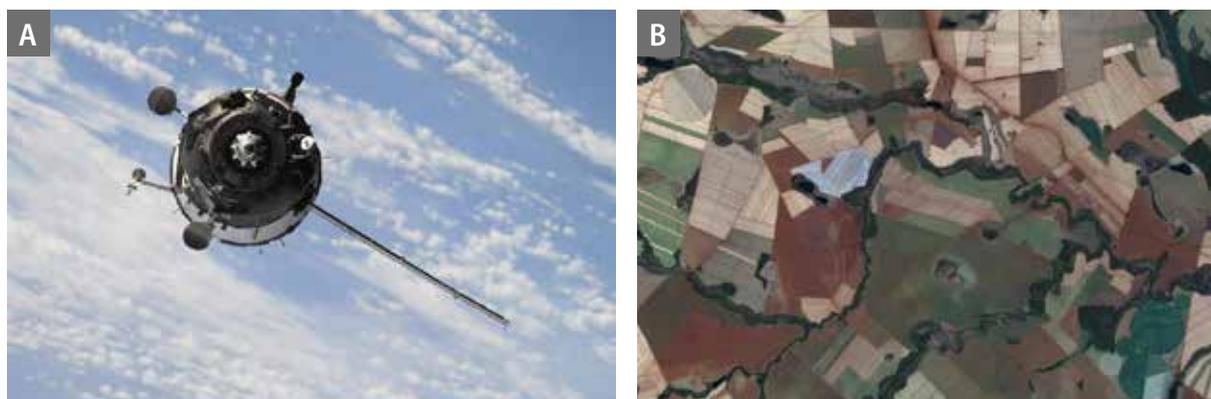


Figura 14.1. Satélite (A) e imagem obtida por satélite (B).

**Tabela 14.1.** Técnicas para detecção de problemas nutricionais por meio do uso de imagens de satélite.

Trabalho	Satélite	Banda	Nutriente	Cultura agrícola testada	Classificação/Regressão
Amirruddin et al. (2018)	SPOT-6	Multiespectral	Nitrogênio	Palma de óleo	Regressão linear múltipla
Amirruddin e Muharam (2018)	SPOT-6	Multiespectral	Nitrogênio	Palma de óleo	Máquinas de vetores suporte
Bausch e Khosla (2010)	QuickBird	Multiespectral	Nitrogênio	Milho	Regressão linear
Benincasa et al. (2018)	GeoEye-1 e WorldView-2	Multiespectral	Nitrogênio	Trigo	Regressão linear
Caturegli et al. (2015)	GeoEye-1	Multiespectral	Nitrogênio	Gramma	Regressão linear
Cohen et al. (2010)	VEN $\mu$ S	Multiespectral	Nitrogênio	Batata	Regressão por mínimos quadrados parciais
Huang et al. (2015)	Formosat-2	Multiespectral	Nitrogênio	Arroz	Regressão linear
Jia et al. (2012)	Ikonos	Multiespectral	Nitrogênio	Trigo	Regressão linear e não linear
Nutini et al. (2018)	RapidEye	Multiespectral	Nitrogênio	Arroz	Regressão linear
Shou et al. (2017)	QuickBird	Multiespectral	Nitrogênio	Trigo	Regressão linear
Sims et al. (2013)	EO-1/Hyperion	Hiperespectral	Nitrogênio, fósforo, boro	Floresta	Regressão linear
Wu et al. (2007)	QuickBird	Multiespectral	Nitrogênio	Batata	Regressão linear e não linear

fornecer um perfil espectral detalhado da área imageada. Os trabalhos que utilizam satélites têm se concentrado quase exclusivamente no nitrogênio, provavelmente por esse nutriente ser o mais relevante economicamente e também pelo fato de seus efeitos poderem ser mais facilmente detectados (variação de clorofila). O trigo é a cultura que mais vem recebendo atenção, porém outras plantações vêm também sendo exploradas. Com poucas exceções, as imagens obtidas por satélite normalmente são usadas para gerar alguns índices de vegetação, como o índice de vegetação de diferença normalizada (em inglês *Normalized Difference Vegetation Index* – NDVI), proposto por Rouse Junior et al. (1974), os quais em geral são combinados usando algum tipo de regressão.

## Técnicas baseadas em imagens capturadas usando aeronaves tripuladas

Aeronaves tripuladas para obtenção de imagens (Figura 14.2) são, atualmente, a opção menos comum, devido aos altos custos envolvidos, ao risco de acidentes e ao fato de muitas aeronaves não serem apropriadas para a instalação de câmeras (Barbedo; Koenigkan, 2018). Por sua vez, é possível cobrir grandes áreas e, dependendo da altitude de voo, a resolução obtida pode ser muito mais elevada que no caso de satélites (Quemada et al., 2014; Severtson et al., 2016).

Os sensores multiespectrais e hiperespectrais vêm dominando os trabalhos por meio do uso

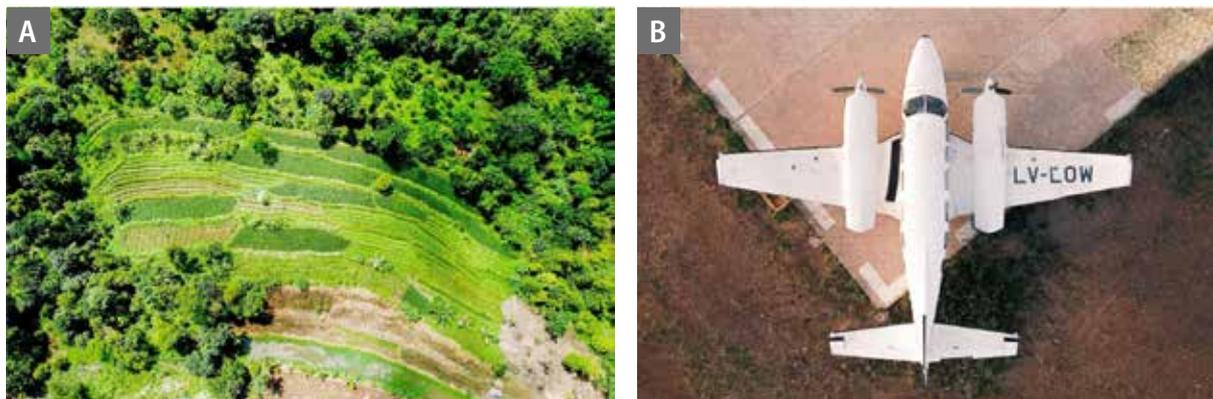


Figura 14.2. Imagem (A) obtida por aeronave tripulada (B) e sensor RGB (vermelho, verde e azul).

de aeronaves, uma vez que esses tipos de sensores tendem a capturar mais minuciosamente as mudanças espectrais causadas por alterações nutricionais (Tabela 14.2). Como no caso de imagens de satélite, o nitrogênio vem sendo o nutriente alvo na grande maioria dos estudos, e o milho é a cultura que vem recebendo a maior atenção. O único trabalho com cana-de-açúcar que se encaixa nessa categoria foi o descrito por Lebourgeois et al. (2012). Como no caso das imagens de satélite, é comum que diferentes índices sejam gerados a partir das imagens capturadas, e que regressão seja utilizada para relacionar tais índices com variáveis indicativas do estado nutricional das plantas. É interessante notar que o número de trabalhos que utilizam aeronaves tripuladas vem diminuindo rapidamente, resultado do crescimento no uso de Vants.

### Técnicas baseadas em imagens capturadas usando drones

A maioria dos Vants é composta por aeronaves leves e de baixo custo, sensores e uma estação de controle em solo (Watts et al., 2012; Anderson; Gaston, 2013). Basicamente, há dois tipos de drones que podem ser utilizados em aplicações agrícolas:

- d) Drones rotativos, os quais são bastante portáteis, mas são mais vulneráveis a condições climáticas adversas e têm capacidade de carga e cobertura limitadas (Agüera et al., 2011).
- e) Drones de asa fixa, os quais tendem a ser mais rápidos, estáveis e com mais capacidade de carga, mas são frequentemente menos portáteis e mais caros (Barbedo; Koenigkan, 2018).

Uma das maiores vantagens dos Vants é o fato de possuírem uma ampla variedade de configurações e capacidades (Hogan et al., 2017), de modo que as necessidades associadas a qualquer aplicação provavelmente são atendidas por algum equipamento. Apesar de fatores extrínsecos como custos envolvidos, necessidade de treinamento, regulações estritas e riscos de quedas ainda desencorajarem o uso de Vants em muitos casos (Watts et al., 2012), os preços continuam a cair e muitas barreiras regulatórias estão sendo removidas, de modo que os níveis de adoção devem continuar a crescer (Hogan et al., 2017).

Os Vants possuem diversas vantagens em relação aos satélites, como resolução espacial mais elevada, resolução espectral adaptável (no caso de sensores multi e hiperespectrais) e flexibilidade de coleta das imagens, permitindo que os

**Tabela 14.2.** Técnicas para detecção de problemas nutricionais por meio do uso de imagens de aeronaves.

Trabalho	Tipo de aeronave	Tipo de imagem	Nutriente	Cultura agrícola testada	Índice de acerto
Blackmer e Schepers (1996)	Avião	RGB <sup>(1)</sup>	Nitrogênio	Milho	Regressão linear
Cilia et al. (2014)	Avião	Hiperespectral	Nitrogênio	Milho	Diferentes regressões
Flowers et al. (2003)	Avião	Multiespectral	Nitrogênio	Trigo	Regressão linear e quadrática
Gabriel et al. (2017)	Avião	Multiespectral e hiperespectral	Nitrogênio	Milho	Relações polinomiais
Gautam et al. (2006)	Avião	Multiespectral	Nitrogênio	Milho	Redes neurais
Gérard et al. (1997)	Balões e pipas	RGB e NIR <sup>(2)</sup>	Nitrogênio	Milheto	Regressão linear
Goel et al. (2003)	Avião	Hiperespectral	Nitrogênio	Milho	Bandas espectrais
Lebourgeois et al. (2012)	Ultraleve	RGB e NIR	Nitrogênio	Cana-de-açúcar	Regressão linear
Maresma et al. (2018)	Avião	Multiespectral	Nitrogênio	Milho	Análise Anova <sup>(3)</sup>
Meggio et al. (2010)	Avião	Hiperespectral	Ferro	Videira	Regressão linear
Nigon et al. (2015)	Avião	Hiperespectral	Nitrogênio	Batata	Regressão por mínimos quadrados parciais
Quemada et al. (2014)	Avião	Hiperespectral	Nitrogênio	Milho	Regressão linear
Reisig e Godfrey (2010)	Avião	Multiespectral e Hiperespectral	Nitrogênio	Algodão	Análise Anova
Scharf e Lory (2002)	Avião	Multiespectral	Nitrogênio	Milho	Regressão linear e não linear
Sripada et al. (2007)	Avião	Multiespectral	Nitrogênio	Trigo	Regressão linear e quadrática
Williams et al. (2010)	Avião	RGB	Nitrogênio	Milho	Regressão quadrática

<sup>(1)</sup> RGB = vermelho, verde, azul. <sup>(2)</sup> NIR = near infrared. <sup>(3)</sup> Anova = análise de variância.

dados sejam obtidos nos momentos mais apropriados (Severtson et al., 2016). Em comparação com aeronaves tripuladas, os Vants são uma opção mais barata, segura e flexível (Barbedo; Koenigkan, 2018).

