



Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios

Monitoring Plant Health Using Remote Sensing: Advances and Challenges

Pedro Paulo da Silva Barros ¹, David Luciano Rosalen ², Fernando Henrique Iost Filho ³, George Deroco Martins ⁴ e Néstor Di Leo ⁵

1 Universidade Federal de Uberlândia, Faculdade de Engenharia Civil, Monte Carmelo, Brasil. pedropaulo.barros@ufu.br.

ORCID: <https://orcid.org/0000-0002-4941-1746>

2 Universidade Estadual Paulista, Departamento de Engenharia e Ciências Exatas, Jaboticabal, Brasil. david.rosalen@unesp.br.

ORCID: <https://orcid.org/0000-0003-1759-9673>

3 Universidade de São Paulo, Departamento de Entomologia e Acarologia, Piracicaba, Brasil. fernandohiost@usp.br.

ORCID: <https://orcid.org/0000-0002-9116-5104>

4 Universidade Federal de Uberlândia, Faculdade de Engenharia Civil, Monte Carmelo, Brasil. deroco@ufu.br.

ORCID: <https://orcid.org/0000-0001-9738-7325>

5 Universidad Nacional de Rosario, Centro de Estudios Territoriales, Rosário, Argentina. ndileo@unr.edu.ar.

ORCID: <https://orcid.org/0000-0001-7872-9692>

Recebido: 08.2020 | Aceito: 11.2020

Resumo: Problemas fitossanitários, como doenças, pragas e plantas daninhas, que competem com as plantas cultivadas por recursos e, conseqüentemente, prejudicam seu pleno desenvolvimento, são responsáveis por perdas significativas no setor agrícola, ano após ano. Portanto, conhecer o status sanitário da lavoura é um fator crucial no planejamento de ações de manejo, além de embasar políticas públicas de investimento e de proteção, a serem adotadas, com o objetivo de prevenir perdas produtivas e de assegurar a segurança alimentar da nação. Quando expostas a esses problemas, as plantas ativam respostas de defesa, cujos mecanismos moleculares são muito complexos. Nos estágios iniciais de um ataque de pragas ou de uma doença, embora os sintomas ainda não sejam visíveis no dossel, as plantas reagem com diferentes mecanismos fisiológicos, tais como a redução da taxa de fotossíntese, que induz a um aumento da fluorescência e da emissão de calor. Dessa forma, plantas estressadas produzem uma assinatura espectral que difere da assinatura de uma planta saudável. Dentro do Sensoriamento Remoto, inúmeras pesquisas têm estudado a relação entre diferentes problemas fitossanitários com a resposta espectral registrada em sensores multi ou hiperespectrais (sejam imageadores ou não imageadores, ativos ou passivos e embarcados em plataformas terrestres, aéreas ou orbitais). Nesse contexto, o objetivo desta revisão é descrever o estado da arte da tecnologia de Sensoriamento Remoto aplicada a aspectos fitossanitários de lavouras, nos níveis de coleta de dados terrestre, aéreo e orbital, envolvendo diferentes modalidades de sensores.

Palavras-chave: Fotogrametria. Drone. Radar de abertura sintética. Agricultura. Estresse vegetal. Resposta espectral.

Abstract: Problems concerning plant health, such as diseases, pests and weeds, which compete with grown plants for resources and, therefore, harm their full development, are responsible for significant losses in agriculture, year after year. Thus, it is extremely important to know the health status of the crops to plan management actions, in addition to serving as a basis for public investment and protection policies, aiming to reduce losses in production and guarantee national food security. When exposed to such problems, plants activate defense responses, whose molecular mechanism are too complex. In the early stages of pest or disease establishment, although symptoms are not yet visible, plants react in a variety of physiological mechanisms, such as reducing photosynthesis, which leads to increased fluorescence and heat emission. Thus, stressed plants produce a different spectral signature than that produced by healthy plants. In the field of Remote Sensing, a lot of studies have demonstrated the relationship between plant health issues and the spectral response registered in multi and hyperspectral sensors (whether imaging or not, active or passive and attached to terrestrial, aerial or orbital platforms). Therefore, the objective of this review is to describe the state of the art of Remote Sensing technology applied to health status of cultivated plants, at the levels of terrestrial, aerial and orbital data collection, using different types of sensors.

Keywords: Photogrammetry. Drone. Synthetic-aperture radar. Agriculture. Plant stress. Spectral response.

1 INTRODUÇÃO

A agricultura moderna fornece calorias além do suficiente para a humanidade, mas cerca de 800 milhões de pessoas permanecem subnutridas e, aproximadamente, 2 bilhões sofrem de deficiências de micronutrientes (TULCHINSKY, 2010). Além disso, projeta-se que a população mundial atinja, em 2050, quase 10 bilhões de pessoas, e mais de 11 bilhões em 2100 (UNITED NATIONS, 2017). Consequentemente, com o aumento da riqueza, ocorre também maior consumo per capita de carne, açúcares refinados, alcoóis e óleos, cuja produção consome mais recursos ou tem valor nutricional limitado do que dietas compostas de grãos, legumes, frutas e vegetais (TILMAN; CLARK, 2014). Portanto, há uma pressão crescente sobre a agricultura para suprir às necessidades atuais e futuras da população. As projeções indicam que será necessário o acréscimo de 70% da produção de alimentos até 2050 para atender às necessidades (GODFRAY et al., 2010).

Os elementos da segurança alimentar, que abrange a disponibilidade de alimentos (ou seja, produção, importação, reservas), acesso físico e econômico aos alimentos, e a utilização de alimentos (ou seja, valor nutritivo, segurança) foram revisados, sendo que perdas de safra causadas por pragas e doenças agrícolas afetam diretamente esses componentes (INGRAM, 2011; MUTANGA; DUBE; GALAL, 2017). Da escala global à local, a produção de alimentos está enfrentando desafios fitossanitários, que têm o potencial de afetar contínuas safras na mais ampla variedade de cultivos, resultando em perdas expressivas de rendimento. A fim de mitigar os danos causados por doenças nas culturas durante o crescimento, a colheita e o processamento pós-colheita, bem como maximizar a produtividade e garantir a sustentabilidade agrícola, a detecção e a prevenção avançadas de estressores nas culturas são extremamente importantes, sejam eles pragas, doenças ou plantas daninhas.

Ressalta-se, portanto, que a detecção, o mapeamento e o monitoramento de pragas, de forma precisa e oportuna, são fundamentais para a segurança alimentar. Culturas de grande área podem ser monitoradas de forma síncrona, e informações de safra em tempo real podem ser obtidas por tecnologias de sensoriamento remoto. Essas tecnologias fornecem uma maneira poderosa, rápida e econômica de alcançar o monitoramento em tempo real e preciso da colheita, das doenças e das pragas (ZHANG et al., 2019).

Dessa maneira, o sensoriamento remoto tornou-se uma ciência de extrema importância para a agricultura, que permite expandir nossa capacidade de tomada de decisão ao quantificar parâmetros agronômicos a partir de informações georreferenciadas com repetitividade e ótimo custo-benefício (MUTANGA; DUBE; GALAL, 2017). O princípio básico do sensoriamento remoto é de captar a energia eletromagnética refletida pela vegetação ou dossel que pode ser alterada por mudanças ocasionadas por pragas, como, por exemplo, nos pigmentos, concentrações químicas, estrutura celular, nutrientes, troca gasosa e conteúdo de água que influenciam diretamente na coloração e na temperatura da vegetação (JENSEN, 2009).

Uma ampla gama de sensores está disponível atualmente, os quais podem ser potencialmente aplicados para detectar e monitorar pragas. Sendo classificados segundo Novo (2010) quanto à fonte de radiação, passivo ou ativo, esses sensores permitem a aquisição de dados que variam no espectro eletromagnético além das conceituadas faixas do visível, infravermelho próximo e termal, analisando de raios gama a micro-ondas.

Nesse processo, conexões entre metodologias de sensoriamento remoto e teorias fitossanitárias foram reforçadas, melhorando assim nossa compreensão do sistema agrícola em todos os aspectos, a partir de avançados métodos estatísticos multivariados que têm como característica principal a extração e a modelagem dos dados espectrais, incluindo algumas novas técnicas de processamento de sinal e algoritmos de *machine learning*. Os resultados e os modelos desses métodos estatísticos não podem ser aplicados sem se analisar a metodologia utilizada para a obtenção dos dados, pois a escala de observação, o tipo de vegetação, as bandas espectrais e a sofisticação dos modelos variam, sendo que cada procedimento e sensor requer otimização específica. Para tanto, fatores como localização geográfica, tipo de vegetação e as condições de iluminação para o momento da aquisição de dados devem ser levados em consideração na escolha do método de análise (ZHANG et al., 2015). Além disso, fatores como resolução espacial, resolução espectral, repetibilidade temporal dos dados de reflectância influenciam profundamente a qualidade dos dados espectrais e, portanto, a capacidade de desenvolver modelos e algoritmos de classificação robustos e confiáveis (NANSEN, 2016).

Nesta revisão, com base em uma completa análise e levantamento de literatura, resumiram-se as realizações de pesquisa de ponta na área do sensoriamento remoto, aplicadas para monitorar pragas de plantas,

incluindo as potenciais tendências futuras e os desafios dessas técnicas. O restante desta revisão está estruturado da seguinte maneira: a seção 2 fornece as definições e a base teórica na área do sensoriamento remoto; a seção 3 identifica e descreve trabalhos com sensores multiespectrais; a seção 4 examina trabalhos utilizando sensores hiperespectrais, enquanto a seção 5 aborda os trabalhos com sensores ativos, do tipo *Radio Detection And Ranging* (RADAR) e *Light Detection And Ranging* (LIDAR). Por fim, a seção 6 apresenta uma discussão dos avanços e desafios dessa técnica. Destaca-se que não se priorizou alguma cultura em especial, mas a relevância do trabalho, levando-se em consideração algoritmos de classificação própria da base de dados. Também, majoritariamente, utilizaram-se artigos publicados em periódicos científicos revisados por pares.

2 DEFINIÇÕES E BASE TEÓRICA

Em um contexto geral, o Sensoriamento Remoto define-se pela aquisição da informação espacial em multiescala (espectral, temporal e espacial) por ondas eletromagnéticas. As ondas eletromagnéticas, ou radiação eletromagnética (REM), é o meio pelo qual a informação é transferida do objeto ao sensor. A REM pode ser definida como uma forma dinâmica de energia que se manifesta a partir de sua interação com a matéria. A REM é gerada por fontes naturais como o Sol ou a Terra, ou por fontes artificiais, como, por exemplo, o Radar (NOVO, 2010).

Os objetos da superfície terrestre, como a vegetação, a água e o solo, refletem, absorvem e transmitem radiação eletromagnética em proporções que variam com o comprimento de onda, de acordo com suas características biofísicas e químicas (FLORENZANO, 2011). Cada objeto tem sua curva singular de energia no espectro eletromagnético, que é conhecida como assinatura espectral do objeto. Esse caráter pode ser aplicado para identificar os objetos com suas assinaturas espectrais singulares. Geralmente, um conjunto de valores de energia em certas bandas-chave, em determinado objeto detectado pelos sensores de satélite é usado para identificá-lo e separá-lo de outros objetos (LIU, 2015).

Na análise do comportamento espectral, Colwell (1974) afirma que as folhas são os elementos da vegetação que mais contribuem para o sinal detectado por sensores, influenciada principalmente pela morfologia interna (distribuição, quantidade de tecidos e espaços intercelulares), pelo tipo e pela quantidade de pigmentos fotossintetizantes, característicos de cada espécie.

Conceitualmente, os sensores passivos captam a energia eletromagnética natural ou artificial que é refletida ou emitida por objetos que se encontram na superfície física terrestre; em contrapartida, os sistemas ativos não são dependentes da energia eletromagnética do Sol, ou das propriedades termais da Terra, apresentando sua própria fonte de energia (JENSEN, 2009).

De forma geral, os dados de sensoriamento remoto multiescala aplicados às culturas agrícolas são obtidos sob diferentes condições ambientais, definindo variações que podem afetar os resultados de classificações, conduzindo a níveis de acurácia insatisfatórios. A qualidade da informação produzida está vinculada, também, aos processamentos aplicados aos dados provenientes de diferentes sensores remotos (MARTINS et al., 2017).

A resolução espacial está relacionada diretamente com a capacidade de amostragem dos sensores e, indiretamente, com o nível de aquisição de dados. Dados medidos *in situ* ou em laboratório, com campo de visada restrito, conseguem capturar condições específicas da folha, enquanto sensores imageadores, instalados em plataformas remotas, determinam uma área de amostragem maior na superfície terrestre. Por incorporar, em uma única imagem, a resposta espectral de vários alvos, como o solo e as plantas, imagens aéreas ou orbitais podem indicar a distribuição e a proporção dos diferentes elementos que compõem uma cultura agrícola. Ou seja, a partir da caracterização espectral das culturas saudáveis e aquelas infectadas, dados multiescala de sensoriamento remoto permitem inferir graus de sanidade para as plantas (MARTINS et al., 2017).

A integração de diferentes tipos de dados de sensoriamento remoto obtidos em multiescala, com vistas ao monitoramento e ao mapeamento de culturas agrícolas infectadas por parasitas, encontra-se em constante avanço. Isso ocorre devido à grande quantidade de dados obtidos por intermédio de plataformas terrestres, aéreas e orbitais, disponibilizando produtos radiométricos oriundos de fontes diversas (ASHOORLOO et al., 2013).

Neste contexto, os sistemas multiespectrais registram a energia refletida ou emitida de um alvo da superfície física terrestre em múltiplas bandas do espectro eletromagnético de ondas curtas. Conceitualmente, os sensores registram a energia no comprimento de onda óptico, medida em nanômetros, que é refletida, espalhada, transmitida ou absorvida pelas camadas mais exteriores de folhas e de galhos do dossel da cultura vegetal. Dependendo da resolução espacial, é comum obter-se pouca informação sobre as características internas do dossel, e menos ainda sobre as características superficiais do solo, abaixo do dossel.

Atualmente, uma série de novos sensores multiespectrais instalados em plataformas espaciais incluem bandas espectrais específicas e apropriadas para monitorar atividades agrícolas. Sensores embarcados em satélites, como RapidEye e o WorldView 2 e 3, dispõem de uma banda espectral no vermelho limítrofe, a qual é capaz de detectar variações sutis de clorofila nas folhas e de fornecer informações sobre a estrutura e a condição sanitária da vegetação (ADELABU; MUTANGA; ADAM, 2012). Além do mais, índices de vegetação, calculados a partir da reflectância das bandas do infravermelho próximo e do vermelho limítrofe, podem fornecer estimativas mais precisas da concentração de clorofila do que no *Normalized Difference Vegetation Index* (NDVI), derivado da reflectância da banda do vermelho centrada no intervalo de absorção da clorofila a e b entre 660 e 680 nm (CHO et al., 2012).

Em adicional, os sistemas hiperespectrais coletam dados em centenas ou em milhares de bandas, podendo ser instalados em plataformas terrestres, conhecidos como espectrorradiômetros, ou em plataformas aéreas e orbitais, como sistemas imageadores. Os dados hiperespectrais possibilitam uma caracterização minuciosa e detalhada de alvos agrícolas, podendo assim determinar intervalos espectrais específicos para detecção de doenças e de sintomas relacionados a patógenos em lavouras diversas sob condições características. Além do mais, podem ser utilizados na calibração de sensores remotos, além de fornecer dados espectrais únicos que contribuem na extração de informações baseadas em dados gerados por sensores remotos multiespectrais e hiperespectrais (MARTINS et al., 2017). Os sensores remotos ativos geram sua própria energia eletromagnética, que é transmitida do sensor para a superfície do terreno e é pouco afetada pela atmosfera, onde interage com os objetos produzindo um retroespalhamento da energia, que é registrada pelo receptor do sensor remoto. Os sistemas de sensoriamento remoto ativos mais amplamente utilizados incluem: RADAR, LIDAR e *Sound Navigation and Ranging* (SONAR).

Dos três sistemas, o RADAR é o mais amplamente utilizado para estudos de vegetação e dos sistemas agrícolas. A energia de micro-ondas ativas pode penetrar o dossel em profundidades variadas, dependendo de variáveis como: modo, frequência, polarização e do ângulo de incidência do sistema de RADAR. A energia de micro-ondas responde a objetos situados na estrutura da vegetação que tenham tamanhos de centímetros até de decímetros. É importante identificar a relação entre os componentes do dossel e como eles influenciam no retroespalhamento de RADAR (JENSEN, 2009).

No momento em que o RADAR envia um pulso de energia de micro-ondas com polarização horizontal ou vertical em direção a um conjunto de árvores, ele interage com os componentes presentes e espalha parte da energia de volta para o sensor. A quantidade de energia recebida é proporcional à natureza da energia enviada (suas frequência e polarização) e depende da ocorrência ou não de despolarização do sinal pelos componentes do dossel, de quanto o sinal penetra no dossel, e se ele, eventualmente, interage com a superfície do solo (JENSEN, 2009).

Neste segmento, diferentes estudos são direcionados para se monitorar quantitativamente a distribuição espacial, a biomassa, a produtividade primária bruta e líquida, e as condições das comunidades globais de vegetação, especialmente das florestas. Além de áreas florestais, também áreas agrícolas, como destacado por Uppala et al. (2016), que indicam que o sensoriamento remoto de micro-ondas, pode oferecer uma abordagem atraente para determinar a variabilidade espacial de diferentes características de cultura agrícolas.


Em termos de estudos fitossanitários, que serão abordados em maiores detalhes na seção 5, as diferentes polarizações e maior resolução espacial (10 m) como a do sensor embarcado no satélite Sentinel 1 A e B, a imagem de RADAR, proveniente de antenas de abertura sintética, pode fornecer alguns dos parâmetros biofísicos relacionados à sanidade da cultura agrícola, tais como: conteúdo de água do dossel, identificação de varietal de cultivares resistentes a doenças, biomassa por componente (folhagem, troncos de ordem superior e

tronco principal), estrutura do dossel (índice de área foliar verde), orientação da folha, geometria e distribuição espacial dos troncos e dos galhos principais, tamanho e distribuição angular dos troncos e galhos (BETBEDER; FIEUZAL; BAUP, 2016).

O *Synthetic Aperture Radar* (SAR) é originário da tecnologia RADAR, um sistema de detecção utilizado em diversas áreas, como na aeronáutica e na meteorologia. Este baseia-se na emissão e na recepção de pulsos de ondas eletromagnéticas (OEM) criados artificialmente. A partir do eco gerado pela interação dessas ondas com o terreno, ou com outros elementos, é possível extrair grande quantidade de informações, como medir distâncias, altitudes, direções e velocidade (RICHARDS, 2009). O SAR é um tipo de RADAR de visão lateral, que mede a distribuição espacial da reflectividade das micro-ondas emitidas na superfície iluminada. Além disso, transmite um pulso e mede o tempo e a intensidade do eco refletido que retorna para ele (ex: medidas de amplitude e de fase). Nele, a relação entre a energia de micro-ondas incidente e a refletida captada pelo sensor, é denominada retrodispersão (MORAN et al., 2002).

Assim, como o RADAR, os sensores do tipo LIDAR também são capazes de mensurar atributos de culturas agrícolas. O instrumento LIDAR consiste em um sistema de controle, transmissor e receptor. Quando a plataforma que comporta o sistema se move pulsos de luz laser (comprimentos de ondas curtas), eles são direcionados ao terreno por um espelho com varredura perpendicular à trajetória, ao passo que a energia retroespalhada retorna ao sensor, formando a imagem (JENSEN, 2009). Em aplicações florestais, com o sistema LIDAR, é possível monitorar elementos estruturais, como a biomassa da vegetação, o volume e a qualidade da madeira. A Figura 1 exibe um exemplo de cada modalidade de sensores, anteriormente citados, que podem ser adaptados para uso em RPA.

Figura 1 – Exemplos de sensores: Sensor óptico multispectral DLS-2, (Micasense, EUA) (a); Sensor óptico hiperespectral HSC-2, (Senop Optronics, Finlândia) (b); Sensor ativo LIDAR Corner Solid State, (Ibeo Automotive Systems, Alemanha) (c) e Sensor ativo RADAR ARX-408 (Continental Engineering Services, Alemanha) (d).



Fonte: Micasense (2020); Senop (2020); Ibeo Automotives (2020); Continental Corporation (2020).

De forma geral, os dados de sensoriamento remoto multiescala, aplicados às culturas agrícolas são obtidos sob diferentes condições ambientais e de imageamento, definindo variações que podem afetar os resultados de classificações, conduzindo a níveis de acurácia insatisfatórios. A qualidade da informação produzida está vinculada, também, aos processamentos aplicados aos dados provenientes de diferentes sensores remotos.

3 SENSORES MULTIESPECTRAIS

Esta seção do artigo tem como objetivo tratar do uso de sensores multiespectrais em aspectos

fitossanitários nas culturas agrícolas. Esses aspectos são aqueles nos quais agentes como insetos, ácaros, nematoides, fungos, bactérias, vírus e plantas daninhas levam à ocorrência de estresse de natureza biótica e, conseqüentemente, à redução da produtividade ou até a perda total da produção. Neste contexto, serão apresentados alguns conceitos sobre estresse biótico e a respectiva detecção destes, utilizando-se de sensores multiespectrais e RGB, embarcados em plataformas orbitais e aéreas. No caso de plataformas aéreas, o enfoque foi em RPAs, tendo-se em vista que, na agricultura, há predominância do uso desta plataforma com relação a aeronaves tripuladas.

Sensores multiespectrais são sensores passivos, na faixa óptica e termal do espectro eletromagnético, imageadores ou não. Na atualidade, são de varredura eletrônica, compostos por dispositivos como CCD (*charge-coupled device*) ou CMOS (*complementary metal-oxide semiconductor*). Inicialmente, na Fotogrametria, as câmeras eram analógicas, e a energia luminosa era registrada nos filmes fotográficos, e toda a energia oriunda do alvo era integralizada em todo o seu espectro, dentro da sensibilidade do filme, que podia abranger o espectro visível ou infravermelho próximo. Dessa forma, informações particulares entre a resposta espectral do alvo com uma banda espectral específica não podiam ser identificadas (NOVO, 2010). Nas câmeras fotográficas, tornaram-se digitais, estas continuaram a integralizar o espectro eletromagnético dentro da faixa do visível ou do infravermelho, conforme o sensor. Destaca-se que essas câmeras são também compostas por dispositivos CCD ou CMOS. Câmeras digitais que registram o espectro visível podem ser denominadas de sensores RGB (*Red/Green/Blue*).

A vantagem dos sensores multiespectrais digitais deve-se ao fato de uma mesma imagem ser registradas, simultaneamente, em várias regiões do espectro eletromagnético, podendo, dessa forma, registrar aspectos da resposta espectral de diferentes alvos, em comprimentos de banda específicos. A maior parte dos programas de sensoriamento remoto espaciais utiliza sensores multiespectrais; inclusive, o primeiro sensor multiespectral, o MSS (*Multispectral Scanner System*), desenvolvido em 1970, foi utilizado na plataforma Landsat 1 (lançado em 1972) ao Landsat 5 (lançado em 1984). O MSS registrava informações espectrais em quatro bandas distintas (verde, vermelha e duas bandas do infravermelho próximo).

Em termos de plataformas, os sensores podem estar embarcados em plataformas orbitais, aéreas ou terrestres. No caso das orbitais, são as missões espaciais com o lançamento de satélites de observação da Terra. As plataformas aéreas podem ser aeronaves tripuladas ou não tripuladas, denominadas de Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft Systems* - RPA). Na atualidade, as RPAs têm tido muito destaque, tendo-se em vista a facilidade e o baixo custo de aquisição e operação. As plataformas terrestres, na área agrícola, poderiam ser tratores, máquinas agrícolas, quadriciclos ou, ainda, veículos terrestres não tripulados especialmente projetados (ROSALEN, 2015).

Com relação às missões espaciais e aos respectivos sensores multiespectrais, atualmente, destacam-se a missão Landsat 8, sensor OLI (*Operational Land Imager*); Sentinel 2A/B, sensor MSI (*Multispectral Instrument*); SPOT 6 e 7, sensor NAOMI; CBERS 4A (parceria sino-brasileira), sensores MUX (câmera multiespectral); WFI (Câmera de Campo Largo), e WPM (Câmera Multiespectral e Pancromática de Ampla Varredura). Além destas, pode-se destacar, também, a plataforma RapidEye, especialmente desenvolvida para monitoramento agrícola. Esta foi adquirida pela BlackBridge e depois pela Planet Labs, que suspendeu a operação da constelação RapidEye, em abril de 2020. A Planet Labs opera constelações de nanossatélites (*CubSat*) de média (constelação Flock) e de alta resoluções (constelação SkySat) com grande potencial para monitoramento agrícola (SABINS; ELLIS, 2020; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2020).

Quanto aos sensores embarcados em RPAs, devido às limitações de carga útil que uma RPA de Classe 3 pode transportar (microvants, de acordo com a ANAC), os mais comuns são as câmeras digitais com boa resolução espacial e sensíveis à faixa do visível (sensores RGB). Algumas dessas câmeras possibilitam intercambiar as lentes do sistema óptico, de maneira a permitir o registro do infravermelho próximo ou outra faixa, conforme o índice de vegetação que se desejava calcular, como o NDVI (*Normalized Difference Vegetation Index*), que podem ter papel fundamental na realização de diagnósticos da ocorrência de pragas, doenças ou de estresses de outra natureza, em diferentes culturas agrícolas. Posteriormente, desenvolveram-se

sensores multiespectrais adequados à RPA de pequeno porte, assim como sensores ativos de tecnologia LIDAR (*Light Detection And Ranging*) (ROSALEN et al., 2017). Ainda dentro deste contexto, sensores hiperespectrais passaram também a ser desenvolvidos e adaptados para uso em RPA; porém, geralmente são maiores e exigem acessórios que elevam o *payload*, implicando montagens mais caras e de maior massa. Além disso, são os sensores mais caros e a análise de dados requer mais tempo e experiência, limitando dessa maneira seu uso a projetos específicos de pesquisa (IOST FILHO et al., 2020). Destaca-se que existe ampla gama de sensores embarcados em RPA descritos em literatura (AASEN et al., 2018).

O estresse, originalmente, relacionava-se ao conceito da Mecânica, no qual uma força externa atuava sobre um corpo. Esse conceito pode ser aplicado em certos estresses de natureza biótica em plantas, os quais são mensuráveis em termos físicos, como o potencial de água nas plantas. Porém, para estresses de outras naturezas e, especialmente, os de origem biótica, o estresse não pode ser reduzido a medidas físicas. Dessa forma, em termos mais genéricos, poder-se-ia definir o estresse como um afastamento das condições fisiológicas ideais (PETERSON; HIGLEY, 2001). Dessa forma, partindo-se do pressuposto de que plantas sob estresse terão alterações fisiológicas e, conseqüentemente, sua resposta espectral será também alterada, técnicas de sensoriamento remoto podem ser utilizadas para relacionar a resposta espectral com diferentes agentes causadores de estresse.

Dentro de agentes estressores de natureza biótica, têm-se os artrópodes-praga (insetos e ácaros), vírus, bactérias e fungos causadores de doenças, além da ocorrência de plantas daninhas; ou, ainda, uma associação entre esses diferentes agentes. Por exemplo, infestações por artrópodes induzem respostas fisiológicas das plantas, causando alterações na capacidade de realizar a fotossíntese, o que leva a alterações na reflectância foliar, detectadas em algumas faixas espectrais (IOST FILHO et al., 2020).

Uma vez registrada a resposta espectral, a análise dos dados é realizada. Essa análise pode ser realizada de diferentes maneiras, como estudo de bandas de absorção, picos de reflectância, profundidade de bandas e cálculo de índices de vegetação, dentre outras. Neste contexto, o processamento de dados oriundos de sensores multiespectrais é muito mais rápido quando comparado ao processamento de dados hiperespectrais; porém, pode levar a resultados de menor qualidade na detecção de estresse biótico, como os provocados por artrópodes-praga (YANG et al., 2009).

Também se deve destacar que a automação da análise de dados e sua respectiva análise em tempo real podem agilizar a detecção de áreas de interesse (*hotspots*). Isto é, uma RPA pode detectar, em tempo real, áreas cultivadas que estejam sob estresse e em conjunto com outros sistemas (RPA e/ou veículos terrestres não tripulados aplicadores), atuando na mitigação dos efeitos de estresse sobre a produtividade agrícola, como no caso de infestação por plantas daninhas (HUNTER III, 2019).

Em termos de índices de vegetação, existem índices de caráter estrutural, bioquímicos e fisiológicos (relacionados com estresse), e índices específicos para a detecção de pragas, como afídeos (insetos de aparelho bucal picador-sugador) e doenças. O Quadro 1 ilustra alguns exemplos. Outros índices podem ser encontrados em Prabhakar, Prasad e Rao (2012).

Quadro 1 – Exemplos de índices de vegetação. R: reflectância e comprimento de onda correspondente (nm).

Índice	Equação	Características	Referência
<i>Normalized Difference Vegetation Index</i> - NDVI	$(R800-R670)/(R800+R670)$	Índices de caráter estrutural relacionado a produção de biomassa	Rouse et al. (1974)
<i>Modified red edge Normalized Difference Vegetation Index</i> - mNDVI	$(R750-R705)/(R750+R705-2.R445)$		Sims e Gamon (2002)
<i>Chlorophyll Absorption Ratio Index</i> - CARI	$[(R700-R670)-0,2.(R700-R550)]$	Índices de caráter bioquímico relacionado a pigmentos (clorofila)	Kim (1994)
<i>Modified Chlorophyll Absorption Reflectance Index</i> - MCARI	$[(R700-R670)-0,2.(R700-R550)].(R700/R670)$		Daughtry et al. (2000)
<i>Chlorophyll Green</i> - CI	$(R415-R435)/(R415+435)$		Barnes (1992)
<i>Disease Water Stress Index</i> 2	R1660/R550	Utilizado para detecção de doenças na cultura da cana-de-açúcar	Apan et al. (2004)
<i>Aphid Index</i> – AI	$(R761-R908)/(R712-R719)$	Utilizados para a detecção de afídeos	Mirik et al. (2006a)
<i>Damage Sensitive Spectral Index</i> -2 - DSSI2	$(R747-R901-R537-R572)/(R747-R901)+(R537-R572)$		Mirik et al. (2006b)

Fonte: Os autores (2021).