A Tabela 14.3 revela que Vants rotativos (quadri, hexa e octocópteros, ver exemplo na Figura 14.3) são os mais utilizados, provavelmente devido ao baixo custo associado. Na maior parte dos casos, são utilizados sensores multiespec-

trais e RGB convencionais. Isso ocorre devido a esses tipos de sensores tenderem a ser mais leves e baratos que sensores hiperespectrais. O custo dos sensores é particularmente importante, porque, considerando que o risco de quedas está sempre presente, os prejuízos causados por eventuais danos têm de ser limitados tanto quanto possível. Novamente, estudos estão quase exclusivamente concentrados no nitrogênio. Uma grande variedade de culturas agrícolas vem sendo considerada, com destaque para o

**Tabela 14.3.** Técnicas para detecção de problemas nutricionais por meio do uso de imagens de drones.

Trabalho	Tipo de drone	Tipo de imagem	Nutriente	Cultura agrícola testada	Classificação/Regressão
Agüera et al. (2011)	Rotativo	Multiespectral	Nitrogênio	Girassol	Regressão linear
Ballester et al. (2017)	Rotativo	Multiespectral	Nitrogênio	Algodão	Regressão linear e quadrática
Benincasa et al. (2018)	Rotativo	Multiespectral	Nitrogênio	Trigo	Regressão linear
Berni et al. (2009)	Rotativo	Multiespectral e termal	Nitrogênio	Pessegueiro	Regressão linear
Caturegli et al. (2016)	Rotativo	Multiespectral	Nitrogênio	Gramma	Regressão linear
Corti et al. (2019)	Rotativo	RGB <sup>(1)</sup> + filtro NIR <sup>(2)</sup>	Nitrogênio	Milho	Regressão por mínimos quadrados parciais
Felderhof e Gillieson (2011)	Rotativo	RGB + NIR	Nitrogênio	Macadâmia	Regressão linear
Gabriel et al. (2017)	Rotativo	Multiespectral e hiperespectral	Nitrogênio	Milho	Funções polinomiais
Geipel et al. (2016)	Rotativo	Multiespectral	Nitrogênio	Trigo	Regressão linear
Gracia-Romero et al. (2017)	Rotativo	RGB	Fósforo	Milho	Regressão multilinear
Hunt Junior et al. (2005)	Asa fixa	RGB	Nitrogênio	Milho	Regressão de mínimos quadrados
Hunt Junior et al. (2018)	Parapente	Multiespectral	Nitrogênio	Batata	Regressão linear
Latif et al. (2018)	Rotativo	Multiespectral	Nitrogênio, fósforo, zinco	Trigo	Regressão linear
Lelong et al. (2008)	Parapente e asa fixa	Multiespectral	Nitrogênio	Trigo	Funções exponenciais
Li et al. (2015)	Rotativo	RGB	Nitrogênio	Arroz	Regressão linear
Liu et al. (2018)	Não informado	Multiespectral	Nitrogênio	Colza	Regressão linear
Maimaitijiang et al. (2017)	Rotativo	Multiespectral, termal, RGB	Nitrogênio	Soja	Aprendizado extremo
Maresma et al. (2016)	Asa fixa	Multiespectral	Nitrogênio	Milho	Regressão linear e quadrática
Saberioon e Gholizadeh (2016)	Asa fixa	Multiespectral	Nitrogênio	Arroz	Regressão linear
Sankaran et al. (2018)	Rotativo	Multiespectral	Nitrogênio	Feijão	Regressão linear
Severtson et al. (2016)	Rotativo	Multiespectral e hiperespectral	Potássio	Canola	Diferentes regressões
Swain et al. (2007)	Rotativo	Multiespectral	Nitrogênio	Arroz	Regressão linear
Vega et al. (2015)	Rotativo	Multiespectral	Nitrogênio	Girassol	Regressão linear
Wen et al. (2018)	Rotativo	Hiperespectral	Nitrogênio	Arroz	Regressão linear
Yakushev e Kanash (2016)	Não informado	RGB	Nitrogênio	Trigo	Regressão linear
Zaman-Allah et al. (2015)	Asa fixa	Multiespectral	Nitrogênio	Milho	Regressão linear
Zermas et al. (2015)	Rotativo	RGB	Nitrogênio	Milho	Máquinas de vetores suporte
Zheng et al. (2018a)	Rotativo	RGB, NIR, Multiespectral	Nitrogênio	Arroz	Regressão linear
Zheng et al. (2018b)	Rotativo	Multiespectral	Nitrogênio	Trigo	Vários
Zhu et al. (2018)	Rotativo	Hiperespectral	Nitrogênio	Trigo	Regressão multilinear

<sup>(1)</sup> RGB = vermelho, verde, azul. <sup>(2)</sup> NIR = near infrared.

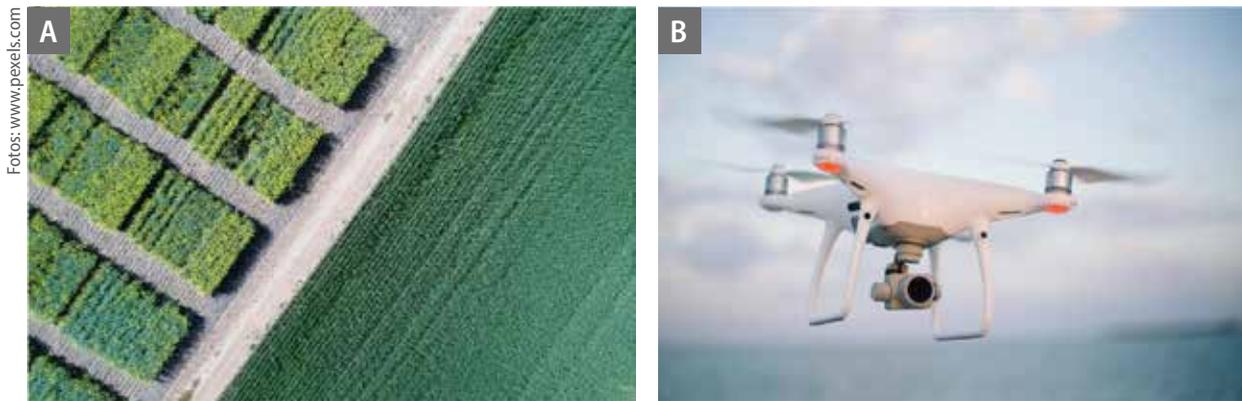


Figura 14.3. Imagem obtida por quadricóptero (A) e sensor RGB (B).

milho, o trigo e o arroz. Como no caso dos satélites e das aeronaves tripuladas, a regressão vem sendo a técnica preferida para relacionar os índices e atributos extraídos das imagens com as medidas que caracterizam o estado nutricional das plantas. Pode-se observar que o número de estudos utilizando drones vem aumentando consideravelmente, resultado da popularização deste tipo de aeronave.

### Técnicas baseadas em imagens proximais

Imagens proximais podem ser obtidas em campo ou em laboratório, e o sensor normalmente é posicionado a uma curta distância do alvo (alguns centímetros a alguns metros) (Figura 14.4). Na maioria dos casos, as imagens são captura-

das manualmente, porém o uso de sensores fixos para monitoramento permanente de certas áreas vem se tornando mais comum. Além disso, com os avanços na área de robótica, a captura de imagens usando veículos autônomos, a qual já vem sendo feita há algum tempo no âmbito de pesquisas (Shafiekhani et al., 2017), em breve se tornará uma realidade também na prática.

Na comparação com imagens obtidas por satélite, imagens proximais permitem resoluções espaciais muito mais elevadas, tornando possível que plantas e até mesmo suas diferentes estruturas (folhas, flores, caule, etc.) sejam analisadas e tratadas individualmente, permitindo que problemas nutricionais sejam detectados com mais antecedência. Na comparação com drones, as vantagens residem no fato de que



Figura 14.4. Imagens obtidas por sensores proximais.

não há a necessidade de treinamentos longos, não há restrições regulatórias e intempéries têm um impacto menor. Além disso, se a captura é realizada manualmente, os sensores podem ser posicionados de maneira a gerar o máximo de informação possível a respeito das plantas que estão sendo analisadas.

O número de técnicas baseadas em imagens proximais é consideravelmente maior que aquelas baseadas em imagens obtidas remotamente (Tabela 14.4). Este fato é devido principalmente aos custos envolvidos na condução de experimentos (no caso de drones e aeronaves) e na aquisição das imagens (no caso de satélites).

**Tabela 14.4.** Técnicas para detecção de problemas nutricionais por meio do uso de imagens proximais.

Trabalho	Tipo de imagem	Nutriente	Cultura agrícola testada	Classificação/Regressão
Amirruddin et al. (2018)	Multiespectral	Nitrogênio	Palma de óleo	Regressão linear múltipla
Backhaus et al. (2011)	Hiperespectral	Genérico	Tabaco	SVM <sup>(1)</sup> , SRNG <sup>(2)</sup> , GRLVQ <sup>(3)</sup> , RBF <sup>(4)</sup>
Bai et al. (2018)	RGB <sup>(5)</sup>	Ferro	Soja	DA Linear + SVM
Balasubramaniam e Ananthi (2016)	RGB	Manganês, fósforo, molibdênio, zinco, boro, potássio	Várias	Fuzzy C-Means
Borhan et al. (2004)	RGB e multiespectral	Nitrogênio	Batata	Regressão linear múltipla
Borhan et al. (2017)	Multiespectral	Nitrogênio	Batata	Regressão linear múltipla
Caturegli et al. (2015)	Multiespectral	Nitrogênio	Gramma	Regressão linear
Chen et al. (2013)	RGB	Fósforo	Arroz	SVM
Chen e Wang (2014)	RGB	Nitrogênio	Arroz	SVM
Chen et al. (2014)	RGB	Nitrogênio, fósforo, potássio	Arroz	SVFS <sup>(6)</sup> , Fisher DA <sup>(7)</sup>
Chen et al. (2017)	RGB	Nitrogênio	Arroz	SVM
Chen et al. (2018)	RGB	Nitrogênio	Sândalo	Função exponencial
Condori et al. (2017)	RGB	Nitrogênio	Milho	CNN <sup>(8)</sup>
Contreras-Medina et al. (2012)	RGB	Genérico	Abóbora	Contagem de pixels
Corp et al. (2003)	Fluorescência da clorofila	Nitrogênio	Milho	Regressão quadrática
Corti et al. (2017)	Hiperespectral	Nitrogênio	Espinafre	Regressão PLS <sup>(9)</sup>
Culman et al. (2017)	RGB	Potássio, magnésio, nitrogênio	Palma de óleo	MLPNN <sup>(10)</sup>
Ghosal et al. (2018)	RGB	Ferro, potássio	Soja	CNN
Giacomelli et al. (1998)	Monocromática	Genérico	Alface	(*)
Gracia-Romero et al. (2017)	RGB	Fósforo	Milho	Regressão multilinear

Continua...

Tabela 14.4. Continuação.

Trabalho	Tipo de imagem	Nutriente	Cultura agrícola testada	Classificação/ Regressão
Graeff et al. (2008)	Multiespectral	Nitrogênio	Brócolis	Regressão linear
Hu et al. (2012)	RGB	Manganês	Várias	Fuzzy C-Means
Ji-Yong et al. (2012)	Hiperespectral	Nitrogênio	Pepino	Regressão linear múltipla
Jia et al. (2004)	RGB	Nitrogênio	Trigo	Regressão linear
Jia et al. (2007)	RGB	Nitrogênio	Trigo	Regressão linear
Lee e Lee (2013)	RGB	Nitrogênio	Arroz	Regressão linear
Leemans et al. (2017)	Multiespectral	Nitrogênio	Trigo	Regressão PLS
Li et al. (2010)	RGB	Nitrogênio	Trigo	Regressão logarítmica
Li et al. (2016)	RGB	Nitrogênio	Canola	DA Linear, ELM <sup>(11)</sup> , SVM, RF <sup>(12)</sup> , kNN <sup>(13)</sup>
Liu et al. (2015)	Hiperespectral	Nitrogênio, fósforo	Citros	Regressão PLS, SVM
Liu et al. (2018)	Hiperespectral	Nitrogênio	Colza	Regressão linear
Luz et al. (2018)	RGB	Boro	Milho	kNN
Mao et al. (2015)	RGB	Nitrogênio	Alface	ELM
Mercado-Luna et al. (2010)	RGB	Nitrogênio	Tomate	Regressão linear
Moshou et al. (2006)	Hiperespectral	Nitrogênio	Trigo	SOM <sup>(14)</sup> , DA Quadrático
Asraf et al. (2012)	RGB	Nitrogênio, potássio, magnésio	Palma de óleo	SVM
Asraf et al. (2017)	RGB	Nitrogênio, potássio, magnésio	Palma de óleo	Inferência Fuzzy
Noh et al. (2003)	Multiespectral	Nitrogênio	Milho	Regressão linear
Noh et al. (2005)	Multiespectral	Nitrogênio	Milho	Regressão de potência
Pagola et al. (2009)	RGB	Nitrogênio	Cevada	Regressão linear
Rangel et al. (2016)	RGB	Potássio	Videira	kNN
Romualdo et al. (2018)	RGB	Nitrogênio	Milho	Classificadores estatísticos
Rorie et al. (2011)	RGB	Nitrogênio	Milho	Regressão linear
Saberioon et al. (2013)	RGB	Nitrogênio	Arroz	Regressão linear
Sanyal et al. (2007)	RGB	Boro, manganês, ferro, nitrogênio, potássio, magnésio	Arroz	MLPNN
Schuerger et al. (2003)	Hiperespectral	Zinco	Gramma Bahia	Regressão linear e quadrática
Silva et al. (2014)	RGB	Magnésio	Milho	Naive Bayes

Continua...