Pode-se inferir que índices estruturais estão relacionados à biomassa e ao Índice de Área Foliar - IAF (*Leaf Area Index* - LAI), e poderiam ser utilizados para a detecção de injúrias provocadas por insetos de aparelho bucal mastigador que reduzem a área foliar, como lagartas desfolhadoras da soja, tais como a lagarta-da-soja [*Anticarsia gemmatalis* (Hübner)], lagarta-falsa-medideira [*Pseudoplusia includens* (Walker)] e *Helicoverpa armigera* (Hubner) (Lepidoptera: Noctuidae), enquanto índices bioquímicos relacionados à clorofila poderiam ser relacionados a injúrias de insetos de aparelho bucal picador-sugador, como o complexo de percevejos que atacam a cultura da soja. Também, índices fisiológicos e relacionados a estresse biótico poderiam ser referentes a infestações, em suas fases iniciais, visto que as plantas, ao serem infestadas, podem ter alterações em sua fisiologia, inclusive emitindo complexos voláteis, como indicam alguns trabalhos (KOST; HEIL, 2006; SHRIVASTAVA et al., 2010; PINTO-ZEVALLOS et al., 2013; RIFFEL, 2015).

Com relação aos artrópodes-praga, há diversos trabalhos que procuraram correlacionar infestação e resposta espectral em diferentes culturas. Por exemplo, o estudo potencial do uso de imagens multiespectrais RapidEye na detecção e na discriminação de áreas infestadas pelo besouro-da-raiz, *Migdolus fryanus* (Westwood) (Coleoptera: Cerambycidae), assim como de nematoides na cultura da cana-de-açúcar (MARTINS; GALO, 2014). Por meio da plataforma Sentinel-2, banda 5 (vermelha de borda), banda 4 (vermelha), banda 3 (verde) e banda 12 (SWIR 2), Kumbula et al. (2019) identificaram áreas sob infestação de *Coryphodema tristis* (Drury) (Lepidoptera: Cossidae) em áreas de *Eucalyptus nitens*, na África do Sul, utilizando o modelo Mexent com variáveis preditoras de bandas espectrais, índices de vegetação e combinações.

Já Severtson et al. (2016), através de um sensor multiespectral (6-channel Tetracam miniature multicâmera array, Tetracam, EUA) embarcado numa RPA, detectaram a suscetibilidade ao pulgão-verde, *Myzus persicae* Sulzer (Hemiptera: Aphididae), na cultura da canola (*Brassica napus* L. var oleífera), com acurácia de classificação de 69 a 100%, em função da data de amostragem e da altura de voo. Destaca-se que, nesse estudo, as infestações por pulgões aconteceram de forma natural, sendo estes amostrados em campo para verificação da classificação remota.

Ainda dentro da família de afídeos, foi possível, através da classificação de imagens multiespectrais (bandas do infravermelho próximo, vermelho e verde), separar áreas infestadas pelo pulgão-russo, *Diuraphis noxia* (Kurdjumov), de áreas infestadas pelo pulgão-dos-cereais, *Schizaphis graminum* (Rondani) (Hemiptera:

Aphididae), na cultura do trigo (*Triticum aestivum* L.). Destaca-se que o sensor utilizado foi o MS3100-CIR (Duncan Tech, EUA), embarcado em veículo aéreo pilotado (altura de voo de 1.500 m). Para a diferenciação das áreas, utilizou-se de métricas de padrões de espacialização (BACKOULOU; ELLIOTT; GILES, 2016). Já o pulgão da cana-de-açúcar, *Melanaphis sacchari* (Zehntner) (Hemiptera: Aphididae), é uma das principais pragas do sorgo (*Sorghum bicolor* L.); dessa forma, utilizando o mesmo sensor e a mesma aeronave, foi possível identificar e delimitar áreas infestadas, obtendo-se acurácia geral da classificação em torno de 89 a 96% (BACKOULOU et al., 2018).

Em termos de lagartas, a lagarta-do-pinheiro ou *Pine processionary moth* (PPM), [*Thaumetopoea pityocampa* (Denis & Schiffermüller) (Lepidoptera: Notodontidae)] alimenta-se das folhas de coníferas, causando elevadas taxas de desfolhação. Neste contexto, os autores utilizaram o sensor multiespectral Sequoia (Sensefly/Parrot, França), bandas do infravermelho próximo, vermelho e verde, e o sensor RGB PC300S (DJI, China) para geração de ortomosaico, embarcados em RPA modelo Phantom 3 (DJI, China). Para a classificação de áreas sob infestação, os índices NDVI (*Normalized Difference Vegetation Index*) e o ExG (*Green Index*) foram utilizados com acurácia geral de 81,8% (CARDIL et al., 2019).

Um sistema de visão de máquina (*Machine Vision Systems – MVS*) multiespectral foi desenvolvido para detecção de artrópodes-praga em folhas. Neste, optou-se pelo registro 3D dos dados na forma de nuvens de pontos, e os resultados obtidos para 12 diferentes pragas alcançaram uma acurácia aceitável (LIU HUAJIAN; CHAHL, 2018). Em outro trabalho, no desenvolvimento de um MVS, utilizaram-se espectros do ultravioleta, azul, verde, vermelho e infravermelho próximo, com registro, também, na forma 3D; destaca-se que esse MVS desenvolvido pôde ser utilizado num sistema robótico em movimento para a inspeção de plantas (LIU HUAJIAN; LEE SANGHEON; CHAHL, 2018).

Utilizando-se de RPA modelo S800 EVO Hexacopter (DJI, China), equipado com sensor RGB de alta resolução EOS 5DS-R (Canon, Japão), sensor multiespectral RedEDGE (MicaSense, EUA) e sensor hiperespectral Nano-Hyperspec (Headwall Photonics, EUA), os autores desenvolveram uma metodologia para a predição da ocorrência de filoxera, *Daktulosphaira vitifoliae* (Fitch) (Hemiptera: Phylloxeridae) em vinhedos. Neste trabalho, obteve-se um modelo digital de vigor, obtido a partir do desenvolvimento e da avaliação de índices de vegetação. Também se determinou a assinatura espectral de plantas infestadas e demonstrou-se a possibilidade de, a partir de dados hiperespectrais, detectar plantas infestadas sem a ocorrência de sintomas visíveis (VANEGAS et al., 2018).

A seguir, são apresentados trabalhos relevantes quanto ao uso de sensores multiespectrais no manejo de doenças que afetam culturas agrícolas. Nas últimas décadas, a queima bacteriana das rosáceas (*Fire Blight* - FB), causada por *Erwinia amylovora*, foi reconhecida como uma das doenças mais perigosas das macieiras e pereiras do mundo, sendo seu diagnóstico precoce muito importante para o manejo da doença. Em termos nacionais, a queima bacteriana das rosáceas, devido à sua importância, sua prevenção em termos de introdução e de disseminação são medidas de grande importância para a produção nacional de maçã.

Neste contexto, Bagheri (2020) utilizou sensor multiespectral ADC-Microcâmera (Tetracam, EUA) embarcado em RPA, para avaliar diferentes índices de vegetação, sendo que o SIPI (*Structure Intensive Pigment Index*), RDVI (*Randomized Difference Vegetation Index*), MCARI1 (*Modified Chlorophyll Absorption Ratio Index 1*), MCARI2 (*Modified Chlorophyll Absorption Ratio Index 2*), TVI (*Triangular Vegetation Index*), MTVI1 (*Modified Triangular vegetation Index 1*), MTVI2 (*Modified Triangular vegetation Index 2*), TCARI (*Transformed Chlorophyll Absorption and Reflectance Index*), PSRI (*Plant Senescence Reflectance Index*) e ARI (*Anthocyanin Reflectance Index*) foram adequados para a detecção precoce da doença, com acurácia geral em torno de 95%.

Jarolmasjed et al. (2019) obtiveram dados normalizados de condutância estomática, adquiridos por meio de um sistema fotossintético portátil LI-6800 (LI-COR Biosciences, EUA), dados de imagem coletados por sensor RGB PowerShot SX260HS (Canon, Japão), sensor multiespectral FM50-25 (Floatagraph Technologies, EUA) e reflectância espectral visível no infravermelho próximo adquiridos pelo sistema de detecção hiperespectral SVC HR-1024i (Spectra Vista Corporation, EUA). Esses dados foram avaliados para estimar a progressão da infecção pela queima bacteriana das rosáceas em macieiras jovens. Os dados

multiespectrais foram coletados a partir de duas escalas, a 7 m de AGL (*Above Ground Level*) utilizando o veículo agrícola Gator XUV590i (John Deere, EUA) e a 100 m de AGL, com RPA ARF OktoXL 6S12 (velocidade de voo de $0,5 \text{ m s}^{-1}$) da HiSystems GmbH (Alemanha). Os dados RGB e hiperespectrais foram coletados *in loco*, sendo os hiperespectrais através de um *clip* de folha. Posteriormente, foram determinados os índices GNDVI (*Green Normalized Difference Vegetation Index*), NDER (*Normalized Difference Red Edge*) e NDVI (*Normalized Difference Vegetation Index*). Os dados indicaram que as bandas espectrais específicas podem ser usadas para avaliar a gravidade da doença causada pela patologia em programas de melhoramento de maçãs e, potencialmente, como ferramenta de detecção precoce para auxiliar em sistemas de produção.

Destaca-se que Greening (Huanglongbing) é uma doença de grande importância na citricultura, e dessa forma, os autores utilizando-se de sensor multiespectral (bandas vermelha, verde, azul, vermelho de borda e infravermelho próximo) embarcado em RPA, identificaram árvores de citros doentes com 81,75% de acurácia (DADRASJAVAN et al., 2019).

A brusone em trigo (*Triticum aestivum*), causada por *Magnaporthe oryzae* *Triticum* infesta folhas e espigas de trigo. Os sintomas da brusone nas espigas são bem identificáveis em campo, daí essa patologia ser também denominada de branqueamento de espiga; porém, os sintomas da folha são geralmente inconspícuos. Imagens multiespectrais foram coletadas pelo sensor RedEDGE-M (Micasense, EUA), embarcado em RPA, numa altura de voo de 15 m (velocidade de 2 m s^{-1}), com amostragens de até 58 dias após a inoculação da brusone em plantas de trigo. Os autores utilizaram os índices NDVI (*Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red Edge*), GNDVI (*Green Normalized Difference Vegetation Index*), GRVI (*Green Ratio Vegetation Index*), OSAVI (*Optimized Soil-adjusted Vegetation Index*) e 1-gvp (*nongreen vegetation pixels*). A gravidade dos sintomas em espiga apresentou bons resultados em termos de precisão e acurácia utilizando o índice 1-gvp, em níveis de infecção de moderadamente baixos a altos (GONGORA-CANUL et al., 2020).

Destaca-se que as características de um dossel são cruciais para determinar com precisão e segurança a quantidade de calda a ser aplicada em vinhedos. Porém, a variabilidade da cultura em campo implica dificuldade do estabelecimento de uma taxa ideal para toda área, fazendo-se necessárias aplicações a taxa variada. Dessa forma, os autores desenvolveram um sistema de suporte à decisão para geração de mapas de aplicação a taxa variada em vinhedos. Esses mapas foram construídos a partir de sensor multiespectral RedEDGE embarcado no RPA DroneHEXA (Dronetools SI., EUA) (CAMPOS et al., 2020).

No caso de infestação de áreas agrícolas por plantas daninhas, um dos objetivos da utilização do sensoriamento remoto, neste contexto, é a identificação de reboleras e, portanto, na diferenciação de espécies dentro da área. Essa diferenciação, em termos gerais, possibilita a identificação e posterior controle de áreas nas quais as plantas daninhas estejam competindo em termos de nutrientes, luz, etc. Além da competição direta, a infestação pode provocar danos indiretos, como proporcionar áreas nas quais ocorrem espécies vegetais que possam servir de hospedeiros para pragas ou patógenos.

Neste contexto, pode-se citar um estudo no qual os autores, por um período de três anos, utilizando sensor multiespectral MS-2100 (Geospatial Systems, EUA), determinaram índices de vegetação que melhor diferenciasse plantas de folhas largas de plantas de folhas estreitas, e em qual dessas categorias os percevejos manchados do algodão [*Lygus lineolaris* (Hemiptera: Miridae)] preferiam como hospedeiras. Essa diferenciação permitiu que fosse realizado o controle das plantas daninhas com herbicida e, dessa forma, se reduzisse a população do percevejo no período agrícola (SUDBRINK et al., 2015).

Para classificar e identificar áreas sob infestação de plantas daninhas de áreas cultivadas, os autores utilizaram, com sucesso, o algoritmo LEGION (*Locally Excitatory Globally Inhibitory Oscillatory Network Model*) aplicado na classificação de imagens multiespectrais coletadas por sensor RGB TCS34725 (TAOS, EUA) e pelo sensor NIR versão 230218 (Tetracam, EUA), embarcados na RPA Phantom 4 (DJI, China) (MATEEN; ZHU, 2019).

Métodos de fusão de imagens obtidas em diferentes sensores podem possibilitar melhorias no processo de classificação. Neste contexto, os autores propuseram novo método, baseado em redes neurais, para a fusão

de imagens RGB (sensor Powershot D20, Canon, EUA) com imagens multiespectrais (sensor RedEDGE, Micasense, EUA) embarcados em RPA (Zeta FX-61 Phantom, Hobbyking, China) para identificar plantas daninhas Gramineae na cultura do arroz. Os dados foram coletados 50 dias após a emergência do arroz, numa altura de voo de 60 a 70 m. Utilizaram-se os índices NDVI (*Normalized Difference Vegetation Index*) e NGRDI (*Normalized Green-Red Difference Index*). A fusão das imagens RGB e multiespectrais apresentou melhores resultados, com índice de acerto entre 70 e 80%, além de consumir metade do tempo de processamento de imagens não fundidas (BARRERO; PERDOMO, 2018).

Em outro trabalho, os autores classificaram somente imagens RGB (sensor SODA, SenseFly/Parrot, Suíça), obtidas a partir do recobrimento aéreo com RPA (eBee Plus RTK, SenseFly/Parrot, Suíça), em campos de aveia. Nesse trabalho utilizaram-se os índices NGRDI (*Normalized Green-Red Difference Index*), GLI (*Green Leaf Index*), VARI (*Visual Atmospheric Resistance Index*), BI (*Brightness Index*), CI (*Colour Index*) e RI (*Redness Index*). Dos quatro algoritmos de classificação avaliados no trabalho, o método automático de classificação, baseado em objeto, utilizando o índice NGRVI, alcançou a maior acurácia de classificação de plantas daninhas (valor de 89 em termos gerais) (GAŠPAROVIĆ et al., 2020).

As plantas daninhas *Brachiaria decumbens*, *Cynodon dactylon* e *Amaranthus viridis* representam problemas fitossanitários de importância na cultura da cana-de-açúcar (*Saccharum officinarum*). Dessa forma, através de sensor multiespectral embarcado em RPA coletaram-se dados para a identificação de áreas de cana-de-açúcar infestadas por essas plantas daninhas. As bandas utilizadas foram infravermelho próximo, vermelho de borda, vermelho e verde. Para a classificação das imagens, foi utilizada uma regressão logística multinomial sob a estrutura GAMLSS (*Generalized Additive Model for Location, Scale and Shape*). Os resultados indicaram que a área experimental de 4,47 ha revelou 27% de plantas daninhas, 57% de cana e 16% de solo; portanto, o uso de herbicida poderia ser reduzido de 84% para 27% (RIGHETTO et al., 2019).

4 SENSORES HIPERESPECTRAIS

Esta seção do artigo tem como objetivo apresentar o uso de sensores hiperespectrais no monitoramento fitossanitário de culturas agrícolas. Como apresentado anteriormente, os principais problemas fitossanitários são decorrentes de seres vivos que competem com as plantas cultivadas por recursos, ou prejudicam seu desenvolvimento, por meio de herbivoria ou de infecções. São apresentados nesta seção os trabalhos mais recentes nesta área (últimos 5 anos), incluindo artrópodes-praga, plantas invasoras e fitopatógenos, publicados em periódicos científicos de grande divulgação.

Levando em consideração aspectos práticos e econômicos, os sensores hiperespectrais levam desvantagem, por serem, geralmente, mais caros e complexos para se utilizar. Nesse sentido, vale o princípio de se entender o objetivo do sensoriamento em cada caso e avaliar o custo-benefício da utilização de um sensor que, embora mais caro e trabalhoso, gere uma riqueza de detalhes muito superior em relação ao sensoriamento multiespectral.

O primeiro passo para a utilização de sensoriamento remoto no monitoramento fitossanitário é a decisão da escala em que se deseja coletar as informações. As principais escalas em que se pode trabalhar são: tecido vegetal, folhas, plantas individuais e dosséis (THOMAS et al., 2018). Estudos em escala de tecido e folhas são geralmente conduzidos em laboratório, como pesquisa básica, ao passo que estudos em escala de plantas e dosséis tendem a ser realizados em casas de vegetação e em campo, como pesquisa prática para validar os resultados obtidos na etapa anterior.

Assim como os multiespectrais, sensores hiperespectrais podem ser embarcados em plataformas orbitais, aéreas ou terrestres. Apesar de menos comuns, é possível encontrar trabalhos científicos baseados em dados hiperespectrais coletados em plataformas orbitais, como o sensor Hyperion da plataforma orbital *Earth Observing-1* - EO-1 (NASA, EUA), que opera na faixa espectral de 400-2.500 nm, com resolução espectral de 10 nm em 220 bandas, e espacial de 30 metros. Apesar de ter sido desativado em 2017, suas imagens ainda estão disponíveis, com acervo desde o ano 2000.

A maior parte dos estudos é realizada em nível terrestre, com sensores utilizados em bancadas ou

manipulados pelos próprios pesquisadores. Essa forma de coleta de dados é conhecida como espectroscopia e tem como característica a coleta de uma riqueza de detalhes do alvo em função da alta resolução espacial (ADÃO et al., 2017). Ou seja, essa técnica é mais utilizada para coleta pontual de informação, de alvos como a área de uma folha, por exemplo.

Por outro lado, um dos desafios na utilização do sensoriamento hiperespectral é justamente o tratamento e a análise da grande quantidade de dados gerados. Um problema típico é a redundância de resposta de bandas tão próximas, o que pode afetar a qualidade da análise. Assim, um desafio atual para a análise de dados espectrais é o desenvolvimento de computadores ainda mais rápidos e de dispositivos de armazenamento de dados com maior capacidade (CABALLERO; CALVINI; AMIGO, 2020). Ressalta-se que muitos esforços têm sido realizados nesse sentido, de modo a minimizar o grau desse desafio, dentre os quais se podem citar a computação paralela, em rede, além do desenvolvimento de algoritmos mais sofisticados.

A técnica de imageamento hiperespectral em nível orbital é menos utilizada para monitoramento de lavouras. Os principais motivos são os problemas relacionados às resoluções espacial e temporal e, às condições ambientais. Quanto ao tamanho da cena, com uma resolução espectral de 30 m, por exemplo, um *pixel* pode apresentar informação de grande quantidade de plantas, ou até mesmo de mais de uma espécie de plantas ao mesmo tempo, sendo esse fato descrito como informação espectral misturada nos *pixels* (JETZ et al., 2016; TURNER et al., 2014). Soma-se a esse fato o problema com a redundância de informações das bandas mais próximas, descrito anteriormente.

Por sua vez, o problema relacionado às condições ambientais dá-se em função da alta sensibilidade do sensor. Por exemplo, a água absorve energia de duas faixas espectrais do infravermelho de ondas curtas, SWIR (*short-wave infrared*), principalmente próximas a 1.440 nm e 1.930 nm (TIAN; PHILPOT, 2015). Isso leva à presença de ruídos nas informações coletadas nesses comprimentos de onda, em função da umidade relativa do ar, fazendo com que os dados dessas faixas sejam descartados nas análises.

Outro desafio relacionado às condições ambientais diz respeito à grande variação a que as assinaturas espectrais estão sujeitas, dependendo da exposição de luz. A comunidade científica tem buscado maneiras de enfrentar esse desafio, das quais se destacam a melhora nos processos de aquisição dos dados (visando a controlar as condições ambientais) e nas metodologias de análises (visando a minimizar os ruídos) (ADÃO et al., 2017). Dessa maneira, o desenvolvimento de técnicas robustas de calibragem é essencial para garantir a repetitividade dos dados extraídos de uma lavoura ao longo do ciclo de desenvolvimento da cultura (SINGH; NANSEN, 2017). Somente assim, será possível identificar eficientemente o comportamento de populações de pragas ou o avanço de doenças, tanto pelo tempo, quanto pela distribuição geográfica na lavoura (NANSEN; ELLIOTT, 2015).

As análises dos dados hiperespectrais coletados para monitorar estressores bióticos na lavoura podem ser baseadas no conjunto dos dados, em subamostras ou em bandas individuais. A abordagem mais comum é baseada na análise do conjunto de dados como um todo, fazendo valer a característica vantajosa do sensor hiperespectral de coletar respostas em uma grande quantidade de bandas espectrais. Para tanto, as análises mais comuns são do tipo multivariada, com destaque para regressão parcial de quadrados mínimos (*Partial Least Squares* - PLS) (WHETTON et al., 2018; YU et al., 2018), análise dos componentes principais (*Principal Component Analysis* - PCA) (WHETTON; WAINE; MOUAZEN, 2018; LU et al., 2018) além de variogramas (NANSEN, 2012) e redes neurais (GOLHANI et al., 2018). Uma maneira de mensurar a qualidade da classificação obtida por meio dos dados é a validação cruzada.

Quanto ao imageamento hiperespectral no monitoramento de pragas, vale ressaltar que o alvo de estudos não é propriamente a praga, mas, sim, a alteração no comportamento espectral da planta infectada. Uma variedade de trabalhos demonstra que a herbivoria por artrópodes-praga, na vasta maioria insetos, afeta negativamente a capacidade das plantas cultivadas de fazerem fotossíntese (KERCHEV et al., 2012).

Considerando-se que a fotossíntese é um processo bioquímico que envolve a absorção de energia solar por pigmentos foliares, é possível correlacionar a infestação de pragas com alteração na quantidade de energia absorvida e, conseqüentemente, refletida. Os pigmentos foliares responsáveis pela maior parte do comportamento espectral da vegetação, na região da luz visível, são clorofilas, carotenoides e antocianinas

(MISHRA et al., 2017).

Apesar de a temática sobre o uso da análise do perfil de reflectância de plantas para monitoramento de pragas já ter sido discutida e revisada (IOST FILHO et al., 2020; NANSEN; ELLIOTT, 2016), nesses trabalhos, não há uma clara distinção entre o monitoramento hiperespectral e as demais modalidades. Analisando a cultura do trigo, Shi et al. (2017) estudaram os efeitos de doenças e insetos-praga na alteração do perfil de reflectância das plantas. Para tanto, o sensor ASD FieldSpec 4 (Malvern Panalytical, EUA) foi utilizado. Diversos índices vegetativos foram utilizados isoladamente e comparados no estudo, por meio de validação independente, sendo que nenhum apresentou boa acurácia na distinção de plantas sadias, infestadas por pulgões, infectadas por míldio e por ferrugem amarela. No entanto, foi proposta uma análise discriminante baseada em índices vegetativos, *SVI-based kernell discriminant analysis* (SVIKDA), a qual proporcionou clara distinção entre os estressores, com a vantagem de reduzir a redundância dos dados hiperespectrais e de demandar menos amostras para treinamento e validação.

Utilizando a mesma base de dados, Zhang et al. (2017) exploraram uma variedade de análises. A análise *wavelet* contínua (CWA) demonstrou capacidade de diferenciação dos estressores superior a técnicas de análise espectral convencionais, como análise derivativa dos espectros e análise da remoção contínua das feições.

A eficácia do sensoriamento hiperespectral na diferenciação de plantas de arroz (*Oryza sativa*) sadias e infestadas pela cigarrinha *Nilaparvata lugens* Stål (Hemiptera: Delphacidae) foi testada, utilizando-se do sensor ASD FieldSpec Handheld (Malvern Panalytical, EUA). Esse sensor atua na faixa espectral de 325 a 1.075 nm, com resolução espectral de 3 nm e intervalo amostral de 1,6 nm. Os autores analisaram uma variedade de índices espectrais e, observaram que o índice $RVI_{746/670}$ apresentou alterações significativas em função da infestação (TAN et al., 2019).

Utilizando o mesmo modelo de cultura, praga e sensor, foi possível observar que a reflectância do dossel foi significativamente correlacionada com a infestação da cigarrinha e com a duração da infestação. Ainda neste caso, foi estudado o comportamento espectral das plantas infestadas e sadias em função da deficiência de nitrogênio. A deficiência nutricional também foi significativamente correlacionada com a reflectância do dossel (HUANG et al., 2015).

De maneira análoga, Nguyen e Nansen (2020) estudaram a relação entre estresse nutricional e infestações de larva minadora *Liriomyza trifolii* Burgess (Diptera: Agromyzidae), em plantas de acelga (*Brassica rapa* L. var. *Chinensis*) e espinafre (*Spinacia oleracea*). Nesse estudo, foi utilizado o sensor imageador OCI Imager (BaySpec, EUA), que atua na faixa espectral de 460 a 983 nm, em 116 bandas espectrais. As análises foram baseadas no espectro da primeira derivativa, com modelos lineares de bandas individuais e com classificadores do tipo máquina de vetor-suporte. Os resultados obtidos indicam que, apesar de alterações em bandas individuais apresentarem correlação com a infestação, também apresentam correlação com o estresse nutricional, sendo impossível separar os estressores. Ao analisar o conjunto de bandas, foi possível separar os estressores e classificar com acurácia de 99% as plantas infestadas.

Tradicionalmente, doenças em plantas cultivadas são classificadas quanto à sua intensidade, severidade, incidência e prevalência. Dessa maneira, sensores hiperespectrais têm sido demonstrados como ferramenta confiável no monitoramento de tais doenças, em função de sua capacidade de capturar mudanças na reflectância foliar de folhas infectadas em comparação às sadias (LOWE et al., 2017).

Moghadam et al. (2017) estudaram a viabilidade da utilização de imageamento hiperespectral (VNIR e SWIR) e técnicas de *machine learning* para a detecção de *Tomato Spotted Wilt Virus* (TSWW) em plantas de pimentão (*Capsicum* spp.) cv Warlock, em um sistema automatizado de coleta de dados em intervalos regulares após a inoculação do patógeno. A coleta dos dados foi feita em nível proximal, com duas câmeras hiperespectrais do tipo *push-broom*, VNIR A-series e SWIR M-series (Headwall, EUA). A primeira atua na região VNIR (400-1.000 nm), em 324 bandas espectrais, enquanto a segunda atua na região SWIR (900-2.500 nm), com 168 bandas espectrais. Os autores testaram distintas abordagens de análise dos dados, incluindo índices vegetativos, modelos probabilísticos e análise do espectro completo. Seus resultados indicam que os modelos baseados no espectro completo apresentaram resultados melhores do que as demais abordagens

analíticas, sendo que a acurácia obtida foi superior a 90%. Um fato interessante desse trabalho é a indicação dos autores de que a acurácia obtida por especialistas na classificação visual das plantas foi de aproximadamente 70%, enquanto a análise das imagens hiperespectrais apresentou acurácia superior a 90%.

A detecção da severidade de infestações de *Maize streak virus* (MSV) em cultivos de milho (*Zea mays*) foi avaliada por Dhau et al. (2017). O estudo foi realizado em campo, sendo que as folhas saudáveis e infectadas (em diferentes níveis de severidade) foram amostradas com o sensor não imageador ASD FieldSpec-4 (Malvern Panalytical, EUA), um sensor proximal que tem a faixa espectral de 350 a 2.500 nm, com intervalos de amostragem de 1,4 nm e 2 nm para as regiões UV/VNIR (350–1.000 nm) e SWIR (1.000–2.500 nm), respectivamente. Uma análise do tipo *random forest* identificou 5 bandas como ótimas para detectar e discriminar diferentes níveis de infecção de MSV em milho, 3 na região visível, uma na região do vermelho de borda e uma na região NIR. Posteriormente, a acurácia do monitoramento foi mensurada por meio do procedimento de validação cruzada, que indicou acurácia acima de 90% nos variados estágios de severidade estudados.

Na cultura do trigo, uma doença limitante na produção é a mancha-amarela, ou mancha salpicada, causada pelo fungo *Zymoseptoria tritici*. Utilizando o sensor ASD FieldSpec-4 (Malvern Panalytical, EUA), foi avaliada a capacidade de detecção e de quantificação da doença em plantas de trigo, em nível de campo, por meio de dados hiperespectrais (YU et al., 2018). Os autores utilizaram tanto análises multivariadas, do tipo PLS e PLS-DA (*discriminant analysis by partial least squares*), quanto índices de vegetação para a análise dos dados. Os resultados indicaram que o índice vegetativo NDWI, que utiliza informação na região do vermelho de borda e na região do SWIR, foi o que melhor discriminou plantas saudáveis e plantas infectadas, sugerindo uma associação entre a infecção e o nível de senescência e o conteúdo hídrico na planta. Ainda, foi observado que as bandas mais significativas na discriminação de plantas saudáveis e infectadas foram nas regiões de 520-580 nm, 700-1.300 nm, 1.500-1.580 nm, 1.760-1.800 nm e, 2.100-2.400 nm, com acurácia da classificação do modelo na validação cruzada de 93%.

Considerando a sequência recomendada para estudos dessa natureza, um grupo de pesquisadores avaliou o potencial uso de imageamento hiperespectral para mensuração das doenças ferrugem (*Puccinia striiformis*) e fusariose (*Fusarium graminearum*) nas culturas do trigo (*Triticum aestivum*) e cevada (*Hordeum vulgare*), com a parte básica de laboratório (WHETTON et al., 2018), seguida pela parte aplicada em campo (WHETTON; WAINE; MOUAZEN, 2018). Em laboratório, foi utilizada a câmera do tipo *push broom* HS spectral câmera (Gilden Photonics, Reino Unido), que atua na faixa espectral de 400-1.000 nm, com um intervalo de coleta de 7,4 nm. Foram feitas coletas em diferentes intervalos após a infestação e os dados foram analisados por meio de análises do tipo PCA e PSLR, que indicaram maior acurácia na mensuração da ferrugem em detrimento da fusariose.