Tabela 14.4. Continuação.

Trabalho	Tipo de imagem	Nutriente	Cultura agrícola testada	Classificação/ Regressão
Singh et al. (1996)	RGB	Nitrogênio	Arroz	Regressão linear múltipla
Story et al. (2010)	RGB	Cálcio	Alface	Regressão linear segmentada
Sulistyo et al. (2017)	RGB	Nitrogênio	Trigo	ELM
Sulistyo et al. (2018)	RGB	Nitrogênio	Trigo	Regressão MLP
Summy et al. (2003)	Multiespectral	Nitrogênio	Pepino	Agrupamento estatístico
Sun et al. (2018a)	RGB	Nitrogênio, fósforo, potássio	Arroz	Valor de impacto médio e MLPNN
Sun et al. (2018b)	RGB	Nitrogênio, fósforo, potássio	Arroz	DA por passos
Sun et al. (2018c)	RGB	Nitrogênio	Arroz	Análise Anova <sup>(15)</sup>
Tewari et al. (2013)	RGB	Nitrogênio	Arroz	Regressão quadrática
Vakilian e Massah (2012)	RGB	Nitrogênio	Pepino	Regressão linear segmentada
Vakilian e Massah (2017)	RGB	Nitrogênio		
Vigneau et al. (2011)	Hiperespectral	Pepino	Limiares	Regressão PLS
Wang et al. (2013)	RGB	Nitrogênio	Arroz	Regressão exponencial
Wang et al. (2014)	RGB	Nitrogênio	Arroz	Regressão linear
Wei et al. (2010)	Multiespectral	Nitrogênio	Pepino	Regressão linear
Wiwart et al. (2009)	RGB	Nitrogênio, fósforo, potássio, magnésio	Ervilha, tremoço	(*)
Xu et al. (2011)	RGB	Nitrogênio, potássio	Tomate	Algoritmo genético
Yao e Luo (2012)	RGB	Nitrogênio	Seringueira	Regressão linear
Yu et al. (2014)	Hiperespectral	Nitrogênio	Pimenteira	Regressão PLS
Yuan et al. (2016)	RGB	Nitrogênio	Arroz	Regressão linear
Yuzhu et al. (2011)	RGB	Nitrogênio	Pimenteira	Regressão linear

<sup>(1)</sup> SVM = máquinas de suporte vetorial. <sup>(2)</sup> SRNG = gás neural de relevância. <sup>(3)</sup> GRLVQ = quantização vetorial para aprendizado de relevância generalizada. <sup>(4)</sup> RBF = função de base radial. <sup>(5)</sup> RGB = vermelho, verde, azul. <sup>(6)</sup> SVFS = seleção de atributos de vetores suporte. <sup>(7)</sup> DA = análise de discriminante. <sup>(8)</sup> CNN = redes neurais convolucionais. <sup>(9)</sup> PLS = mínimos quadrados parciais. <sup>(10)</sup> MLPNN = rede neural perceptron multicamadas. <sup>(11)</sup> ELM = máquina de aprendizado extremo. <sup>(12)</sup> RF = random forests. <sup>(13)</sup> kNN = k-vizinhos mais próximos. <sup>(14)</sup> SOM = mapas auto-organizáveis. <sup>(15)</sup> Anova = análise de variância.

(\*) Nota: Estes estudos compararam apenas os comportamentos de plantas saudáveis e com deficiências nutricionais, de modo que nenhum método de detecção foi proposto.

Câmeras RGB são mais baratas e possuem melhor portabilidade, por esse motivo são as preferidas. Contudo, outros tipos de sensores vêm se tornando mais comuns, especialmente os hiperespectrais. Diferentemente dos casos anteriores, outras técnicas de aprendizado de máquina além da regressão vêm sendo utilizadas com frequência no caso de imagens proximais, incluindo máquinas de suporte vetorial (em inglês *Support Vector Machine* – SVM) e redes neurais.

## Problemas gerais com imagens

Como detalhado nas seções anteriores, o uso de imagens para a detecção de problemas nutricionais em plantas vem proporcionando avanços importantes com aplicação imediata em propriedades rurais. Para que todo esse potencial seja efetivamente realizado, alguns cuidados importantes devem ser observados. No caso de imagens proximais, vários desses cuidados foram explorados em detalhes em Barbedo (2016, 2018a). Os mais importantes são resumidos a seguir.

### Fundo da imagem

Todos os métodos para detecção de problemas nutricionais precisam identificar, explícita ou implicitamente, os sinais característicos do estresse de interesse. Em muitos casos, elementos espúrios presentes no fundo da imagem (outras plantas, solo, outras estruturas) podem levar a erros de classificação, especialmente se as técnicas não foram treinadas para lidar com esse tipo de situação. Há três possíveis maneiras de evitar esse tipo de problema:

- a) Capturar as imagens de modo a evitar a presença de elementos problemáticos no fundo da imagem, o que exige prática e pode nem sempre ser possível.
- b) Remover o fundo da imagem, processo esse que pode ser proibitivamente demorado se

feito manualmente, e sujeito a muitos erros se feito automaticamente.

- c) Treinar o modelo para lidar com os objetos espúrios presentes na imagem. Esta última opção é, em geral, a mais confiável, porém, dependendo das condições práticas, isso pode exigir uma quantidade impraticável de dados.

Em última análise, a melhor solução dependerá das características de cada caso e do grau de dificuldade de se obter os dados/imagens necessários.

### Condições de captura das imagens

Muitas das técnicas para reconhecimento de deficiências nutricionais e doenças em planta são desenvolvidas tendo como referência imagens capturadas em condições controladas, nas quais a iluminação é uniforme e a influência de fatores externos é limitada. O problema com essa estratégia é que, na prática, variações de iluminação são inevitáveis devido a condições atmosféricas e à posição do sol no momento da captura. Além disso, o ambiente em campo é inóspito, com diversos fatores como poeira, vento e outros fenômenos atmosféricos podendo ter grande impacto nas imagens. Portanto, para que qualquer técnica tenha potencial de uso prático, é essencial que todas as condições esperadas no dia a dia estejam contempladas nos seus conjuntos de treinamento. Novamente, na maioria das vezes é bastante difícil gerar dados em quantidade e variedade ideais, porém essa é uma condição essencial para a adoção prática dessa tipo de ferramenta.

### Presença de múltiplos estresses simultaneamente

A geração de dados para o desenvolvimento de técnicas para detecção de problemas

nutricionais frequentemente envolve a indução da deficiência/toxicidade de interesse, e então imagens dos sinais resultantes são capturadas. Na prática, é muito comum que múltiplos estresses ocorram simultaneamente (Quemada et al., 2014), o que significa que as características visuais e espectrais da planta naquele instante são uma combinação dos diferentes problemas que estão afetando a planta.

Considerando que há uma grande quantidade de possíveis combinações de estresses bióticos e abióticos, a variedade de sintomas pode ser proibitivamente elevada. Idealmente, todas essas combinações deveriam estar contempladas nos conjuntos de treinamento utilizados, porém isso é inexequível na prática. Para evitar possíveis problemas, é importante que pelo menos as doenças e deficiências mais comuns sejam estudadas em conjunto, de modo a verificar quais tendem a dominar as características visuais e a determinar como afinar o modelo para lidar com esse tipo de situação.

### **Diferentes desordens com sintomas similares**

A similaridade de sintomas entre diferentes desordens é uma das principais dificuldades enfrentadas por métodos para detecção automática de problemas nutricionais. Essas desordens abrangem doenças, deficiências nutricionais, pragas, fitotoxicidade, frio ou calor excessivo, bem como vários danos mecânicos. Em alguns casos, o uso de bandas como o infravermelho pode prover informação suficiente para distinguir entre essas desordens, porém isso pode aumentar os custos de captura, e a maior parte dos dispositivos móveis não é capaz de capturar imagens nessas bandas adicionais, o que pode alijar muitos usuários potenciais da tecnologia. Além disso, é importante notar que certas ambiguidades não podem ser resolvidas mesmo pelo uso de várias bandas espectrais. Esse é um

problema desafiador, e estudos específicos devem ser realizados em cada caso para identificar o que é mais problemático e determinar a melhor abordagem em cada situação.

Imagens capturadas remotamente por meio de drones, aeronaves tripuladas e satélites estão também sujeitas aos problemas causados por múltiplas desordens simultâneas e por desordens com sintomas similares, porém há também alguns desafios específicos, muitos dos quais estão ligados a fatores operacionais e ambientais (Barbedo; Koenigkan, 2018) e não serão tratados aqui. Quanto aos fatores que afetam diretamente as características das imagens, os seguintes são particularmente relevantes.

### **Altitude de voo**

Satélites têm altitude fixa, porém as aeronaves, tripuladas ou não, podem voar a diferentes altitudes. Quanto mais alto o voo, maior a área coberta por unidade de tempo, reduzindo custos e riscos, porém reduzindo também a resolução espacial das imagens obtidas. Assim, a altitude ideal deve ser definida caso a caso considerando a resolução mínima requerida para aplicação pretendida.

### **Pixels misturados**

A resolução da maioria das imagens capturadas remotamente não é suficiente para evitar a ocorrência de pixels resultantes da mistura de diferentes elementos (por exemplo, folhas mais solo). Dependendo da proporção de pixels misturados, a análise nutricional da área de interesse pode ficar comprometida (Williams et al., 2010). Isso reforça a necessidade de se determinar a altitude de voo com cuidado, para evitar inconsistências nos dados obtidos.

### **Cobertura de nuvens**

A captura de nuvens é um problema que afeta imagens de satélite com mais intensidade.

Especialmente no caso de áreas com tendência a alta nebulosidade, é importante que seja possível capturar imagens com uma frequência temporal suficiente para que, no caso de haver perda de informação devido à presença de nuvens, seja possível realizar uma nova análise a tempo de detectar problemas nutricionais antes que esses causem danos sérios.

### **Construção de mosaicos**

Cada imagem aérea é capaz de cobrir certa extensão territorial, e normalmente são necessárias várias imagens para que a área de interesse inteira seja completamente coberta. Em muitos casos, é necessário registrar essas imagens e combiná-las em um único mosaico, em um processo que é sujeito a erros. Felizmente, ferramentas recentes para construção de mosaicos são bastante eficientes, e eventuais erros normalmente têm impacto limitado na análise geral da área de interesse.

### **Variação da refletância devido às características do solo**

A composição do solo e a quantidade de água presente afetam as refletâncias obtidas e, por conseguinte, podem prejudicar a detecção dos problemas de interesse (Shou et al., 2007). Normalmente, a melhor solução é incluir no conjunto de treinamento toda a variabilidade de solos que se pode encontrar na prática.

### **Presença de sombras**

Dependendo do ângulo solar, as imagens obtidas podem ter grandes áreas sombreadas que necessitam de processamento específico. Em alguns casos, pode haver perda de informação relevante para a detecção de deficiências nutricionais. Assim, recomenda-se que as imagens sejam capturadas com sol a pino, a fim de minimizar a ocorrência de sombras.