Para a avaliação dos sintomas da infecção de plantas de tomate (espécie) pelo nematoide *Meloidogyne incognita* e a diferenciação de tais sintomas daqueles causados pelo estresse hídrico, foram utilizadas duas câmeras do tipo *push broom*, HySpex VNIR (faixa espectral 400–988 nm) e SWIR (faixa espectral 950–2.500 nm) (Norsk Elektro Optikk AS, Noruega). Em ensaios realizados em vasos, com coleta de dados próximos ao alvo e respectiva análise por meio de PLS-DA, os pesquisadores concluíram ser possível diferenciar plantas hidratadas de plantas estressadas e plantas com e sem a presença dos nematoides nas duas condições hídricas (SUSIČ et al., 2018). Considerando que os sintomas na parte aérea das plantas são os mesmos para esses dois estressores, e que a amostragem de nematoides nesse só é feita com a retirada da planta e análise do sistema radicular, a técnica de sensoriamento apresentada tem potencial de ser utilizada em campo, gerando economia de tempo e de recursos para o agricultor.

Na cultura do café, Martins et al. (2017) investigaram a possibilidade de discriminação e de mapeamento de áreas infectadas por meio de dados espectrais. Para tanto, os autores coletaram dados em campo, em plantas com sintomas da infecção por nematoides (cuja presença foi confirmada por análises em laboratório de amostras de solo próximas a essas plantas). Os dados hiperespectrais foram coletados em folhas retiradas de plantas saudáveis e infectadas, utilizando-se do sensor FieldSpec HandHeld (Malvern Panalytical, EUA), que opera na faixa espectral de 375–1.075 nm, com resolução espectral de 512 e com largura de bandas

de 1,6 nm. Esses dados foram comparados com dados multiespectrais retirados do sensor orbital RapidEye, que opera em 5 bandas espectrais: (azul: 440–510 nm, verde: 520–590 nm, vermelho: 630–685 nm, vermelho de borda: 690–730 nm e infravermelho próximo: 760–850 nm). Os autores concluíram que a análise hiperespectral foi capaz de diferenciar plantas saudáveis de plantas com infecção inicial e severa, principalmente na região do infravermelho, ao passo que os dados multiespectrais de nível orbital não foram capazes de realizar tal diferenciação.

Em estudos florestais, essa técnica já foi utilizada para monitoramento de áreas de pinheiros infectadas pelo nematoide *Bursaphelenchus xylophilus*. Esse estudo foi realizado, utilizando-se da câmera VNIR A-series (Headwall, EUA), acoplada a uma aeronave tripulada. Após avaliação *in loco*, ortomosaico gerado a partir de imagens RGB e análise dos dados hiperespectrais, os resultados indicam que a distribuição das árvores sintomáticas foi a mesma nas três metodologias, porém mais fácil de se atingir, e com maior acurácia, com o sensoriamento hiperespectral (QIN et al., 2016). Em uma revisão mais recente sobre este mesmo assunto, são abordadas ainda outras maneiras de se adquirir e de se processar esses dados, por exemplo, com sensores acoplados a RPAs (WU et al., 2020).

Por fim, a técnica de imageamento hiperespectral de nível aéreo foi testada, também, no contexto de agricultura. Para tanto, o sensor não imageador ASD FieldSpec- 4 (Malvern Panalytical, EUA) foi utilizado em nível terrestre, em comparação ao sensor imageador Gamaya OXI VNIR 40 câmera system (Gamaya, Suíça) em nível aéreo, acoplado a uma RPA, modelo Solo drone (3D Robotics, EUA), que sobrevoou a área de estudo a 80 metros de altura. Esse sensor é composto por duas câmeras individuais que medem 16 bandas na região visível e 25 bandas na região do infravermelho. Assim, o sistema opera em 40 bandas na faixa espectral de 475 a 875 nm. A cultura investigada foi a beterraba sacarina e, o patógeno em questão, o nematoide do cisto *Heterodera schachtii*. Após análises PCA e validações cruzadas, os autores concluíram que os dados hiperespectrais tanto em nível terrestre, quanto em nível aéreo, apesar de não consistentes entre si, foram utilizados para diferenciar, com alta eficiência, plantas infectadas de plantas saudáveis (JOALLAND et al., 2018).

O sensoriamento remoto hiperespectral aplicado ao monitoramento de plantas daninhas na lavoura é baseado na busca pela diferença do comportamento espectral de espécies invasoras, em relação à espécie cultivada. Para análises dessa natureza, é comum a utilização de sensores em nível terrestre e orbital. O nível de coleta terrestre, com sensores acoplados em tratores, tende a ser o mais desejado por pesquisadores, uma vez que a identificação de plantas daninhas em tempo real poderia ser utilizada para fins de pulverização dirigida (TITTLE, 2017).

Tais vantagens seriam a menor dificuldade com correção atmosférica e o georreferenciamento do mapa, uma vez que o sensor está muito próximo do solo e, conseqüentemente, do alvo. Assim, facilita-se a sincronização entre o mapa de plantas daninhas, a localização de fato das mesmas e o pulverizador, permitindo a pulverização em tempo real (PLANT, 2001; TITTLE, 2017). No entanto, o imageamento hiperespectral requer alta capacidade de armazenamento e de processamento de dados. Soma-se a esse fato o valor relativamente caro desses sensores. Portanto, essa combinação ainda limita a viabilidade de utilização dessa tecnologia acoplada a tratores (UTO et al., 2015).

Nesse sentido, alguns trabalhos são realizados em laboratório e de forma proximal, com sensores em movimento, para simular as condições de coleta de dados em campo, no que diz respeito a distância do alvo, velocidade de aquisição, entre outros. No intuito de diferenciar plantas de milho (*Zea mays*) e plantas daninhas, para três espécies distintas (*Convolvus arvensis*, *Rumex* e *Cirsium arvense*), o sensor imageador cmosis cmv4000 (Imec, Bélgica), que opera na região do infravermelho, em 25 bandas, entre 601 e 871 nm, foi utilizado. Os resultados obtidos indicam que a identificação de plantas de milho é feita com alta acurácia (acima de 90%). No entanto, a acurácia na identificação das espécies de plantas daninhas é menor. De um ponto de vista prático, esses resultados indicam que a simples separação entre a planta cultivada (milho) e as plantas daninhas pode ser feita por meio de índices vegetativos contendo, principalmente, bandas próximas ao vermelho de borda (GAO et al., 2018).

Para avaliar a viabilidade de sensores hiperespectrais distintos, Huang et al. (2016) utilizaram o sensor não-imageador ADS FieldSpec-2 Handheld (Malvern Panalytical, EUA) e o sensor imageador Pika II

(Resonon, EUA), o qual foi testado em condições de laboratório e de campo. Os resultados obtidos indicam altos níveis de acurácia na distinção de plantas daninhas e de plantas cultivadas, até mesmo quando o sensor foi utilizado em campo, acoplado a um trator, embora o sistema precise ser otimizado.

A técnica de aprendizado ativa (*active learning*) é bastante utilizada no contexto de sensoriamento hiperespectral de plantas daninhas, justamente para buscar a total automação dos processos de coleta, análise e interpretação dos dados. Nesse cenário, pesquisas básicas também são necessárias, como a apresentada por Pantazi et al. (2016), que utilizaram um sistema de imageamento hiperespectral composto por um espectrógrafo de linha modelo V9 (Specim, Finlândia), combinado com uma câmera monocromática. As configurações do sistema são: faixa espectral de 435 a 834 nm, intervalo amostral variando de 1,5 a 5 nm, resultando em 200 bandas espectrais amostradas. Por meio dos algoritmos de aprendizagem, os autores concluíram que, assim como no exemplo citado acima, a distinção entre plantas de milho e plantas daninhas é feita com alta acurácia, mas a distinção das diferentes espécies de plantas daninhas não apresenta o mesmo grau de assertividade.

5 SENSORES ATIVOS

Dentre as vantagens dos sensores ativos, destaca-se a capacidade de realizar mensurações em qualquer momento, independentemente da hora do dia ou da estação do ano. Estes sensores podem ser utilizados para estudar a interação de diferentes objetos através da radiação em que os comprimentos de onda não são influenciados pela energia solar, como as micro-ondas, ou para controlar melhor a forma como se ilumina um objeto.

No entanto, os sistemas ativos requerem a geração de uma grande quantidade de energia para iluminar adequadamente os alvos. As regiões do espectro mais empregadas pelos sensores remotos ativos são as micro-ondas (3 a 25 cm) e o visível, e o infravermelho próximo (530 a 1.070 nm). Dentre os tipos mais comuns, na primeira região, encontram-se os radares de abertura sintética (*Synthetic Aperture Radar* - SAR) e, na segunda, os sensores LIDAR (*Light Detection and Ranging*) (NASA, 2020).

O SAR é originário da tecnologia RADAR (*Radio Detection and Ranging*), um sistema de detecção utilizado em diversas áreas, como na aeronáutica e na meteorologia. Este sistema baseia-se na emissão e na recepção de pulsos de ondas eletromagnéticas (OEM) criados artificialmente. A partir do eco gerado pela interação dessas ondas com o terreno, ou com outros elementos, é possível extrair grande quantidade de informações, como medir distâncias, altitudes, direções e velocidade (RICHARDS, 2009). O SAR é um tipo de RADAR de visão lateral, que mede a distribuição espacial da reflectividade das micro-ondas emitidas na superfície iluminada. Além disso, transmite um pulso e mede o tempo e a intensidade do eco refletido que retorna para ele (i.e. medidas de amplitude e de fase). Nele, a relação entre a energia de micro-ondas incidente e a refletida captada pelo sensor, é denominada retrodispersão (MORAN et al., 2002).

Devido a suas características e propriedades, a aquisição de dados SAR não é afetada pela presença de nuvens, névoa ou chuva e é, também, independente da iluminação solar. Aproximadamente dois terços da superfície terrestre estão, frequentemente, atrás das nuvens durante todo o ano. Isso também ocorre em áreas agrícolas na zona climática úmida e semiúmida, com recursos hídricos abundantes. Portanto, frequentemente, afetadas por condições climáticas adversas para a aplicação do sensoriamento remoto com sensores ópticos (LIU et al., 2019), fato que coloca os sensores SAR em vantagem.

Essa vantagem pode ser vista, principalmente, onde as condições do solo, das culturas, ou das pragas mudam de maneira dinâmica, que requerem observações frequentes para rastrear seus desenvolvimentos e enfrentar os problemas fitossanitários. As imagens SAR são sensíveis às características dielétricas e geométricas das plantas e possuem certa capacidade de penetração que depende da frequência, sendo possível obter informações de debaixo da cobertura vegetal (BETBEDER; FIEUZAL; BAUP, 2016).

As plataformas que estarão em operação em curto prazo, como SAOCOM-1 A/B (CONAE-Argentina) e RISAT-1/2 (NASA-EUA e ISRO-ÍNDIA), ampliarão fortemente a disponibilidade de dados desse tipo. Da mesma forma, a crescente disponibilidade de sensores LIDAR, tanto aerotransportados, como satélites (futura missão GEDI da NASA-EUA) e bi ou multiespectrais, juntamente com a desejada redução de custos desta

tecnologia, oferecem um futuro promissor para a caracterização e o monitoramento de cultivos agrícolas, incluindo suas condições fitossanitárias.

O segundo tipo de sensor remoto ativo mais frequente baseia-se na emissão e na recepção de OEM que correspondem ao sensor visível e ao infravermelho próximo do espectro. O sistema sensor LIDAR funciona essencialmente segundo o princípio de medição do intervalo de tempo entre a emissão e a recepção de pulsos de luz LASER (*Light Amplification by Stimulated Emission of Radiation*). A medida de distância entre o sensor e o objeto-alvo é realizada através da multiplicação desse intervalo de tempo pela velocidade da luz.

O número de trabalhos sobre a aplicação do sensoriamento remoto ativo, na caracterização e/ou no monitoramento de problemas fitossanitários (pragas, doenças e plantas daninhas), ainda é baixo (ZHANG et al., 2019). A maioria dos problemas fitossanitários desencadeia mecanismos de defesa nas plantas, que geram alteração ou redução do desenvolvimento vegetativo, causando a redução da quantidade de biomassa, o índice de área foliar e/ou outros parâmetros associados ao dossel (AGRAWAL; KHAIRNAR, 2019). Sendo assim, a detecção remota de alterações no acúmulo de biomassa e na estrutura do dossel vegetal poderia servir como indicativo da ocorrência de problemas fitossanitários.

A tecnologia LIDAR tem sido amplamente empregada no monitoramento com o objetivo de analisar as condições nutricionais e fitossanitárias de plantas de grande porte, como na fruticultura, no florestamento e matas nativas, inclusive para caracterização de substratos nos entornos de matas (JARRON, 2020). Além disso, com os últimos avanços que implementaram a capacidade do LIDAR para detectar a estrutura morfológica de dosséis, tornou-se possível realizar trabalhos nos quais se estudam a altura e a densidade da vegetação e, ainda, seu relacionamento com a quantidade de biomassa por unidade de área, mostrando, também, boas correlações com os índices espectrais, como o NDVI (*Normalized Difference Vegetation Index*) e o NDRE (*Normalized Difference Red Edge*) (EITEL et al., 2016; WALTER et al., 2019). Destaca-se que, no caso do LIDAR, os problemas fitossanitários poderiam ser estimados indiretamente a partir desses parâmetros agrônômicos (INOUE; SAKAIYA; WANG, 2014; MCNAIRN; SHANG, 2016; CHAPARRO et al., 2018; LILIENTHAL; GERIGHAUSEN; SCHNUG, 2018).

A interpretação de dados de RADAR obtidos em áreas agrícolas, tem demonstrado ser complexa, e os avanços têm sido lentos em comparação com sensores óticos (BOUMAN et al., 1999). Esta situação persiste até do presente momento, inclusive para a classificação e o monitoramento da fitossanidade de culturas agrícolas (MUTANGA et al., 2017; ZHANG et al., 2019). Em relação à caracterização e à parametrização de diferentes variáveis agrônômicas a partir do emprego de dados de SAR, nos últimos anos, muito se avançou. Dessa forma, tornou-se possível a análise temporal de assinaturas de retrodispersão SAR em várias culturas. Também, foi possível a descoberta de altas correlações entre parâmetros de importância agrícola, tais como IAF, biomassa, fração absorvida da radiação fotossinteticamente ativa, conteúdo de água no de tecido, altura do cultivo, rendimento físico, entre outros.

A respeito da detecção direta de pragas, existem antecedentes de radares terrestres convencionais, que são empregados para monitorar a migração de insetos em determinados períodos do ano, incluindo radares meteorológicos (DRAKE, 2002; POFFO et al., 2018).

Wiseman et al. (2014) observaram diferenças na retrodispersão SAR na banda C entre áreas de soja, na mesma fase fenológica, devido às diferenças na densidade de semeadura e na biomassa total ($R^2=0,81$). Esses resultados demonstram que este mesmo modelo poderia ser utilizado para detectar zonas afetadas por pragas e doenças fúngicas, que representariam menor retrodispersão SAR.