### **Perda de dados**

Se as imagens não são armazenadas na própria aeronave, falhas de comunicação podem causar perda de informação. O uso de sistemas redundantes não é adequado devido a limitações de carga e custos envolvidos. Uma maneira prática de evitar que algumas áreas fiquem sem qualquer dado associado é fazer com que todas as imagens sejam capturadas com pelo menos 50% de sobreposição, garantindo assim que todos os pontos em solo sejam imageados pelo menos duas vezes, à custa de mais dados precisarem ser processados.

### **Considerações finais**

Este capítulo apresentou uma visão geral do uso de imagens digitais para a determinação do estado nutricional de plantas e detecção de possíveis deficiências. Embora a cana-de-açúcar ainda recebe pouca atenção nesse sentido, a maior parte das técnicas e tecnologias apresentadas aqui pode ser estendida para diferentes culturas agrícolas. Apesar dos avanços que vêm sendo alcançados, ainda são raras as tecnologias baseadas em imagens disponíveis comercialmente. Isso provavelmente se deve aos muitos desafios práticos envolvidos na tarefa, alguns dos quais foram listados neste capítulo. Assim, o grande desafio do momento é transformar os avanços científicos em ferramentas de uso prático para auxiliar os produtores na gestão de suas lavouras, o que resultará em plantas mais saudáveis e em menos desperdício.

### **Referências**

AGÜERA, F.; CARVAJAL, F.; PÉREZ, M. Measuring sunflower nitrogen status from an unmanned aerial vehicle-based system and an on the ground device. *International Archives of The Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 38-1, n. C22, p. 33-37, 2011. Trabalho apresentado na International Conference on Unmanned Aerial

Vehicle in Geomatics, 2011, Zurich. DOI: [10.5194/isprsarchives-XXXVIII-1-C22-33-2011](https://doi.org/10.5194/isprsarchives-XXXVIII-1-C22-33-2011).

ALI, M. M.; AL-ANI, A.; EAMUS, D.; TAN, D. K. Y. Leaf nitrogen determination using non-destructive techniques-a review. **Journal of Plant Nutrition**, v. 40, n. 7, p. 928-953, 2017. DOI: [10.1080/01904167.2016.1143954](https://doi.org/10.1080/01904167.2016.1143954).

AMIRRUDDIN, A. D.; MUHARAM, F. M. Evaluation of linear discriminant and support vector machine classifiers for classification of nitrogen status in mature oil palm from SPOT-6 satellite images: analysis of raw spectral bands and spectral indices. **Geocarto International**, v. 34, n. 7, p. 735-749, 2018. DOI: [10.1080/10106049.2018.1434687](https://doi.org/10.1080/10106049.2018.1434687).

AMIRRUDDIN, A. D.; MUHARAM, F. M.; KARAM, D. S. Evaluation of ground-level and space-borne sensor as tools in monitoring nitrogen nutrition status in immature and mature oil palm. **Journal of Plant Nutrition**, v. 41, n. 3, p. 371-383, 2018. DOI: [10.1080/01904167.2017.1385804](https://doi.org/10.1080/01904167.2017.1385804).

ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138-146, Apr. 2013. DOI: [10.1890/120150](https://doi.org/10.1890/120150).

ASRAF, M. H.; DALILA, N. K. A.; FAIZ A. Z. A.; AMINAH, S. N.; NOORITAWATI, M. T. A fuzzy inference system for diagnosing oil palm nutritional deficiency symptoms. **ARPN Journal of Engineering and Applied Sciences**, v. 12, n. 10, p. 3244-3250, May 2017.

ASRAF, M. H.; NOORITAWATI, M. T.; RIZAM, M. S. B. S. A comparative study in kernel-based support vector machine of oil palm leaves nutrient disease. **Procedia Engineering**, v. 41, p. 1353-1359, 2012. DOI: [10.1016/j.proeng.2012.07.321](https://doi.org/10.1016/j.proeng.2012.07.321).

BACKHAUS, A.; BOLLENBECK, F.; SEIFFERT, U. Robust classification of the nutrition state in crop plants by hyperspectral imaging and artificial neural networks. In: Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 3., 2011, Lisbon. **Proceedings...** Piscataway: IEEE, 2011. 4 p. DOI: [10.1109/WHISPERS.2011.6080898](https://doi.org/10.1109/WHISPERS.2011.6080898).

BAI, G.; JENKINS, S.; YUAN, W.; GRAEF, G. L.; GE, Y. Field-based scoring of soybean iron deficiency chlorosis using RGB imaging and statistical learning. **Frontiers in Plant Science**, v. 9, p. 1-12, July 2018. DOI: [10.3389/fpls.2018.01002](https://doi.org/10.3389/fpls.2018.01002).

BALASUBRAMANIAM, P.; ANANTHI, V. P. Segmentation of nutrient deficiency in incomplete crop images using intuitionistic fuzzy C-means clustering algorithm. **Nonlinear Dynamics**, v. 83, n. 1-2, p. 849-866, Jan. 2016. DOI: [10.1007/s11071-015-2372-y](https://doi.org/10.1007/s11071-015-2372-y).

BALLESTER, C.; HORNBUCKLE, J.; BRINKHOFF, J.; SMITH, J.; QUAYLE, W. Assessment of in-season cotton nitrogen status and lint yield prediction from unmanned aerial system imagery. **Remote Sensing**, v. 9, n. 1, p. 1-18, Nov. 2017. DOI: [10.3390/rs9111149](https://doi.org/10.3390/rs9111149).

BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, p. 52-60, Apr. 2016. DOI: [10.1016/j.biosystemseng.2016.01.017](https://doi.org/10.1016/j.biosystemseng.2016.01.017).

BARBEDO, J. G. A. Digital image processing techniques for detecting, quantifying and classifying plant diseases. **SpringerPlus**, v. 2, p. 1-12, 2013. DOI: [10.1186/2193-1801-2-66](https://doi.org/10.1186/2193-1801-2-66).

BARBEDO, J. G. A. Factors influencing the use of deep learning for plant disease recognition. **Biosystems Engineering**, v. 172, p. 84-91, Aug. 2018a. DOI: [10.1016/j.biosystemseng.2018.05.013](https://doi.org/10.1016/j.biosystemseng.2018.05.013).

BARBEDO, J. G. A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. **Computers and Electronics in Agriculture**, v. 153, p. 46-53, Oct. 2018b. DOI: [10.1016/j.compag.2018.08.013](https://doi.org/10.1016/j.compag.2018.08.013).

BARBEDO, J. G. A.; KOENIGKAN, L. V. Perspectives on the use of unmanned aerial systems to monitor cattle. **Outlook on Agriculture**, v. 47, n. 3, p. 214-222, Sept. 2018. DOI: [10.1177/0030727018781876](https://doi.org/10.1177/0030727018781876).

BAUSCH, W. C.; KHOSLA, R. QuickBird satellite versus ground-based multi-spectral data for estimating nitrogen status of irrigated maize. **Precision Agriculture**, v. 11, n. 3, p. 274-290, June 2010. DOI: [10.1007/s11119-009-9133-1](https://doi.org/10.1007/s11119-009-9133-1).

BENINCASA, P.; ANTOGNELLI, S.; BRUNETTI, L.; FABBRI, C. A.; NATALE, A.; SARTORETTI, V.; MODEO, G.; GUIDUCCI, M.; TEI, F.; VIZZARI, M. Reliability of NDVI derived by high resolution satellite and UAV compared to in-field methods for the evaluation of early crop N status and grain yield in wheat. **Experimental Agriculture**, v. 54, n. 4, p. 604-622, Aug. 2018. DOI: [10.1017/S0014479717000278](https://doi.org/10.1017/S0014479717000278).

BERNI, J. A. J.; ZARCO-TEJADA, P. J.; SUÁREZ, L.; FERERES, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial Vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722-738, Mar. 2009. DOI: [10.1109/TGRS.2008.2010457](https://doi.org/10.1109/TGRS.2008.2010457).

BLACKMER, T. M.; SCHEPERS, J. S. Aerial Photography to Detect Nitrogen Stress in Corn. **Journal of Plant Physiology**, v. 148, n. 3-4, p. 440-444, May 1996. DOI: [10.1016/S0176-1617\(96\)80277-X](https://doi.org/10.1016/S0176-1617(96)80277-X).

- BOCK, C. H.; POOLE, G. H.; PARKER, P. E.; GOTTWALD, T. R. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, v. 29, n. 2, p. 59-107, 2010. DOI: [10.1080/07352681003617285](https://doi.org/10.1080/07352681003617285).
- BONADIES, S.; LEFCOURT, A.; GADSDEN, S. A. A survey of unmanned ground vehicles with applications to agricultural and environmental sensing. In: AUTONOMOUS AIR AND GROUND SENSING SYSTEMS FOR AGRICULTURAL OPTIMIZATION AND PHENOTYPING, 1., 2016, Baltimore. **Proceedings...** Bellingham: SPIE, 2016. p. 98660Q-1-98660Q-14. (Proceedings of SPIE, 9866). DOI: [10.1117/12.2224248](https://doi.org/10.1117/12.2224248).
- BORDOGNA, G.; KLIMENT, T.; FRIGERIO, L.; BRIVIO, P. A.; CREMA, A.; STROPPIANA, D.; BOSCHETTI, M.; STERLACCHINI, S. A spatial data infrastructure integrating multisource heterogeneous geospatial data and time series: a study case in agriculture. **ISPRS International Journal of Geo-Information**, v. 5, n. 5, p. 1-27, May 2016. DOI: [10.3390/ijgi5050073](https://doi.org/10.3390/ijgi5050073).
- BORHAN, M. S.; PANIGRAHI, S.; PANIGRAHI, S.; GU, H. Multispectral and color imaging techniques for nitrate and chlorophyll determination of potato leaves in a controlled environment. **Transactions of the ASAE**, v. 47, n. 2, p. 599-608, Mar./Apr. 2004. DOI: [10.13031/2013.16023](https://doi.org/10.13031/2013.16023).
- BORHAN, M. S.; PANIGRAHI, S.; SATTER, M. A.; GU, H. Evaluation of computer imaging technique for predicting the SPAD readings in potato leaves. **Information Processing in Agriculture**, v. 4, n. 4, p. 275-282, Dec. 2017. DOI: [10.1016/j.inpa.2017.07.005](https://doi.org/10.1016/j.inpa.2017.07.005).
- BUTLER, H. J.; ADAMS, S.; MCAINSH, M. R.; MARTIN, F. L. Detecting nutrient deficiency in plant systems using synchrotron Fourier-transform infrared microspectroscopy. **Vibrational Spectroscopy**, v. 90, p. 46-55, May 2017. DOI: [10.1016/j.vibspec.2017.03.004](https://doi.org/10.1016/j.vibspec.2017.03.004).
- CAPOLUPO, A.; KOOISTRA, L.; BERENDONK, C.; BOCCIA, L.; SUOMALAINEN, J. Estimating plant traits of grasslands from UAV-acquired hyperspectral images: a comparison of statistical approaches. **ISPRS International Journal of Geo-Information**, v. 4, n. 4, p. 2792-2820, Dec. 2015. DOI: [10.3390/ijgi4042792](https://doi.org/10.3390/ijgi4042792).
- CATUREGLI, L.; CASUCCI, M.; LULLI, F.; GROSSI, N.; GAETANI, M.; MAGNI, S.; BONARI, E.; VOLTERRANI, M. GeoEye-1 satellite versus ground-based multispectral data for estimating nitrogen status of turfgrasses. **International Journal of Remote Sensing**, v. 36, n. 8, p. 2238-2251, 2015. DOI: [10.1080/01431161.2015.1035409](https://doi.org/10.1080/01431161.2015.1035409).
- CATUREGLI, L.; CORNIGLIA, M.; GAETANI, M.; GROSSI, N.; MAGNI, S.; MIGLIAZZI, M.; ANGELINI, L.; MAZZONCINI, M.; SILVESTRI, N.; FONTANELLI, M.; RAFFAELLI, M.; PERUZZI, A.; VOLTERRANI, M. Unmanned Aerial Vehicle to estimate nitrogen status of turfgrasses. **Plos One**, v. 11, n. 6, p. 1-13, 2016. DOI: [10.1371/journal.pone.0158268](https://doi.org/10.1371/journal.pone.0158268).
- CHEN, L.; LIN, L.; CAI, G.; SUN, Y.; HUANG, T.; WANG, K.; DENG, J. Identification of nitrogen, phosphorus, and potassium deficiencies in rice based on static scanning technology and hierarchical identification method. **Plos One**, v. 9, n. 11, p. 1-17, 2014. DOI: [10.1371/journal.pone.0113200](https://doi.org/10.1371/journal.pone.0113200).
- CHEN, L.; SUN, Y.; WANG, K. Rapid diagnosis of nitrogen nutrition status in rice based on static scanning and extraction of leaf and sheath characteristics. **International Journal of Agricultural and Biological Engineering**, v. 10, n. 3, p. 158-164, May 2017. DOI: [10.3965/j.ijabe.20171003.1860](https://doi.org/10.3965/j.ijabe.20171003.1860).
- CHEN, L. S.; WANG, K. Diagnosing of rice nitrogen stress based on static scanning technology and image information extraction. **Journal of Soil Science and Plant Nutrition**, v. 14, n. 2, p. 382-393, June 2014. DOI: [10.4067/S0718-95162014005000030](https://doi.org/10.4067/S0718-95162014005000030).
- CHEN, L. S.; ZHANG, S. J.; WANG, K.; SHEN, Z. Q.; DENG, J. S. Identifying of rice phosphorus stress based on machine vision technology. **Life Science Journal**, v. 10, n. 2, p. 2655-2663, 2013.
- CHEN, Z.; WANG, X.; WANG, H. Preliminary research on total nitrogen content prediction of sandalwood using the error-in-variable models based on digital image processing. **Plos One**, v. 13, n. 8, p. 1-22, 2018. DOI: [10.1371/journal.pone.0202649](https://doi.org/10.1371/journal.pone.0202649).
- CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; Busetto, L.; AMADUCCI, S.; BOSCHETTI, M.; PICCHI, V.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, July 2014. DOI: [10.3390/rs6076549](https://doi.org/10.3390/rs6076549).
- COHEN, Y.; ALCHANATIS, V.; ZUSMAN, Y.; DAR, Z.; BONFIL, D. J.; KARNIELI, A.; ZILBERMAN, A.; MOULIN, A.; OSTROVSKY, V.; LEVI, A.; BRIKMAN, R.; SHENKER, M. Leaf nitrogen estimation in potato based on spectral data and on simulated bands of the VEN $\mu$ S satellite. **Precision Agriculture**, v. 11, n. 5, p. 520-537, Oct. 2010. DOI: [10.1007/s11119-009-9147-8](https://doi.org/10.1007/s11119-009-9147-8).
- CONDORI, R. H. M.; ROMUALDO, L. M.; BRUNO, O. M.; LUZ, P. H. DE C. Comparison between traditional texture methods and deep learning descriptors for detection of nitrogen deficiency in maize crops. In: Workshop of Computer Vision, 2017, Natal. **Proceedings...** Piscataway: IEEE, 2017. p. 7-12. DOI: [10.1109/WVC.2017.00009](https://doi.org/10.1109/WVC.2017.00009).
- CONTRERAS-MEDINA, L. M.; OSORNIO-RIOS, R. A.; TORRES-PACHECO, I.; ROMERO-TRONCOSO, R. J.;