No caso de áreas com a presença de plantas daninhas, a resposta retrodispersiva poderia ser maior, já que a biomassa destas, somada à dos cultivos, aumenta a dispersão volumétrica, como demonstrado por Oré et al. (2020) no cultivo de milho utilizando técnicas de interferometria diferencial (*Differential SAR. Interferometry - DinSAR*). Também, o retroespalhamento da polarização, derivada do RADARSAT-2 cruzada, pode ser utilizado para determinar o estágio de desenvolvimento de grãos de milho. Para esta aplicação, a polarização cruzada (VH ou HV) também tem a vantagem de ser insensível à direção da fileira de sombra (MCNAIRN; SHANG, 2016).

McNairn et al. (2014) citam que as bandas C e X do SAR são responsáveis pela identificação do

crescimento da canola, e caso seja possível determinar a umidade do solo durante o florescimento, é também possível determinar a suscetibilidade dessa cultura a fungos altamente sensíveis à acumulação de biomassa, possibilitando, assim, identificar o momento da floração e a transição até ao enchimento das vagens. Os mesmos autores encontraram que, para o cultivo do milho, a sensibilidade de alguns parâmetros polarimétricos das diferenças de altura do dossel e do IAF ($R^2=0,81$) pode ser útil para avaliar o estado geral da planta e o risco de ocorrência de doenças.

Assim como a LIDAR, a tecnologia SAR também apresenta bons desempenhos na caracterização de problemas associados à quebra de talos e ao tombamento das plantas. Han et al. (2017) mostraram que a retrodispersão SAR cruzada (VH) é sensível à altura da planta antes do tombamento, enquanto a soma VV (Vertical/Vertical) + VH (Vertical/Horizontal) representa a maior altura do dossel logo depois da ocorrência do problema. A diferença de altura antes e depois do tombamento, é utilizada para classificar o grau do problema em leve, moderado e severo. Isso possibilita a aplicação dessa tecnologia desde estudos do estado fitossanitário até ao emprego da informação na determinação de riscos agrícolas, passando por problemas climáticos, como a ocorrência de granizo, entre outros.

Para o monitoramento das condições fitossanitárias das culturas, a repetitividade é a chave. Em regiões tropicais ou temperadas úmidas e semiúmidas, o levantamento de dados de sensoriamento remoto óptico é frequentemente prejudicado por uma cobertura de nuvens. O SAR pode adquirir informações com alta resolução devido à sua capacidade operativa, independentemente do clima. Por outro lado, em grande parte dos estudos, tem sido demonstrado que a integração de dados ópticos com SAR e LIDAR são uma boa alternativa, quando comparado ao emprego separado das duas ferramentas. O uso combinado pode ser realizado simultaneamente ou em diferentes momentos durante o crescimento e pode melhorar as estimativas das variáveis próprias dos cultivos (GAO et al., 2013; JOSHI et al., 2016; ZHANG et al., 2019).

Radares entomológicos fornecem medidas de atividade de voo, volume e fluxo de populações de insetos. Ainda, alguns podem fornecer informações sobre a trajetória e, também, a identidade do inseto (DRAKE, 2002; DRAKE; REYNOLDS, 2012; DRAKE et al., 2017). Chapman et al. (2005) utilizaram um radar de observação vertical e estudaram a migração do besouro predador *Notiophilus biguttatus* (Duméril) (Coleoptera: Carabidae).

A utilização de radares meteorológicos também é muito comum no monitoramento de populações de insetos. Porém, neste caso, são necessárias informações auxiliares da espécie monitorada, que são obtidas por observação visual, armadilhas ou radares entomológicos de observação vertical (HUPPOP et al., 2018).

Outra forma utilizada no monitoramento de pragas é a radiotelemetria. Nesta técnica, um dispositivo que emite um sinal de rádio é afixado ao animal, que retorna o sinal para o radar com o dobro da frequência transmitida. Neste caso, o receptor, o radar harmônico, é ajustado para a frequência adequada (KISSLING et al., 2014). Essa tecnologia já foi utilizada no monitoramento de abelhas, na dispersão de borboletas e no monitoramento de pragas de importância agrícola (BEAUDOIN-OLLIVIER et al., 2003; CANT et al., 2005; LIHOREAU et al., 2012; FISCHER et al., 2014).

6 AVANÇOS E DESAFIOS

Com o aumento da pressão populacional em todo o mundo e a necessidade de aumento da produção agrícola, há uma necessidade definitiva de melhoria na gestão dos recursos agrícolas mundiais. Para fazer isso acontecer, primeiro é necessário obter dados não apenas sobre os tipos de recursos, mas também sobre a qualidade, a quantidade e a localização desses recursos. Assim, monitorar doenças e pragas de forma confiável, aceitável e eficiente, ao longo de extensas áreas, tornou-se muito importante para a avaliação e a gestão agrícola.

O maior desafio para pesquisadores, novos ou experientes, de sensoriamento remoto é perceber o potencial dessa tecnologia como fonte útil de informações que podem ser usadas para decisões de manejo fitossanitário. Isso requer expansão e aprimoramento constantes de nossa base de conhecimento. Dessa forma, a comunidade científica tem a seguinte problemática: como unir características tão distintas e únicas dos sensores em um equipamento capaz de ser usado em campo, na grande abrangência de problemas fitossanitários, trazendo informações em tempo real? Um exemplo de dificuldade apresentada em alguns

trabalhos é a tentativa de correlação de dados multiescala, visando a utilização da riqueza de detalhes do sensoriamento hiperespectral, aliada à facilidade de operação e ao menor custo dos sensores multiespectrais.

Por fim, espera-se que esta revisão dos avanços da pesquisa de ponta no monitoramento de doenças e pragas utilizando sensoriamento remoto, possa provocar novos pensamentos e promover o desenvolvimento de novas técnicas e metodologias. É possível, a multidisciplinariedade na pesquisa, responder questionamentos levantados pelo sensoriamento remoto e complementar estes com pesquisas mais robustas e complexas, visando evitar resultados falso-negativo ou falso-positivo? Para tanto, é indispensável o avanço da inter e multidisciplinariedade das pesquisas, no intuito de se extrair o máximo potencial das áreas correlatas da ciência, desde o nível de entendimento dos processos fisiológicos das plantas estressadas, até à análise e ao processamento dos dados, passando pelo desenvolvimento de sensores e de plataformas de coleta, proporcionando a otimização da aquisição de dados.

Agradecimentos

Os autores agradecem à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo), processo nº 2017/19407-4, pelo apoio.

Contribuição dos Autores

As contribuições dos autores no desenvolvimento deste trabalho são: responsável pelos itens “Introdução” e “Avanços e desafios”, Pedro Paulo da Silva Barros; responsável pelo item “Sensores multiespectrais”, assim como pela estruturação e revisão geral como autor correspondente do artigo, David Luciano Rosalen; responsável pelo item “Sensores hiperespectrais”, Fernando Henrique Iost Filho; responsável pelo item “Definições e base teórica”, George Deroco Martins; responsável pelo item “Sensores ativos”, Néstor Di Leo.

Conflitos de Interesse

Os autores declaram que não há conflito de interesse.

Referências

- AASEN, H.; HONKAVAARA, E.; LUCIEER, A.; ZARCO-TEJADA, P. J. Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: a review of sensor technology, measurement procedures, and data correction workflows. **Remote Sensing**, Basel, v. 10, n. 7, p. 1091, 2018. DOI: 10.3390/rs10071091.
- ADÃO, T.; HRUŠKA, J.; PÁDUA, L.; BESSA, J.; PERES, E.; MORAIS, R.; SOUSA, J. J. Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. **Remote Sensing**, Basel, v. 9, n. 11, p. 1110, 2017. DOI: :10.3390/rs9111110.
- ADELABU, S.; MUTANGA, O.; ADAM, E. Evaluating the impact of red-edge band from Rapideye image for classifying insect defoliation levels. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam v. 95, p. 34-41, 2014. DOI: 10.1016/j.isprsjprs.2014.05.013.
- AGRAWAL, S.; KHAIRNAR, G. B. Comparative assessment of remote sensing imaging techniques: optical, SAR and LiDAR. **ISPRS - The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, Amsterdam, v. 42, n. 5/W3, p. 1-6, 2019. DOI: 10.5194/isprs-archives-XLII-5-W3-1-2019
- APAN, A.; HELD A.; PHINN, S.; MARKLEY, J. Detecting sugarcane ‘orange rust’ disease using EO-1 Hyperion hyperspectral imagery. **International journal of remote sensing**, v. 25, n. 2, p. 489-498, 2004.
- ASHOORLOO, D. A.; MATKAN, A.; HUETE, A.; AGHIGHI, H.; MOBASHERI, M.R. Developing an Index

- for Detection and Identification of Disease Stages. **IEEE Geoscience and Remote Sensing Letters**, Nova Iorque, v. 13, n. 6, p. 851-855, 2016. DOI. 10.1109/LGRS.2016.2550529.
- BACKOULOU, G. F.; ELLIOTT, N. C.; GILES, K. L.; ALVES, T. M. Using multispectral imagery to map spatially variable sugarcane aphid infestations in sorghum. **Southwestern Entomologist**, Washington DC, v. 43, n. 1, p. 37-44, 2018. DOI. 10.3958/059.043.0122.
- BACKOULOU, G. F.; ELLIOTT, N. C.; GILES, K. L. Using multispectral imagery to compare the spatial pattern of injury to wheat caused by Russian wheat aphid and greenbug. **Southwestern Entomologist**, Washington DC, v. 41, n. 1, p. 1-8, 2016. DOI. 10.3958/059.041.0101.
- BAGHERI, N. Application of aerial remote sensing technology for detection of Fire Blight infected pear trees. **Computers and Electronics in Agriculture**, Amsterdam, v. 168, p. 105147, 2020. DOI. 10.1016/j.compag.2019.105147.
- BARNES, Jeremy D. et al. A reappraisal of the use of DMSO for the extraction and determination of chlorophylls a and b in lichens and higher plants. **Environmental and Experimental botany**, v. 32, n. 2, p. 85-100, 1992.
- BARRERO, O.; PERDOMO, S. A. RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. **Precision Agriculture**, Amsterdam, v. 19, n. 5, p. 809-822, 2018. DOI. 10.1007/s11119-017-9558-x
- BEAUDOIN-OLLIVIER, L.; BONACCORSO, F.; ALOYSIUS, M.; KASIKI, M. Flight movement of *Scapanes australis australis* (Boisduval) (Coleoptera: Scarabaeidae: Dynastinae) in Papua New Guinea: a radiotelemetry study. **Australian Journal of Entomology**, New Jersey, v. 42, n. 4, p. 367-372, 2003. DOI. 10.1046/j.1440-6055.2003.00369.x.
- BETBEDER, J.; FIEUZAL, R.; BAUP, F. Assimilation of LAI and dry biomass data from optical and SAR images into an agro-meteorological model to estimate soybean yield. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Nova Iorque, v. 9, n. 6, p. 2540-2553, 2016. DOI. 10.1109/JSTARS.2016.2541169
- BOUMAN, B. A. M.; VAN KRAALINGEN, D. W.; STOL, W.; VAN LEEUWEN, H. J. C. An agroecological modeling approach to explain ERS SAR radar backscatter of agricultural crops. **Remote Sensing of Environment**, Amsterdam, v. 67, n. 2, p. 137-146, 1999. DOI. 10.1016/S0034-4257(96)00178-2.
- CABALLERO, D.; CALVINI, R.; AMIGO, J. M. Hyperspectral imaging in crop fields: precision agriculture. In: AMIGO, J. M. (Ed.). **Data Handling in Science and Technology: Hyperspectral Imaging**. Amsterdam: Elsevier, 2020. p. 453-473.
- CAMPOS, J.; GALLART, M.; LLOP, J.; ORTEGA, P.; SALCEDO, R. GIL, E. On-farm evaluation of prescription map-based variable rate application of pesticides in vineyards. **Agronomy**, Madison, v. 10, n. 1, 2020. DOI. 10.3390/agronomy10010102.
- CANT, E. T.; SMITH, A. D.; REYNOLDS, D. R.; OSBORNE, J. L. Tracking butterfly flight paths across the landscape with harmonic radar. **Proceedings of the Royal Society B: Biological Sciences**, Londres, v. 272, n. 1565, p. 785-790, 2005. DOI. 10.1098/rspb.2004.3002
- CARDIL, A.; OTSU, K.; PLA, M.; SILVA, C. A.; BROTONS, L. Quantifying pine processionary moth defoliation in a pine-oak mixed forest using unmanned aerial systems and multispectral imagery. **PLoS ONE**, San Francisco, v. 14, n. 3, p. e0213027, 2019. DOI. 10.1371/journal.pone.0213027.
- CHAPARRO, D.; PILES, M.; VALL-LLOSSERA, M.; CAMPS, A.; KONINGS, A. G.; ENTEKHABI, D. L-band vegetation optical depth seasonal metrics for crop yield assessment. **Remote Sensing of Environment**, Amsterdam, v. 212, p. 249-259, 2018. DOI. 10.1016/j.rse.2018.04.049.
- CHAPMAN, J. W.; REYNOLDS, D. R.; SMITH, A. D.; RILEY, J. R.; TELFER, M. G.; WOIWOD, I. P. Mass aerial migration in the carabid beetle *Notiophilus biguttatus*. **Ecological Entomology**, New Jersey, v. 30, n. 3, p 264-272, 2005. DOI. 10.1111/j.0307-6946.2005.00702.x.
- CHO, M. A.; DEBBA, P.; MUTANGA, O.; DUDENI-TIHONE, N.; MAGADLA, T.; KHULUSE, S. A. Potential utility of the spectral red-edge region of SumbandilaSat imagery for assessing indigenous forest