- GUEVARA-GONZÁLEZ, R. G.; MILLAN-ALMARAZ, J. R. Smart sensor for real-time quantification of common symptoms present in unhealthy plants. **Sensors**, v. 12, n. 1, p. 784-805, Jan. 2012. DOI: [10.3390/s120100784](https://doi.org/10.3390/s120100784).
- CORP, L. A.; MCMURTREY, J. E.; MIDDLETON, E. M.; MULCHI, C. L.; CHAPPELLE, E. W.; DAUGHTRY, C. S. T. Fluorescence sensing systems: In vivo detection of biophysical variations in field corn due to nitrogen supply. **Remote Sensing of Environment**, v. 86, n. 4, p. 470-479, Aug. 2003. DOI: [10.1016/S0034-4257\(03\)00125-1](https://doi.org/10.1016/S0034-4257(03)00125-1).
- CORTI, M.; CAVALLI, D.; CABASSI, G.; VIGONI, A.; DEGANI, L.; GALLINA, P. M. Application of a low-cost camera on a UAV to estimate maize nitrogen-related variables. **Precision Agriculture**, v. 20, n. 4, p. 675-696, Aug. 2019. DOI: [10.1007/s11119-018-9609-y](https://doi.org/10.1007/s11119-018-9609-y).
- CORTI, M.; GALLINA, P. M.; CAVALLI, D.; CABASSI, G. Hyperspectral imaging of spinach canopy under combined water and nitrogen stress to estimate biomass, water, and nitrogen content. **Biosystems Engineering**, v. 158, p. 38-50, June 2017. DOI: [10.1016/j.biosystemseng.2017.03.006](https://doi.org/10.1016/j.biosystemseng.2017.03.006).
- COSTA, J. M.; GRANT, O. M.; CHAVES, M. M. Thermography to explore plant–environment interactions. **Journal of Experimental Botany**, v. 64, n. 13, p. 3937-3949, Oct. 2013. DOI: [10.1093/jxb/ert029](https://doi.org/10.1093/jxb/ert029).
- CULMAN, M. A.; GÓMEZ, J. A.; TALAVERA, J.; QUIROZ, L. A.; TOBÓN, L. E.; ARANDA, J. M.; GARRETA, L. E.; BAYONA, C. J. A novel application for identification of nutrient deficiencies in oil palm using the Internet of Things. In: IEEE International Conference on Mobile Cloud Computing, Services, and Engineering, 5., 2017, San Francisco. **Proceedings...** Piscataway: IEEE, 2017. p. 169-172.
- CUNHA, M. L. P.; AQUINO, L. A.; NOVAIS, R. F.; CLEMENTE, J. M.; AQUINO, P. M. DE; OLIVEIRA, T. F. Diagnosis of the nutritional status of garlic crops. **Revista Brasileira de Ciência do Solo**, v. 40, p. 1-14, 2016. DOI: [10.1590/18069657rbcs20140771](https://doi.org/10.1590/18069657rbcs20140771).
- DEZORDI, L. R.; AQUINO, L. A. DE; AQUINO, R. F. B. DE; CLEMENTE, J. M.; ASSUNÇÃO, N. S. Diagnostic methods to assess the nutritional status of the carrot crop. **Revista Brasileira de Ciência do Solo**, v. 40, p. 1-16, 2016. DOI: [10.1590/18069657rbcs20140813](https://doi.org/10.1590/18069657rbcs20140813).
- ELVANIDI, A.; KATSOUKAS, N.; AUGOUSTAKI, D.; LOULOU, I.; KITTAS, C. Crop reflectance measurements for nitrogen deficiency detection in a soilless tomato crop. **Biosystems Engineering**, v. 176, p. 1-11, Dec. 2018. DOI: [10.1016/j.biosystemseng.2018.09.019](https://doi.org/10.1016/j.biosystemseng.2018.09.019).
- FELDERHOF, L.; GILLIESON, D. Near-infrared imagery from unmanned aerial systems and satellites can be used to specify fertilizer application rates in tree crops. **Canadian Journal of Remote Sensing**, v. 37, n. 4, p. 376-386, Aug. 2011. DOI: [10.5589/m11-046](https://doi.org/10.5589/m11-046).
- FLOWERS, M.; WEISZ, R.; HEINIGER, R. Quantitative approaches for using color infrared photography for assessing in-season nitrogen status in winter wheat. **Agronomy Journal**, v. 95, n. 5, p. 1189-1200, Sept./Oct. 2003. DOI: [10.2134/agronj2003.1189](https://doi.org/10.2134/agronj2003.1189).
- GABRIEL, J. L.; ZARCO-TEJADA, P. J.; LÓPEZ-HERRERA, P. J.; PÉREZ-MARTÍN, E.; ALONSO-AYUSO, M.; QUEMADA, M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. **Biosystems Engineering**, v. 160, p. 124-133, Aug. 2017. DOI: [10.1016/j.biosystemseng.2017.06.003](https://doi.org/10.1016/j.biosystemseng.2017.06.003).
- GAUTAM, R.; PANIGRAHI, S.; FRANZEN, D. Neural network optimisation of remotely sensed maize leaf nitrogen with a genetic algorithm and linear programming using five performance parameters. **Biosystems Engineering**, v. 95, n. 3, p. 359-370, Nov. 2006. DOI: [10.1016/j.biosystemseng.2006.07.007](https://doi.org/10.1016/j.biosystemseng.2006.07.007).
- GEIPEL, J.; LINK, J.; WIRWAHN, J. A.; CLAUPEIN, W. A programmable aerial multispectral camera system for in-season crop biomass and nitrogen content estimation. **Agriculture**, v. 6, n. 1, p. 1-19, Mar. 2016. DOI: [10.3390/agriculture6010004](https://doi.org/10.3390/agriculture6010004).
- GÉRARD, B.; BUERKERT, A.; HIERNAUX, P.; MARSCHNER, H. Non-destructive measurement of plant growth and nitrogen status of pearl millet with low-altitude aerial photography. **Soil Science and Plant Nutrition**, v. 43, p. 993-998, 1997. Sup1. DOI: [10.1080/00380768.1997.11863705](https://doi.org/10.1080/00380768.1997.11863705).
- GHOSAL, S.; BLYSTONE, D.; SINGH, A. K.; GANAPATHYSUBRAMANIAN, B.; SINGH, A.; SARKAR, S. An explainable deep machine vision framework for plant stress phenotyping. **Proceedings of the National Academy of Sciences of the United States of America**, v. 115, n. 18, p. 4613-4618, May 2018. DOI: [10.1073/pnas.1716999115](https://doi.org/10.1073/pnas.1716999115).
- GIACOMELLI, G. A.; LING, P. P.; KOLE, J. Determining nutrient stress in lettuce plants with machine vision technology. **HortTechnology**, v. 8, n. 3, p. 361-365, July 1998. DOI: [10.21273/HORTTECH.8.3.361](https://doi.org/10.21273/HORTTECH.8.3.361).
- GOEL, P. K.; PRASHER, S. O.; LANDRY, J. A.; PATEL, R. M.; BONNELL, R. B.; VIAU, A. A.; MILLER, J. R. Potential of airborne hyperspectral remote sensing to detect nitrogen deficiency and weed infestation in corn. **Computers and Electronics in Agriculture**, v. 38, n. 2, p. 99-124, Feb. 2003. DOI: [10.1016/S0168-1699\(02\)00138-2](https://doi.org/10.1016/S0168-1699(02)00138-2).
- GORBE, E.; CALATAYUD, A. Applications of chlorophyll fluorescence imaging technique in horticultural research:

a review. **Scientia Horticulturae**, v. 138, p. 24-35, May 2012. DOI: [10.1016/j.scienta.2012.02.002](https://doi.org/10.1016/j.scienta.2012.02.002).

GRACIA-ROMERO, A.; KEFAUVER, S. C.; VERGARA-DÍAZ, O.; ZAMAN-ALLAH, M. A.; PRASANNA, B. M.; CAIRNS, J. E.; ARAUS, J. L. Comparative performance of ground vs. aerially assessed RGB and multispectral indices for early-growth evaluation of maize performance under phosphorus fertilization. **Frontiers in Plant Science**, v. 8, p. 1-13, Nov. 2017. DOI: [10.3389/fpls.2017.02004](https://doi.org/10.3389/fpls.2017.02004).

GRAEFF, S.; PFENNING, J.; CLAUPEIN, W.; LIEBIG, H. P. Evaluation of image analysis to determine the n-fertilizer demand of broccoli plants (*Brassica oleracea* convar. *botrytis* var. *italica*). **Advances in Optical Technologies**, v. 2008, p. 1-8, 2008. DOI: [10.1155/2008/359760](https://doi.org/10.1155/2008/359760).

HIREMATH, S. A.; VAN DER HEIJDEN, G. W. A. M.; VAN EVERT, F. K.; STEIN, A.; TER BRAAK, C. J. F. Laser range finder model for autonomous navigation of a robot in a maize field using a particle filter. **Computers and Electronics in Agriculture**, v. 100, p. 41-50, Jan. 2014. DOI: [10.1016/j.compag.2013.10.005](https://doi.org/10.1016/j.compag.2013.10.005).

HOGAN, S. D.; KELLY, M.; STARK, B.; CHEN, Y. Unmanned aerial systems for agriculture and natural resources. **California Agriculture**, v. 71, n. 1, p. 5-14, Jan./Mar. 2017. DOI: [10.3733/ca.2017a0002](https://doi.org/10.3733/ca.2017a0002).

HU, J.; LI, D.; CHEN, G.; DUAN, Q.; HAN, Y. Image segmentation method for crop nutrient deficiency based on Fuzzy C-Means clustering algorithm. **Intelligent Automation & Soft Computing**, v. 18, n. 8, p. 1145-1155, 2012. DOI: [10.1080/10798587.2008.10643318](https://doi.org/10.1080/10798587.2008.10643318).

HUANG, S.; MIAO, Y.; ZHAO, G.; YUAN, F.; MA, X.; TAN, C.; YU, W.; GNYP, M. L.; LENZ-WIEDEMANN, V. I. S.; RASCHER, U.; BARETH, G. Satellite remote sensing-based in-season diagnosis of rice nitrogen status in Northeast China. **Remote Sensing**, v. 7, n. 8, p. 10646-10667, Aug. 2015. DOI: [10.3390/rs70810646](https://doi.org/10.3390/rs70810646).

HUNT JUNIOR, E. R.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; MCMURTREY, J.; WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, n. 4, p. 359-378, Aug. 2005. DOI: [10.1007/s11119-005-2324-5](https://doi.org/10.1007/s11119-005-2324-5).

HUNT JUNIOR, E. R.; HORNECK, D. A.; SPINELLI, C. B.; TURNER, R. W.; BRUCE, A. E.; GADLER, D. J.; BRUNGARDT, J. J.; HAMM, P. B. Monitoring nitrogen status of potatoes using small unmanned aerial vehicles. **Precision Agriculture**, v. 19, n. 2, p. 314-333, Apr. 2018. DOI: [10.1007/s11119-017-9518-5](https://doi.org/10.1007/s11119-017-9518-5).

JI-YONG, S.; XIAO-BO, Z.; JIE-WEN, Z.; KAI-LIANG, W.; ZHENG-WEI, C.; WIAO-WEI, H.; DE-TAO, Z.; HOLMES, M. Nondestructive diagnostics of nitrogen deficiency by cucumber leaf chlorophyll distribution map based

on near infrared hyperspectral imaging. **Scientia Horticulturae**, v. 138, p. 190-197, May 2012. DOI: [10.1016/j.scienta.2012.02.024](https://doi.org/10.1016/j.scienta.2012.02.024).

JIA, L.; CHEN, X.; ZHANG, F.; BUERKERT, A.; ROEMHELD, V. Optimum nitrogen fertilization of winter wheat based on color digital camera images. **Communications in Soil Science and Plant Analysis**, v. 38, n. 11-12, p. 1385-1394, 2007. DOI: [10.1080/00103620701375991](https://doi.org/10.1080/00103620701375991).

JIA, L.; CHEN, X.; ZHANG, F.; BUERKERT, A.; RÖMHELD, V. Use of digital camera to assess nitrogen status of winter wheat in the northern China Plain. **Journal of Plant Nutrition**, v. 27, n. 3, p. 441-450, 2004. DOI: [10.1081/PLN-120028872](https://doi.org/10.1081/PLN-120028872).

JIA L.; YU, Z.; LI, F.; GNYP, M.; KOPPE, W.; BARETH, G.; MIAO, Y.; CHEN, X.; ZHANG, F. Nitrogen status estimation of winter wheat by using an IKONOS satellite image in the North China Plain. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMPUTING TECHNOLOGIES IN AGRICULTURE, 5., 2011, Beijing. **Computer and computing technologies in agriculture V: proceedings**. Heidelberg: Springer, 2012. pt. II, p. 174-184. (IFIP advances in information and communication technology, 369). DOI: [10.1007/978-3-642-27278-3\\_19](https://doi.org/10.1007/978-3-642-27278-3_19).

JINYANG, L.; MEIQING, L.; HANPING, M.; WENJING, Z. Diagnosis of potassium nutrition level in *Solanum lycopersicum* based on electrical impedance. **Biosystems Engineering**, v. 147, p. 130-138, July 2016. DOI: [10.1016/j.biosystemseng.2016.04.005](https://doi.org/10.1016/j.biosystemseng.2016.04.005).

KAMILARIS, A.; ASSUMPCIO, A.; BLASI, A. B.; TORRELLAS, M.; PRENAFETA-BOLDÚ, F. X. Estimating the environmental impact of agriculture by means of geospatial and big data analysis: the case of Catalonia. In: OTJACQUES, B.; HITZELBERGER, P.; NAUMANN, S.; WOHLGEMUTH, V. (ed.). **From science to society: new trends in environmental informatics**. Cham: Springer, 2018. p. 39-48. Trabalho apresentado na 31st. edition of the long-standing and established international and interdisciplinary conference on environmental information and communication technologies (EnvirolInfo 2017), Luxembourg.

KARMAS, A.; TZOTSOS, A.; KARANTZALOS, K. Geospatial big data for environmental and agricultural applications. In: YU, S.; GUO, S. (ed.). **Big data concepts, theories, and applications**. Cham: Springer, 2016. p. 353-390. DOI: [10.1007/978-3-319-27763-9\\_10](https://doi.org/10.1007/978-3-319-27763-9_10).

LATIF, M. A.; CHEEMA, M. J. M.; SALEEM, M. F.; MAQSOOD, M. Mapping wheat response to variations in N, P, Zn, and irrigation using an unmanned aerial vehicle. **International Journal of Remote Sensing**, v. 39, n. 21, p. 7172-7188, 2018. DOI: [10.1080/01431161.2018.1515509](https://doi.org/10.1080/01431161.2018.1515509).

- LEBOURGEOIS, V.; BÉGUÉ, A.; LABBÉ, S.; HOULÈS, M.; MARTINÉ, J. F. A light-weight multi-spectral aerial imaging system for nitrogen crop monitoring. **Precision Agriculture**, v. 13, n. 5, p. 525-541, Oct. 2012. DOI: [10.1007/s11119-012-9262-9](https://doi.org/10.1007/s11119-012-9262-9).
- LEE, K. J.; LEE, B. W. Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis. **European Journal of Agronomy**, v. 48, p. 57-65, July 2013. DOI: [10.1016/j.eja.2013.02.011](https://doi.org/10.1016/j.eja.2013.02.011).
- LEEMANS, V.; MARLIER, G.; DESTAIN, M. F.; DUMONT, B.; MERCATORIS, B. Estimation of leaf nitrogen concentration on winter wheat by multispectral imaging. In: REMOTE SENSING FOR AGRICULTURE, ECOSYSTEMS, AND HYDROLOGY, 19., 2017, Warsaw. **Proceedings...** Bellingham: SPIE, 2017. p. 102130I-1-102130I-10. (SPIE proceedings, v. 10213). DOI: [10.1117/12.2268398](https://doi.org/10.1117/12.2268398).
- LELONG, C. C. D.; BURGER, P.; JUBELIN, G.; ROUX, B.; LABBÉ, S.; BARET, F. Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots. **Sensors**, v. 8, n. 5, p. 3557-3585, May 2008. DOI: [10.3390/s8053557](https://doi.org/10.3390/s8053557).
- LI, J.; ZHANG, F.; QIAN, X.; ZHU, Y.; SHEN, G. Quantification of rice canopy nitrogen balance index with digital imagery from unmanned aerial vehicle. **Remote Sensing Letters**, v. 6, n. 3, p. 183-189, 2015. DOI: [10.1080/2150704X.2015.1021934](https://doi.org/10.1080/2150704X.2015.1021934).
- LI, J. H.; WANG, F.; LI, J. W.; ZOU, R. B.; LIAO, G. P. Multifractal methods for rapeseed nitrogen nutrition qualitative diagnosis modeling. **International Journal of Biomathematics**, v. 9, n. 4, p. 1650064-1-1650064-13, July 2016. DOI: [10.1142/S1793524516500649](https://doi.org/10.1142/S1793524516500649).
- LI, Y.; CHEN, D.; WALKER, C. N.; ANGUS, J. F. Estimating the nitrogen status of crops using a digital camera. **Field Crops Research**, v. 118, n. 3, p. 221-227, Sept. 2010. DOI: [10.1016/j.fcr.2010.05.011](https://doi.org/10.1016/j.fcr.2010.05.011).
- LIU, S.; LI, L.; GAO, W.; ZHANG, Y.; LIU, Y.; WANG, S.; LU, J. Diagnosis of nitrogen status in winter oilseed rape (*Brassica napus* L.) using *in-situ* hyperspectral data and unmanned aerial vehicle (UAV) multispectral images. **Computers and Electronics in Agriculture**, v. 151, p. 185-195, Aug. 2018. DOI: [10.1016/j.compag.2018.05.026](https://doi.org/10.1016/j.compag.2018.05.026).
- LIU, Y.; LYU, Q.; HE, S.; YI, S.; LIU, X.; XIE, R.; ZHENG, Y.; DENG, L. Prediction of nitrogen and phosphorus contents in citrus leaves based on hyperspectral imaging. **International Journal of Agricultural and Biological Engineering**, v. 8, n. 2, p. 80-88, Apr. 2015.
- LUZ, P. H. C.; MARIN, M. A.; DEVECHIO, F. F. S.; ROMUALDO, L. M.; ZUÑIGA, A. M. G.; OLIVEIRA, M. W. S.; HERLING, V. R.; BRUNO, O. M. Boron deficiency precisely identified on growth stage V4 of maize crop using texture image analysis. **Communications in Soil Science and Plant Analysis**, v. 49, n. 2, p. 159-169, 2018. DOI: [10.1080/00103624.2017.1421644](https://doi.org/10.1080/00103624.2017.1421644).
- MAIMAITIJIANG, M.; GHULAM, A.; SIDIKE, P.; HARTLING, S.; MAIMAITIYIMING, M.; PETERSON, K.; SHAVERS, E.; FISHMAN, J.; PETERSON, J.; KADAM, S.; BURKEN, J.; FRITSCHI, F. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 134, p. 43-58, Dec. 2017. DOI: [10.1016/j.isprsjprs.2017.10.011](https://doi.org/10.1016/j.isprsjprs.2017.10.011).
- MAO, H.; GAO, H.; ZHANG, X.; KUMI, F. Nondestructive measurement of total nitrogen in lettuce by integrating spectroscopy and computer vision. **Scientia Horticulturae**, v. 184, p. 1-7, Mar. 2015. DOI: [10.1016/j.scienta.2014.12.027](https://doi.org/10.1016/j.scienta.2014.12.027).
- MARESMA, A.; ARIZA, M.; MARTÍNEZ, E.; LLOVERAS, J.; MARTÍNEZ-CASASNOVAS, J. A. Analysis of vegetation indices to determine nitrogen application and yield prediction in Maize (*Zea mays* L.) from a standard UAV service. **Remote Sensing**, v. 8, n. 12, p. 1-15, Dec. 2016. DOI: [10.3390/rs8120973](https://doi.org/10.3390/rs8120973).
- MARESMA, A.; LLOVERAS, J.; MARTÍNEZ-CASASNOVAS, J. A. Use of multispectral airborne images to improve in-season nitrogen management, predict grain yield and estimate economic return of maize in irrigated high yielding environments. **Remote Sensing**, v. 10, n. 4, p. 1-19, Apr. 2018. DOI: [10.3390/rs10040543](https://doi.org/10.3390/rs10040543).
- MEGGIO, F.; ZARCO-TEJADA, P. J.; NÚÑEZ, L. C.; SEPULCRE-CANTÓ, G.; GONZÁLEZ, M. R.; MARTÍN, P. Grape quality assessment in vineyards affected by iron deficiency chlorosis using narrow-band physiological remote sensing indices. **Remote Sensing of Environment**, v. 114, n. 9, p. 1968-1986, Sept. 2010. DOI: [10.1016/j.rse.2010.04.004](https://doi.org/10.1016/j.rse.2010.04.004).
- MERCADO-LUNA, A.; RICO-GARCÍA, E.; LARA-HERRERA, A.; SOTO-ZARAZÚA, G.; OCAMPO-VELÁZQUEZ, R.; GUEVARA-GONZÁLEZ, R.; HERRERA-RUIZ, G.; TORRES-PACHECO, I. Nitrogen determination on tomato (*Lycopersicon esculentum* Mill.) seedlings by color image analysis (RGB). **African Journal of Biotechnology**, v. 9, n. 33, p. 5326-5332, Aug. 2010.
- MOSHOU, D.; BRAVO, C.; WAHLEN, S.; WEST, J.; MCCARTNEY, A.; DE BAERDEMAEKER, J.; RAMON, H. Simultaneous identification of plant stresses and diseases in arable crops using proximal optical sensing and self-organising maps. **Precision Agriculture**, v. 7, n. 3, p. 149-164, July 2006. DOI: [10.1007/s11119-006-9002-0](https://doi.org/10.1007/s11119-006-9002-0).
- MUÑOZ-HUERTA, R. F.; GUEVARA-GONZALEZ, R. G.; CONTRERAS-MEDINA, L. M.; TORRES-PACHECO, I.; PRADO-OLIVAREZ, J.; OCAMPO-VELAZQUEZ, R. V. A