- structure and health. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 16, p. 85-93, Jan. 2012. DOI. 10.1016/j.jag.2011.12.005.
- COLWELL, J. E. Vegetation canopy reflectance. **Remote Sensing of Environment**, Amsterdam, v. 3, n. 3, p. 175-183, 1974. DOI. 10.1016/0034-4257(74)90003-0.
- CONTINENTAL CORPORATION. **ARS 408**. Disponível em: <<https://www.ibeo-as.com/en/products>>. Acesso em 14 nov. 2020.
- DADRASJAVAN, F. et al. UAV-based multispectral imagery for fast citrus greening detection. **Journal of Plant Diseases and Protection**, Berlin, v. 126, n. 4, p. 307–318, 2019. DOI. 10.1007/s41348-019-00234-8.
- DAUGHTRY, C. S. T. WALTHALL, C.L.; KIM, M. S.; BROWN DE COLSTOUN, E.; MC MURTREY, J. E. III. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.
- DHAU, I.; ADAM, E.; MUTANGA, O.; AYISI, K. K. Detecting the severity of maize streak virus infestations in maize crop using in situ hyperspectral data. **Transactions of the Royal Society of South Africa**, Oxfordshire, v. 73, p. 8-15, 2018. DOI. 10.1080/0035919X.2017.1370034
- DRAKE, A. Automatically operating radars for monitoring insect pest migrations. **Insect Science**, New Jersey, v. 9, n. 4, p. 27-39, 2002. DOI. 10.1111/j.1744-7917.2002.tb00169.x
- DRAKE, V. A.; REYNOLDS, D. R. **Radar entomology: observing insect flight and migration**. Cabi, 2012.
- DRAKE, V. A.; CHAPMAN, J. W.; LIM, K. S.; REYNOLDS, D. R.; RILEY, J. R.; SMITH, A. D. Ventral-aspect radar cross sections and polarization patterns of insects at X band and their relation to size and form. **International Journal of Remote Sensing**, Oxfordshire, v. 38, n. 18, p. 5022-5044, 2017. DOI. 10.1080/01431161.2017.1320453.
- EITEL, J. U. H.; MAGNEY, T. S.; VIERLING, L. A.; BROWN, T. T.; HUGGINS, D. R. LiDAR based biomass and crop nitrogen estimates for rapid, non-destructive assessment of wheat nitrogen status. **Field Crops Research**, Amsterdam, v. 159, p. 21–32, 2014. DOI. 10.1016/j.fcr.2014.01.008
- FISCHER, J.; MUELLER, T.; SPATZ, A. K.; GREGGERS, U.; GRUENEWALD, B.; MENZEL, R. Neonicotinoids interfere with specific components of navigation in honeybees. **PloS one**, San Francisco, v. 9, n. 3, p. e91364, 2014. DOI. 10.1371/journal.pone.0091364
- FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina de Textos, 2011. 128 p. ISBN 8579750644.
- GAO, J.; NUYTENS, D.; LOOTENS, P.; HE, Y.; PIETERS, J. G. Recognizing weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. **Biosystems Engineering**, Amsterdam, v. 170, p. 39-50, 2018. DOI. 10.1016/j.biosystemseng.2018.03.006
- GAO, S.; NIU, Z., HUANG, N., HOU, X. Estimating the Leaf Area Index, height and biomass of maize using HJ-1 and RADARSAT-2. **International Journal of Applied Earth Observation & Geoinformation**, Amsterdam, v. 24, p. 1–8, 2013. DOI. 10.1016/j.jag.2013.02.002
- GAŠPAROVIĆ, M.; ZRINJSKI, M.; BARKOVIĆ, D.; RADOCAJ, D. An automatic method for weed mapping in oat fields based on UAV imagery. **Computers and Electronics in Agriculture**, Amsterdam, v. 173, p. 105385, 2020. DOI. 10.1016/j.compag.2020.105385
- GODFRAY, H. C. J.; BEDDINGTON, J. R.; CRUTE, I. R.; HADDAD, L.; LAWRENCE, D.; MUIR, J. F.; PRETTY, J.; ROBINSON, S.; THOMAS, S. M.; TOULMIN, C. Food security: the challenge of feeding 9 billion people. **Science**, Washington DC, v. 327, n. 5967, p. 812-818, 2010. DOI. 10.1126/science.1185383
- GOLHANI, K.; BALASUNDRAM, S. K.; VADAMALAI, G.; PRADHAN, B. A review of neural networks in plant disease detection using hyperspectral data. **Information Processing in Agriculture**, v. 5, n. 3, p. 354-371, 2018. DOI. 10.1016/j.inpa.2018.05.002
- GONGORA-CANUL, C.; SALGADO, J. D.; SINGH, D.; CRUZ, A. P.; COTROZZI, L.; COUTURE, J.; RIVADENEIRA, M. G.; CRUPPE, G.; VALENT, B.; TODD, T.; POLAND, J.; CRUZ, C. D. Temporal

- dynamics of wheat blast epidemics and disease measurements using multispectral imagery. **Phytopathology**, St. Paul, v. 110, n. 2, p. 393–405, 2020. DOI. 10.1094/PHYTO-08-19-0297-R
- HAN, D.; YANG, H.; YANG, G.; QIU, C. Monitoring model of corn lodging based on Sentinel-1 radar image. In: **SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA)**, 2017, Beijing. **Proceedings...** Beijing, 2017. p. 1-5. DOI. 10.1109/BIGSAR DATA.2017.8124928.
- HUANG, Y.; LEE, M. A.; THOMSON, S. J.; REDDY, K. N. Ground-based hyperspectral remote sensing for weed management in crop production. **International Journal of Agricultural and Biological Engineering**, Beijing, v. 9, n. 2, p. 98-109, 2016.
- HUANG, J. R.; SUN, J.Y.; LIAO, H. J.; LIU, X. D. Detection of brown planthopper infestation based on SPAD and spectral data from rice under different rates of nitrogen fertilizer. **Precision Agriculture**, Berlin, v. 16, n. 2, p. 148-163, 2015. DOI. 10.1007/s11119-014-9367-4
- HUNTER III, J. E. **Integration of Unmanned Aerial Vehicles (UAVs) for Remote-sensing and Spray Applications for Weed Management**. 2019. 84 f. Dissertação (Mestre em Crop Science) – Universidade da Carolina do Norte, Raleigh, 2019.
- HÜPPOP, O.; CIACH, M.; DIEHL, R.; REYNOLDS, D. R.; STEPANIAN, P. M.; MENZ, M. H. Perspectives and challenges for the use of radar in biological conservation. **Ecography**, New Jersey, v. 42, n 5, p 912-930, 2018. DOI. 10.1111/ecog.04063
- INGRAM, J. A food systems approach to researching food security and its interactions with global environmental change. **Food Security**, Berlin, v. 3, n. 4, p. 417-431, 2011. DOI. 10.1007/s12571-011-0149-9
- INOUE, Y.; SAKAIYA, E.; WANG, C. Capability of C-band backscattering coefficients from high-resolution satellite SAR sensors to assess biophysical variables in paddy rice. **Remote Sensing of Environment**, Amsterdam, v. 140, p. 257-266, 2014. DOI. 10.1016/j.rse.2013.09.001
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **China-Brazil Earth-Resources Satellite (CBERS)**. Disponível em: <<http://www.cbears.inpe.br/>>. Acesso em 20 out. 2020.
- IBEO AUTOMOTIVES. **Products**. Disponível em: <<https://www.ibeo-as.com/en/products>>. Acesso em 14 nov. 2020.
- IOST FILHO, F. H.; HELDENS, W. B.; KONG, Z.; LANGE, E.S. Drones: Innovative Technology for Use in Precision Pest Management. **Journal of economic entomology**, Washington DC, v. 113, n. 1, p. 1–25, 8 fev. 2020. DOI. 10.1093/jee/toz268.
- JAROLMASJED, S.; SANKARAN, S.; MARZOUGUI, A.; KOSTICK, S.; SI, Y.; VARGAS, J. J. Q.; EVANS, K. High-throughput phenotyping of fire blight disease symptoms using sensing techniques in apple. **Frontiers in Plant Science**, Lausanne, v. 10, n. May, p. 576, 2019. DOI. 10.3389/fpls.2019.00576
- JARRON, L. R.; COOPS, N. C.; MACKENZIE, W. H.; TOMPALSKI, P.; DYKSTRA, P. Detection of sub-canopy forest structure using airborne LiDAR. **Remote Sensing of Environment**, Amsterdam, v. 244, p. 111770, July 2020. DOI. 10.1016/j.rse.2020.111770
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução da 2ª ed. por (pesquisadores do INPE). In: EPIPHANIO, J. C. N. (coordenador); FORMAGGIO, A. R.; SANTOS, A. R.; RUDORFF, B. F. T.; ALMEIDA, C. M.; GALVÃO, L. S. São José dos Campos: Parêntese. 672 p, 2009.
- JETZ, W.; CAVENDER-BARES, J.; PAVLICK, D.; DAVIS, F. W.; ASNER, G. P.; GURALNICK, R.; KATTGE, J.; LATIMER, A. M.; MOORCROFT, P.; SCHAEPMAN, M. E.; SCHILDHAUER, M. P.; SCHNEIDER, F. D.; SCHRODT, F.; STAHL, U.; USTIN, S. L. Monitoring plant functional diversity from space. **Nature Plants**, Berlin, v. 2, n.3, p. 1-5, 2016. DOI. 10.1038/nplants.2016.24
- JOALLAND, S.; SCREPANTI, C.; VARELLA, H. V.; REUTHER, M.; SCHWIND, M.; LANG, C.; WALTER, A.; LIEBISCH, F. Aerial and ground based sensing of tolerance to beet cyst nematode in sugar beet. **Remote Sensing**, Madison, v. 10, n. 5, p. 787, 2018. DOI. 10.3390/rs10050787
- JOSHI, N.; BAUMANN, M.; EHAMMER, A.; FENSHOLT, R.; GROGAN, K.; HOSTERT, P.; JEPSEN, R.

- M.; KUEMMERLE, T.; MEYFROIDT, P.; MITCHARD, E. T. A.; REICHE, J.; RYAN, C. M.; WASKE, B. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. **Remote Sensing**, Madison, v. 8, n. 1, p. 70, 2016. DOI. 10.3390/rs8010070
- KERCHEV, P. I.; FENTON, B.; FOYER, C. H.; HANCOCK, R. D. Plant responses to insect herbivory: interactions between photosynthesis, reactive oxygen species and hormonal signalling pathways, **Plant, Cell and Environment**, New Jersey, v. 35, n. 2, p. 441-453, 2012. DOI. 10.1111/j.1365-3040.2011.02399.x
- KIM, M. S. **The Use of Narrow Spectral Bands for Improving Remote Sensing Estimations of Fractionally Absorbed Photosynthetically Active Radiation**. 75f. Thesis (Master of Arts) - Faculty of The Graduate School of The University of Maryland, College Park, 1994.
- KISSLING, W. D.; PATTEMORE, D. E.; HAGEN, M. Challenges and prospects in the telemetry of insects. **Biological Reviews**, v. 89, n. 3, p. 511-530, 2014. DOI. 10.1111/brv.12065.
- KOST, C.; HEIL, M. Herbivore-induced plant volatiles induce an indirect defence in neighbouring plants: Airborne volatiles induce indirect plant defence. **Journal of Ecology**, New Jersey, v. 94, n. 3, p. 619–628, 16 fev. 2006. DOI. 10.1111/j.1365-2745.2006.01120.x
- KUMBULA, S. T.; MAFONGOYA, P.; PEERBHAY, K. Y.; LOTTERING, R. T.; ISMAIL, R. Using Sentinel-2 multispectral images to map the occurrence of the Cossid moth (*Coryphodema tristis*) in Eucalyptus nitens plantations of Mpumalanga, South Africa. **Remote Sensing**, Madison, v. 11, n. 3, p. 278, 2019. DOI. 10.3390/rs11030278
- LIHOREAU, M.; RAINE, N. E.; REYNOLDS, A. M.; STELZER, R. J.; LIM, K. S.; SMITH, A. D.; OSBORNE, J. L.; CHITTKA, L. Radar tracking and motion-sensitive cameras on flowers reveal the development of pollinator multi-destination routes over large spatial scales. **PLoS Biology**, San Francisco, v. 10, n. 9, p. e1001392, 2012. DOI. 10.1371/journal.pbio.1001392
- LILIENTHAL, H.; GERIGHAUSEN, H.; SCHNUG, E. Agricultural remote sensing information for farmers in Germany. In: 14th International Conference on Precision Agriculture, 2018, Montreal. **Proceedings...** Montreal: ISPA, 2018.
- LIU, W. T. H. **Aplicações de sensoriamento remoto**. 2. ed. Campo Grande: Oficina de Textos, 2015. 908 p. ISBN 8579751772.
- LIU, C. A.; CHEN, Z. X.; SHAO, Y.; CHEN, J. S.; HASI, T.; PAN, H. Z. Research advances of SAR remote sensing for agriculture applications: A review. **Journal of Integrative Agriculture**, Amsterdam, v. 18, n. 3, p. 506-525, 2019. DOI. 10.1016/S2095-3119(18)62016-7
- LIU H.; CHAHL, J. S. A multispectral machine vision system for invertebrate detection on green leaves. **Computers and Electronics in Agriculture**, Amsterdam, v. 150, p. 279–288, 2018. DOI. 10.1016/j.compag.2018.05.002
- LIU H.; LEE S.; CHAHL, J. S. Registration of multispectral 3D points for plant inspection. **Precision Agriculture**, Berlin, v. 19, n. 3, p. 513–536, 2018. DOI. 10.1007/s11119-017-9536-3
- LOWE, A.; HARRISON, N.; FRENCH, A. P. Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. **Plant Methods**, Berlin, v. 13, n. 1, p. 80, 2017. DOI. 10.1186/s13007-017-0233-z
- LU, J.; EHSANI, R.; SHI, Y.; DE CASTRO, A. I.; WANG, S. Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. **Scientific Reports**, Berlin, v. 8, n.1, p. 1-11, 2018. DOI. 10.1038/s41598-018-21191-6
- MARTINS, G. D.; GALO, M. L. B. T. Detecção de áreas infestadas por nematoides e *Migdolus fryanus* em cultura canavieira a partir de imagens multiespectrais Rapideye. **Revista Brasileira de Cartografia**, Monte Carmelo, n. 66/2, p. 285–301, 2014.
- MARTINS, G. D.; GALO, M. L. B. T.; VIEIRA, B. S. Detecting and mapping root-knot nematode infection in coffee crop using remote sensing measurements. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Nova Iorque, v. 10, n. 12, p. 5395-5403, 2017. DOI.

10.1109/JSTARS.2017.2737618.