- review of methods for sensing the nitrogen status in plants: advantages, disadvantages and recent advances. **Sensors**, v. 13, n. 8, p. 10823-10843, Aug. 2013. DOI: [10.3390/s130810823](https://doi.org/10.3390/s130810823).
- NAUŠ, J.; PROKOPOVÁ, J.; REBÍČEK, J.; ŠPUNDOVÁ, M. SPAD chlorophyll meter reading can be pronouncedly affected by chloroplast movement. **Photosynthesis Research**, v. 105, n. 3, p. 265-271, Dec. 2010. DOI: [10.1007/s11120-010-9587-z](https://doi.org/10.1007/s11120-010-9587-z).
- NIGON, T. J.; MULLA, D. J.; ROSEN, C. J.; COHEN, Y.; ALCHANATIS, V.; KNIGHT, J.; RUD, R. Hyperspectral aerial imagery for detecting nitrogen stress in two potato cultivars. **Computers and Electronics in Agriculture**, v. 112, p. 36-46, Mar. 2015. DOI: [10.1016/j.compag.2014.12.018](https://doi.org/10.1016/j.compag.2014.12.018).
- NOH, H. K.; ZHANG, Q.; HAN, S.; SHIN, B.; REUM, D. Dynamic calibration and image segmentation methods for multispectral imaging crop nitrogen deficiency sensors. **Transactions of the ASAE**, v. 48, n. 1, p. 393-401, Jan./Feb. 2005. DOI: [10.13031/2013.17933](https://doi.org/10.13031/2013.17933).
- NOH, H. K.; ZHANG, Q.; SHIN, B. S.; HAN, S. **Multispectral image sensor for detection of nitrogen deficiency in corn by using an empirical line method**. [S.l.: s.n., 2003]. Trabalho apresentado na ASAE annual international meeting, 2003, Las Vegas. Article 031135. DOI: [10.13031/2013.13743](https://doi.org/10.13031/2013.13743).
- NUTINI, F.; CONFALONIERI, R.; CREMA, A.; MOVEDI, E.; PALEARI, L.; STAVRAKOUDIS, D.; BOSCHETTI, M. An operational workflow to assess rice nutritional status based on satellite imagery and smartphone apps. **Computers and Electronics in Agriculture**, v. 154, p. 80-92, Nov. 2018. DOI: [10.1016/j.compag.2018.08.008](https://doi.org/10.1016/j.compag.2018.08.008).
- PAGOLA, M.; ORTIZ, R.; IRIGOYEN, I.; BUSTINCE, H.; BARRENECHEA, E.; APARICIO-TEJO, P.; LAMSFUS, C.; LASA, B. New method to assess barley nitrogen nutrition status based on image colour analysis: comparison with SPAD-502. **Computers and Electronics in Agriculture**, v. 65, n. 2, p. 213-218, Mar. 2009. DOI: [10.1016/j.compag.2008.10.003](https://doi.org/10.1016/j.compag.2008.10.003).
- QUEMADA, M.; GABRIEL, J. L.; ZARCO-TEJADA, P. Airborne hyperspectral images and ground-level optical sensors as assessment tools for maize nitrogen fertilization. **Remote Sensing**, v. 6, n. 4, p. 2940-2962, Apr. 2014. DOI: [10.3390/rs6042940](https://doi.org/10.3390/rs6042940).
- RANGEL, B. M. S.; FERNÁNDEZ, M. A. A.; MURILLO, J. C.; ORTEGA, J. C. P.; ARREGUÍN, J. M. R. KNN-based image segmentation for grapevine potassium deficiency diagnosis. In: International Conference on Electronics, Communications and Computers, 2016, Cholula Puebla. **Proceedings...** Piscataway: IEEE, 2016. p. 48-53. DOI: [10.1109/CONIELECOMP.2016.7438551](https://doi.org/10.1109/CONIELECOMP.2016.7438551).
- REISIG, D. D.; GODFREY, L. D. Remotely sensing arthropod and nutrient stressed plants: a case study with nitrogen and cotton aphid (*Hemiptera: Aphididae*). **Environmental Entomology**, v. 39, n. 4, p. 1255-1263, Aug. 2010. DOI: [10.1603/EN09218](https://doi.org/10.1603/EN09218).
- ROMUALDO, L. M.; LUZ, P. H. DE C.; BAESSO, M. M.; DEVECHIO, F. F. DA S.; BET, J. A. Spectral indexes for identification of nitrogen deficiency in maize. **Revista Ciência Agronômica**, v. 49, n. 2, p. 183-191, Apr./June 2018. DOI: [10.5935/1806-6690.20180021](https://doi.org/10.5935/1806-6690.20180021).
- RORIE, R. L.; PURCELL, L. C.; KARCHER, D. E.; KING, C. A. Assessment of leaf nitrogen in corn from digital images. **Crop Science**, v. 51, n. 5, p. 2174-2180, Sept. 2011. DOI: [10.2135/cropsci2010.12.0699](https://doi.org/10.2135/cropsci2010.12.0699).
- ROUSE JUNIOR, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3., 1973, Washington, DC. **Proceedings...** Washington, DC.: NASA, 1974. v. 1, p. 309-317.
- SABERIOON, M. M.; AMIN, M. S. M.; AIMRUN, W.; GHOLIZADEH, A.; ANUAR, A. A. R. Assessment of colour indices derived from conventional digital camera for determining nitrogen status in rice plants. **Journal of Food, Agriculture & Environment**, v. 11, n. 2, p. 655-662, 2013. DOI: [10.1234/4.2013.4391](https://doi.org/10.1234/4.2013.4391).
- SABERIOON, M. M.; GHOLIZADEH, A. Novel approach for estimating nitrogen content in paddy fields using low altitude remote sensing system. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLI-B1, p. 1011-1015, 2016. DOI: [10.5194/isprsarchives-XLI-B1-1011-2016](https://doi.org/10.5194/isprsarchives-XLI-B1-1011-2016).
- SANKARAN, S.; ZHOU, J.; KHOT, L. R.; TRAPP, J. J.; MNDOLWA, E.; MIKLAS, P. N. High-throughput field phenotyping in dry bean using small unmanned aerial vehicle based multispectral imagery. **Computers and Electronics in Agriculture**, v. 151, p. 84-92, Aug. 2018. DOI: [10.1016/j.compag.2018.05.034](https://doi.org/10.1016/j.compag.2018.05.034).
- SANYAL, P.; BHATTACHARYA, U.; PARUI, S. K.; BANDYOPADHYAY, S. K.; PATEL, S. Color Texture Analysis of Rice Leaves Diagnosing Deficiency in the Balance of Mineral Levels towards Improvement of Crop Productivity. In: International Conference on Information Technology, 10, 2007, Rourkela. **Proceedings...** Piscataway: IEEE, 2007. p. 85-90. DOI: [10.1109/ICIT.2007.40](https://doi.org/10.1109/ICIT.2007.40).
- SCHARF, P. C.; LORY, J. A. Calibrating corn color from aerial photographs to predict sidedress nitrogen need. **Agronomy Journal**, v. 94, n. 3, p. 397-404, May 2002. DOI: [10.2134/agronj2002.3970](https://doi.org/10.2134/agronj2002.3970).
- SCHIRRMANN, M.; GIEBEL, A.; GLEINIGER, F.; PFLANZ, M.; LENTSCHKE, J.; DAMMER, K. H. Monitoring

- agronomic parameters of winter wheat crops with low-cost UAV imagery. **Remote Sensing**, v. 8, n. 9, Sept. 2016. DOI: [10.3390/rs8090706](https://doi.org/10.3390/rs8090706).
- SCHMIDT, S. B.; PEDAS, P.; LAURSEN, K. H.; SCHJOERRING, J. K.; HUSTED, S. Latent manganese deficiency in barley can be diagnosed and remediated on the basis of chlorophyll *a* fluorescence measurements. **Plant and Soil**, v. 372, n. 1-2, p. 417-429, Nov. 2013. DOI: [10.1007/s11104-013-1702-4](https://doi.org/10.1007/s11104-013-1702-4).
- SCHUERGER, A. C.; CAPELLE, G. A.; DI BENEDETTO, J. A.; MAO, C.; THAI, C. N.; EVANS, M. D.; RICHARDS, J. T.; BLANK, T. A.; STRYJEWski, E. C. Comparison of two hyperspectral imaging and two laser-induced fluorescence instruments for the detection of zinc stress and chlorophyll concentration in bahia grass (*Paspalum notatum* Flugge.). **Remote Sensing of Environment**, v. 84, n. 4, p. 572-588, Apr. 2003. DOI: [10.1016/S0034-4257\(02\)00181-5](https://doi.org/10.1016/S0034-4257(02)00181-5).
- SEVERTSON, D.; CALLOW, N.; FLOWER, K.; NEUHAUS, A.; OLEJNIK, M.; NANSEN, C. Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola. **Precision Agriculture**, v. 17, n. 6, p. 659-677, Dec. 2016. DOI: [10.1007/s11119-016-9442-0](https://doi.org/10.1007/s11119-016-9442-0).
- SHAFIEKHANI, A.; KADAM, S.; FRITSCHI, F. B.; DESOUZA, G. N. Vinobot and Vinoculer: two robotic platforms for high-throughput field phenotyping. **Sensors**, v. 17, n. 1, p. 1-16, Jan. 2017. DOI: [10.3390/s17010214](https://doi.org/10.3390/s17010214).
- SHOU, L.; JIA, L.; CUI, Z.; CHEN, X.; ZHANG, F. Using high-resolution satellite imaging to evaluate nitrogen status of winter wheat. **Journal of Plant Nutrition**, v. 30, n. 10, p. 1669-1680, 2007. DOI: [10.1080/01904160701615533](https://doi.org/10.1080/01904160701615533).
- SILVA, F. DE F. DA; LUZ, P. H. C.; ROMUALDO, L. M.; MARIN, M. A.; ZÚÑIGA, A. M. G.; HERLING, V. R.; BRUNO, O. M. A diagnostic tool for magnesium nutrition in maize based on image analysis of different leaf sections. **Crop Science**, v. 54, p. 738-745, Mar./Apr. 2014. DOI: [10.2135/cropsci2013.03.0165](https://doi.org/10.2135/cropsci2013.03.0165).
- SIMS, N. C.; CULVENOR, D.; NEWNHAM, G.; COOPS, N. C.; HOPMANS, P. Towards the operational use of satellite hyperspectral image data for mapping nutrient status and fertilizer requirements in Australian plantation forests. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 2, p. 320-328, Apr. 2013. DOI: [10.1109/JSTARS.2013.2251610](https://doi.org/10.1109/JSTARS.2013.2251610).
- SINGH, A. K.; GANAPATHYSUBRAMANIAN, B.; SARKAR, S.; SINGH, A. Deep learning for plant stress phenotyping: trends and future perspectives. **Trends in Plant Science**, v. 23, n. 10, p. 883-898, Oct. 2018. DOI: [10.1016/j.tplants.2018.07.004](https://doi.org/10.1016/j.tplants.2018.07.004).
- SINGH, N.; CASADY, W. W.; COSTELLO, T. A. Machine-vision-based nitrogen management models for rice. **Transactions of ASAE**, v. 39, n. 5, p. 1899-1904, 1996. DOI: [10.13031/2013.27668](https://doi.org/10.13031/2013.27668).
- SRIPADA, R. P.; FARRER, D. C.; WEISZ, R.; HEINIGER, R. W.; WHITE, J. G. Aerial color infrared photography to optimize in-season nitrogen fertilizer recommendations in winter wheat. **Agronomy Journal**, v. 99, p. 1424-1435, Nov. 2007. DOI: [10.2134/agronj2006.0258](https://doi.org/10.2134/agronj2006.0258).
- STORY, D.; KACIRA, M.; KUBOTA, C.; AKOGLU, A.; AN, L. Lettuce calcium deficiency detection with machine vision computed plant features in controlled environments. **Computers and Electronics in Agriculture**, v. 74, v. 2, p. 238-243, Nov. 2010. DOI: [10.1016/j.compag.2010.08.010](https://doi.org/10.1016/j.compag.2010.08.010).
- SULISTYO, S. B.; WOO, W. L.; DLAY, S. S. Regularized neural networks fusion and genetic algorithm based on-field nitrogen status estimation of wheat plants. **IEEE Transactions on Industrial Informatics**, v. 13, n. 1, p. 103-114, Feb. 2017. DOI: [10.1109/TII.2016.2628439](https://doi.org/10.1109/TII.2016.2628439).
- SULISTYO, S. B.; WU, D.; WOO, W. L.; DLAY, S. S.; GAO, B. Computational deep intelligence vision sensing for nutrient content estimation in agricultural automation. **IEEE Transactions on Automation Science and Engineering**, v. 15, n. 3, p. 1243-1257, July 2018. DOI: [10.1109/TASE.2017.2770170](https://doi.org/10.1109/TASE.2017.2770170).
- SUMMY, K. R.; LITTLE, C. R.; MAZARIEGOS, R. A.; EVERITT, J. H.; DAVIS, M. R.; FRENCH, J. V.; SCOTT JUNIOR, A. W. Detecting stress in glasshouse plants using color infrared imagery: a potential new application for remote sensing. **Subtropical Plant Science**, v. 55, p. 51-58, 2003.
- SUN, Y.; GAO, J.; WANG, K.; SHEN, Z.; CHEN, L. Utilization of machine vision to monitor the dynamic responses of rice leaf morphology and colour to nitrogen, phosphorus, and potassium deficiencies. **Journal of Spectroscopy**, v. 2018, p. 1-13, 2018a. DOI: [10.1155/2018/1469314](https://doi.org/10.1155/2018/1469314).
- SUN, Y.; TONG, C.; HE, S.; WANG, K.; CHEN, L. Identification of nitrogen, phosphorus, and potassium deficiencies based on temporal dynamics of leaf morphology and color. **Sustainability**, v. 10, n. 3, p. 1-15, Mar. 2018b. DOI: [10.3390/su10030762](https://doi.org/10.3390/su10030762).
- SUN, Y.; ZHU, S.; YANG, X.; WESTON, M. V.; WANG, K.; SHEN, Z.; XU, H.; CHEN, L. Nitrogen diagnosis based on dynamic characteristics of rice leaf image. **Plos One**, v. 13, n. 4, p. 1-15, 2018c. DOI: [10.1371/journal.pone.0196298](https://doi.org/10.1371/journal.pone.0196298).
- SWAIN, K. C.; JAYASURIYA, H. P. W.; SALOKHE, V. M. Suitability of low-altitude remote sensing images for estimating nitrogen treatment variations in rice cropping for precision agriculture adoption. **Journal of Applied**

- Remote Sensing, v. 1, n. 1, p. 1-11, Jan. 2007. DOI: [10.1117/1.2824287](https://doi.org/10.1117/1.2824287).
- TEWARI, V. K.; ARUDRA, A. K.; KUMAR, S. P.; PANDEY, V.; CHANDEL, N. S. Estimation of plant nitrogen content using digital image processing. **Agricultural Engineering International: CIGR Journal**, v. 15, n. 2, p. 78-86, July 2013.
- UDDLING, J.; GELANG-ALFREDSSON, J.; PIIKKI, K.; PLEIJEL, H. Evaluating the relationship between leaf chlorophyll concentration and SPAD-502 chlorophyll meter readings. **Photosynthesis Research**, v. 91, n. 1, p. 37-46, Jan. 2007. DOI: [10.1007/s11120-006-9077-5](https://doi.org/10.1007/s11120-006-9077-5).
- VAKILIAN, K. A.; MASSAH, J. A farmer-assistant robot for nitrogen fertilizing management of greenhouse crops. **Computers and Electronics in Agriculture**, v. 139, p. 153-163, June 2017. DOI: [10.1016/j.compag.2017.05.012](https://doi.org/10.1016/j.compag.2017.05.012).
- VAKILIAN, K. A.; MASSAH, J. Design, Development and performance evaluation of a robot to early detection of nitrogen deficiency in greenhouse cucumber (*Cucumis sativus*) with machine vision. **International Journal of Agriculture: Research and Review**, v. 2, n. 4, p. 448-454, 2012.
- VEGA, F. A.; RAMÍREZ, F. C.; SAIZ, M. P.; ROSÚA, F. O. Multi-temporal imaging using an unmanned aerial vehicle for monitoring a sunflower crop. **Biosystems Engineering**, v. 132, p. 19-27, Apr. 2015. DOI: [10.1016/j.biosystemseng.2015.01.008](https://doi.org/10.1016/j.biosystemseng.2015.01.008).
- VIGNEAU, N.; ECARNOT, M.; RABATEL, G.; ROUMET, P. Potential of field hyperspectral imaging as a non destructive method to assess leaf nitrogen content in wheat. **Field Crops Research**, v. 122, n. 1, p. 25-31, Apr. 2011. DOI: [10.1016/j.fcr.2011.02.003](https://doi.org/10.1016/j.fcr.2011.02.003).
- WANG, Y.; WANG, D.; SHI, P.; OMASA, K. Estimating rice chlorophyll content and leaf nitrogen concentration with a digital still color camera under natural light. **Plant Methods**, v. 10, p. 1-11, 2014. DOI: [10.1186/1746-4811-10-36](https://doi.org/10.1186/1746-4811-10-36).
- WANG, Y.; WANG, D.; ZHANG, G.; WANG, J. Estimating nitrogen status of rice using the image segmentation of G-R thresholding method. **Field Crops Research**, v. 149, p. 33-39, Aug. 2013. DOI: [10.1016/j.fcr.2013.04.007](https://doi.org/10.1016/j.fcr.2013.04.007).
- WATTS, A. C.; AMBROSIA, V. G.; HINKLEY, E. A. Unmanned aircraft systems in remote sensing and scientific research: classification and considerations of use. **Remote Sensing**, v. 4, n. 6, p. 1671-1692, June 2012. DOI: [10.3390/rs4061671](https://doi.org/10.3390/rs4061671).
- WEI, Y.; LI, M.; SIGRIMIS, N. Estimating nitrogen content of cucumber leaves based on NIR spectroscopy. **Sensor Letters**, v. 8, n. 1, p. 145-150, Feb. 2010. DOI: [10.1166/sl.2010.1217](https://doi.org/10.1166/sl.2010.1217).
- WEN, D.; TONGYU, X.; FENGHUA, Y.; CHUNLING, C. Measurement of nitrogen content in rice by inversion of hyperspectral reflectance data from an unmanned aerial vehicle. **Ciência Rural**, v. 48, n. 6, p. 1-10, 2018. DOI: [10.1590/0103-8478cr20180008](https://doi.org/10.1590/0103-8478cr20180008).
- WILLIAMS, J. D.; KITCHEN, N. R.; SCHARF, P. C.; STEVENS, W. E. Within-field nitrogen response in corn related to aerial photograph color. **Precision Agriculture**, v. 11, n. 3, p. 291-305, June 2010. DOI: [10.1007/s11119-009-9137-x](https://doi.org/10.1007/s11119-009-9137-x).
- WIWART, M.; FORDOŃSKI, G.; ŻUK-GOŁASZEWSKA, K.; SUCHOWILSKA, E. Early diagnostics of macronutrient deficiencies in three legume species by color image analysis. **Computers and Electronics in Agriculture**, v. 65, n. 1, p. 125-132, Jan. 2009. DOI: [10.1016/j.compag.2008.08.003](https://doi.org/10.1016/j.compag.2008.08.003).
- WU, J.; WANG, D.; ROSEN, C. J.; BAUER, M. E. Comparison of petiole nitrate concentrations, SPAD chlorophyll readings, and QuickBird satellite imagery in detecting nitrogen status of potato canopies. **Field Crops Research**, v. 101, n. 1, p. 96-103, Feb. 2007. DOI: [10.1016/j.fcr.2006.09.014](https://doi.org/10.1016/j.fcr.2006.09.014).
- XU, G.; ZHANG, F.; SHAH, S. G.; YE, Y.; MAO, H. Use of leaf color images to identify nitrogen and potassium deficient tomatoes. **Pattern Recognition Letters**, v. 32, n. 11, p. 1584-1590, Aug. 2011. DOI: [10.1016/j.patrec.2011.04.020](https://doi.org/10.1016/j.patrec.2011.04.020).
- YAKUSHEV, V. P.; KANASH, E. V. Evaluation of wheat nitrogen status by colorimetric characteristics of crop canopy presented in digital images. **Journal of Agricultural Informatics**, v. 7, n. 1, p. 65-74, 2016. DOI: [10.17700/jai.2016.7.1.268](https://doi.org/10.17700/jai.2016.7.1.268).
- YAO, X.; LUO, W. Foliar image color features for rubber nitrogen deficiency status analysis. **Advanced Materials Research**, v. 488-489, p. 1674-1679, 2012. DOI: [10.4028/www.scientific.net/AMR.488-489.1674](https://doi.org/10.4028/www.scientific.net/AMR.488-489.1674).
- YU, K. Q.; ZHAO, Y. R.; LI, X. L.; SHAO, Y. N.; LIU, F.; HE, Y. Hyperspectral imaging for mapping of total nitrogen spatial distribution in pepper plant. **Plos One**, v. 9, n. 12, p. 1-19, 2014. DOI: [10.1371/journal.pone.0116205](https://doi.org/10.1371/journal.pone.0116205).
- YUAN, Y.; CHEN, L.; LI, M.; WU, N.; WAN, L.; WANG, S. Diagnosis of nitrogen nutrition of rice based on image processing of visible light. In: IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications, 2016, Qingdao. [Proceedings...]. Piscataway: IEEE, 2016. p. 228-232. DOI: [10.1109/FSPMA.2016.7818311](https://doi.org/10.1109/FSPMA.2016.7818311).
- YUZHU, H.; XIAOMEI, W.; SHUYAO, S. Nitrogen determination in pepper (*Capsicum frutescens* L.) plants by color image analysis (RGB). **African Journal of Biotechnology**, v. 10, n. 77, p. 17737-17741, Dec. 2011. DOI: [10.5897/AJB11.1974](https://doi.org/10.5897/AJB11.1974).