- MATEEN, A.; ZHU, Q. Weed detection in wheat crop using UAV for precision agriculture. **Pakistan Journal of Agricultural Sciences**, Faisalabad, v. 56, n. 3, p. 809–817, 2019. DOI. 10.21162/PAKJAS/19.8116
- MCNAIRN, H.; WISEMAN, G.; POWERS, J.; MERZOUKI, A.; SHANG, J. Assessment of disease risk in canola using multi-frequency SAR: preliminary results. In: 10th European Conference on Synthetic Aperture Radar, 2014. **Proceedings...** Berlin, VDE, 2014. p. 1-4.
- McNAIRN, H.; SHANG, J. A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. In: BAN, Y. (Ed.) **Multitemporal Remote Sensing. Remote Sensing and Digital Image Processing**, v. 20. Berlin: Springer, 2016. p. 317-340. DOI. 10.1007/978-3-319-47037-5_15
- MICASENSE. **Dual Camera Imaging System**. Disponível em: <<https://micasense.com/pt-br/sistema-de-camera-dual/>>. Acesso em 14 nov. 2020.
- MIRIK, M.; MICHELS, G. J.; MIRIK, S. K.; ELLIOTT N. C.; BOWLING, R. Hyperspectral spectrometry as a means to differentiate uninfested and infested winter wheat by greenbug (Hemiptera: Aphididae). **Journal of economic entomology**, v. 99, n. 5, p. 1682-1690, 2006a.
- MIRIK, M.; MICHELS, G. J.; MIRIK, S. K.; ELLIOTT, N. C.; CANTANA, V.; JONES, D. B.; BOWLING, R. Using digital image analysis and spectral reflectance data to quantify damage by greenbug (Hemiptera: Aphididae) in winter wheat. **Computers and electronics in agriculture**, v. 51, n. 1-2, p. 86-98, 2006b.
- MISHRA, P.; ASAARI, M. S. M.; HERRERO-LANGREO, A.; LOHUMI, S.; DIEZMA, B.; SCHEUNDERS, P. Close range hyperspectral imaging of plants: A review. **Biosystems Engineering**, Amsterdam, v. 164, p. 49-67, 2017. DOI. 10.1016/j.biosystemseng.2017.09.009
- MOGHADAM, P.; WARD, D.; GOAN, E.; JAYAWARDENA, S.; SIKKA, P.; HERNANDEZ, E. Plant disease detection using hyperspectral imaging. In: 2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA). **Proceedings...** Sidney: IEEE, 2017. p. 1-8.
- MORAN, M. S.; HYMER, D. C.; QI, J.; KERR, Y. Comparison of ERS-2 SAR and Landsat TM imagery for monitoring agricultural crop and soil conditions. **Remote Sensing of Environment**, Amsterdam, v. 79, n. 2-3, p. 243-252, 2002. DOI. 10.1016/S0034-4257(01)00276-0
- MUTANGA, O.; DUBE, T.; GALAL, O. Remote sensing of crop health for food security in Africa: Potentials and constraints. **Remote Sensing Applications: Society and Environment**, Amsterdam, v. 8, p. 231-239, 2017. DOI. 10.1016/j.rsase.2017.10.004
- NANSEN, C. Use of variogram parameters in analysis of hyperspectral imaging data acquired from dual-stressed crop leaves. **Remote Sensing**, Madison, v. 4, n. 1, p. 180-193, 2012. DOI. 10.3390/rs4010180
- NANSEN, C. The potential and prospects of proximal remote sensing of arthropod pests. **Pest Management**, New Jersey, v. 72, n. 4, p. 653-659, 2016. DOI. 10.1002/ps.4209
- NANSEN, C.; ELLIOTT, N. Remote sensing and reflectance profiling in entomology. **Annual Review of Entomology**, Palo Alto, v. 61, p. 139-158, 2016. DOI. 10.1146/annurev-ento-010715-023834
- NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). Earth Data Learn Section. **Remote Sensors**. Washington D. C. 2020. Disponível em <<https://earthdata.nasa.gov/learn/remote-sensors>> Acesso 6 jul. 2020.
- NATIONS, United. World population prospects: the 2017 revision, key findings and advance tables. **Department of Economics and Social Affairs PD, editor**. New York: United Nations, 2017.
- NGUYEN, H. D. D.; NANSEN, C. Hyperspectral remote sensing to detect leafminer induced stress in bok choy and spinach according to fertilizer regime and timing. **Pest Management Science**, New Jersey, v. 76, n. 6, p. 2208-2216, 2020. DOI. 10.1002/ps.5758
- NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. 4. ed. São Paulo: Blucher, 2010.
- ORÉ, G.; ALCÂNTARA, M. S.; GÓES, J. A.; OLIVEIRA, L. P.; YEPES, J.; TERUEL, B.; MOREIRA, L. F. Crop Growth Monitoring with Drone-Borne DInSAR. **Remote Sensing**, Madison, v. 12, n. 4, p. 615. 2020. DOI: 10.3390/rs12040615
- PANTAZI, X. E.; MOSHOU, D.; BRAVO, C. Active learning system for weed species recognition based on

- hyperspectral sensing. **Biosystems Engineering**, Amsterdam, v. 146, p. 193-202, 2016. DOI. 10.1016/j.biosystemseng.2016.01.014
- PETERSON, R. K. D.; HIGLEY, L. G. (EDS.). **Biotic stress and yield loss**. Boca Raton, FL: CRC Press, 2001.
- PINTO-ZEVALLOS, D. M. et al. Compostos orgânicos voláteis na defesa induzida das plantas contra insetos herbívoros. **Química Nova**, São Paulo, v. 36, n. 9, p. 1395–1405, 2013. DOI. 10.1590/S0100-40422013000900021
- PLANT, R. E. Site-specific management: the application of information technology to crop production. **Computers and Electronics in Agriculture**, Amsterdam, v. 30, n. 1-3, p. 9-29, 2001. DOI. 10.1016/S0168-1699(00)00152-6
- POFFO D. A.; BECCACECE H. M.; CARANTI, G.; COMES, R. A.; DREWNIAK, M. E.; MARTINA, A.; ZAPATA, A. I.; RODRIGUEZ, A.; SAFFE, J. N. Migration monitoring of *Ascia monuste* (Lepidoptera) and *Schistocerca cancellata* (Orthoptera) in Argentina using RMA1 weather radar. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 145, p. 340-348, 2018. DOI. 10.1016/j.isprsjprs.2018.05.011
- PRABHAKAR, M.; PRASAD, Y.; RAO, M. N. Remote sensing of biotic stress in crop plants and its applications for pest management. In: **Crop stress and its management: Perspectives and strategies**. [s.l.] Springer, 2012. p. 517–545.
- QIN, L.; WANG, X.; JIANG, J.; YANG, X.; KE, D.; LI, H.; WANG, D. Use hyperspectral remote sensing technique to monitoring pine wood nematode disease preliminary. In: **Hyperspectral Remote Sensing Applications and Environmental Monitoring and Safety Testing Technology**. International Society for Optics and Photonics, 2016. p. 101561L.
- RICHARDS, J. A. **Remote Sensing with Imaging Radar**. Berlin: Springer-Verlag, 2009. https://doi.org/10.1007/978-3-642-02020-9_6
- RIFFEL, A. Os Voláteis de Plantas e o seu Potencial para a Agricultura. **Embrapa Documento**, p. 50, 2015.
- RIGHETTO, A. J.; RAMIRES, T. G.; NAKAMURA, L. R.; CASTANHO, P. L. D. B.; FAES, C.; SAVIAN, T. V. Predicting weed invasion in a sugarcane cultivar using multispectral image. **Journal of Applied Statistics**, Oxfordshire, v. 46, n. 1, p. 1–12, 2019. DOI. 10.1080/02664763.2018.1450362
- ROSALEN, D. L. et al. Caracterização altimétrica através de sensor multiespectral embarcado em aeronave remotamente pilotada. **Anais...** In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 27. Rio de Janeiro: 2017
- ROSALEN, D. L. Veículo aéreo não tripulado – VANT: Conceituação e utilização na agricultura. In: **Processos Agrícolas e Mecanização da Cana-de-açúcar**. 1 ed. Jaboticabal: SBEA, 2015, p. 589-600.
- ROUSE, J. W. J.; HAAS, H. R.; SCHELL, A. J.; DEERING, W. D. Monitoring vegetation systems in the Great Plains with ERTS. In: **NASA special publication 1**, 2017, p. 309–317.
- SABINS JR, F. F.; ELLIS, J. M. **Remote Sensing: Principles, Interpretation, and Applications**. 4. ed. Long Grove: Waveland Press, 2020.
- SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2-3, p. 337-354, 2002.
- SENOP. **SENOP HSC-2 hyperspectral camera**. Disponível em: <<https://senop.fi/product/hsc-2-hyperspectral-camera-500-900nm-c-mount/>>. Acesso em 14 nov. 2020.
- 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**, Berlin, v. 17, n. 6, p. 659–677, Dec 2016. DOI. 10.1007/s11119-016-9442-0
- SHI, Y.; HUANG, W.; LUO, J.; HUANG, L.; ZHOU, X. Detection and discrimination of pests and diseases

- in winter wheat based on spectral indices and kernel discriminant analysis. **Computers and Electronics in Agriculture**, Amsterdam, v. 141, p. 171–180, 2017. DOI. 10.1016/j.compag.2017.07.019
- SHRIVASTAVA, G.; ROGERS, M.; WSZELAKI, A.; PANTHEE, D. R.; CHEN, F. Plant Volatiles-based Insect Pest Management in Organic Farming. **Critical Reviews in Plant Sciences**, Oxfordshire, v. 29, n. 2, p. 123–133, Mar. 2010. DOI. 10.1080/07352681003617483
- SINGH, K. D.; NANSEN, C. Advanced calibration to improve robustness of drone-acquired hyperspectral remote sensing data. In: 6th International Conference on Agro-Geoinformatics, 2017, Fairfax. **Anais...** Fairfax: IEEE, 2017. p. 1-6.
- SUDBRINK, D.; THOMSON, S. J.; FLETCHER, R. S.; HARRIS, A.; ENGLISH, P. J.; ROBBINS, J. T. Remote Sensing of Selected Winter and Spring Host Plants of Tarnished Plant Bug (Heteroptera: Miridae) and Herbicide Use Strategies as a Management Tactic. **American Journal of Plant Sciences**, Irvine, v. 06, n. 8 p. 1313–1327, Jan. 2015. DOI. 10.4236/ajps.2015.68131
- SUSIČ, N.; ŽIBRAT, U.; ŠIRCA, S.; STRAJNAR, P.; RAZINGER, J.; KNAPIČ, M.; VONČINA, A.; UREK, G.; STARE, B. G. Discrimination between abiotic and biotic drought stress in tomatoes using hyperspectral imaging. **Sensors and actuators B: Chemical**, Amsterdam, v. 273, p. 842-852, Nov. 2018. DOI. 10.1016/j.snb.2018.06.121
- TAN, Y.; SUN, J. Y.; ZHANG, B.; CHEN, M.; LIU, Y.; LIU, X. D. Sensitivity of a ratio vegetation index derived from hyperspectral remote sensing to the brown planthopper stress on rice plants. **Sensors**, Madison, v. 19, n. 2, p. 375, 2019. DOI. 10.3390/s19020375
- THOMAS, S.; KUSKA, M.T.; BOHNENKAMP, D.; BRUGGER, A.; ALISAAC, E.; WAHABZADA, M.; BEHMANN, J.; MAHLEIN, A.K. Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. **Journal of Plant Diseases and Protection**, Berlin, v. 125, n. 1, p. 5-20, 2018. DOI. 10.1007/s41348-017-0124-6
- TIAN, J.; PHILPOT, W. D. Relationship between surface soil water content, evaporation rate, and water absorption band depths in SWIR reflectance spectra. **Remote Sensing of Environment**, Amsterdam, v. 169, p. 280–289, Nov. 2015. DOI. 10.1016/j.rse.2015.08.007
- TILMAN, D.; CLARK, M. Global diets link environmental sustainability and human health. **Nature**, Berlin, v. 515, n. 7528, p. 518-522, 2014. DOI. 10.1038/nature13959
- TITTLE, S. B. **Effect of spectral band selection and bandwidth on weed detection in agricultural fields using hyperspectral remote sensing**. 125 f. Tese (Doutorado em Ciências Ambientais) - College of Agriculture, Montana State University, Bozeman, 2017.
- TULCHINSKY, T. H. Micronutrient deficiency conditions: global health issues. **Public health reviews**, Berlin, v. 32, n. 1, p. 243-255, 2010. DOI.
- TURNER, W. Sensing biodiversity. **Science**, Washington DC, v. 346, n. 6207, p. 301-302, 2014. DOI. 10.1126/science.1256014
- UTO, K.; SEKI, H.; SAITO, G.; KOSUGI, Y.; KOMATSU, T. Development of a low-cost, lightweight hyperspectral imaging system based on a polygon mirror and compact spectrometers. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Nova Iorque, v. 9, n. 2, p. 861-875, 2015. DOI. 10.1109/JSTARS.2015.2472293.
- UPPALA, D.; Venkataa, R. K.; Polojua, S.; Ramaa, S. M. V.; Dadhwala, V. K. Discrimination of maize crop with hybrid polarimetric RISAT1 data. **International Journal of Remote Sensing**, v. 37, n. 11, p. 2641-2652, 2016.
- VANEGAS, F.; BRATANOV, D.; POWELL, K.; WEISS, J.; GONZALES, F. A novel methodology for improving plant pest surveillance in vineyards and crops using UAV-based hyperspectral and spatial data. **Sensors**, Madison, v. 18, n. 1, p. 260, 2018. DOI. 10.3390/s18010260
- WALTER, J. D. C.; JAMES, E.; McDONALD, G.; KUCHEL, H. Estimating biomass and canopy height with LiDAR for field crop breeding. **Frontiers in Plant Sciences**, Lausanne, v. 10, p. 1145, 2019. DOI. 10.3389/fpls.2019.01145
- WHETTON, R. L.; HASSALL, K. L.; WAINE, T. W.; MOUAZEN, A. M. Hyperspectral measurements of

- yellow rust and fusarium head blight in cereal crops: Part 1: laboratory study. **Biosystems Engineering**, Amsterdam, v. 106, p. 101-115, 2018. DOI. 10.1016/j.biosystemseng.2017.11.008
- WHETTON, R. L.; WAINE, T. W.; MOUAZEN, A. M. Hyperspectral measurements of yellow rust and fusarium head blight in cereal crops: Part 2: on-line field measurement. **Biosystems Engineering**, Amsterdam, v. 167, p. 144-158, Mar. 2018. DOI. 10.1016/j.biosystemseng.2018.01.004
- WISEMAN, G.; McNAIRN, H.; MOMAYOUNI, S.; SHANG, J. RADARSAT-2 polarimetric SAR response to crop biomass for agricultural production monitoring. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Nova Iorque, v. 7, n. 11, p. 4461-4471, 2014. DOI. 10.1109/JSTARS.2014.2322311
- WU, W.; ZHANG, Z.; ZHENG, L.; HAN, C.; WANG, X.; XU, J.; WANG, X. Research Progress on the Early Monitoring of Pine Wilt Disease Using Hyperspectral Techniques. **Sensors**, Madison, v. 20, p. 3729, 2020. DOI. 10.3390/s20133729
- YANG, C.; EVERITT, J. H.; BRADFORD, J. M.; MURDEN, D. Comparison of Airborne Multispectral and Hyperspectral Imagery for Estimating Grain Sorghum Yield. **Transactions of the ASABE**, St. Joseph, v. 52, n. 2, p. 641-649, 2009. DOI. 10.13031/2013.26816
- YU, K.; ANDEREGG, J.; MIKABERIDZE, A.; KARISTO, P.; MASCHER, F.; McDONALD, B. A.; WALTER, A.; HUND, A. Hyperspectral canopy sensing of wheat *Septoria tritici* blotch disease. **Frontiers in plant science**, Lausanne, v. 9, p. 1195, 2018. DOI. 10.3389/fpls.2018.01195
- ZHANG, J.; HUANG, Y.; PU, R.; GONZALEZ-MORENO, P.; YUAN, L.; WU, K.; HUANG, W., 2019. Monitoring plant diseases and pests through remote sensing technology: A review. **Computers and Electronics in Agriculture**, Amsterdam, v. 165, p. 104943, 2019. DOI. 10.1016/j.compedu.2014.10.027
- ZHANG, J.; WANG, N.; YUAN, L.; CHEN, F.; WU, K. Discrimination of winter wheat disease and insect stresses using continuous wavelet features extracted from foliar spectral measurements. **Biosystems Engineering**, Amsterdam, v. 162, p. 20-29, 2017. DOI. 10.1016/j.biosystemseng.2017.07.003

Biografia do autor principal



Pedro Paulo da Silva Barros, natural de Brasília (1986). Recebeu o BSc em Eng. Agrônômica (2007) pela Faculdade da Terra de Brasília (FTB) e MBA em Agronegócio (2010), MSc em Irrigação & Drenagem (2012), PhD em Eng. de Sistemas Agrícolas (2016) e Pós-doutorado (2019) pela Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ/USP). Experiência profissional como docente na área de topografia e sensoriamento remoto desde 2015, atualmente como professor visitante na Universidade Federal de Uberlândia (UFU). Seu interesse de pesquisa é na área de monitoramento agrícola por meio de dados de sensoriamento remoto hiperespectral e sistema de informações geográficas.



Esta obra está licenciado com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.