


Estado da Arte da Classificação Automática de Áreas Agrícolas Usando Imagens de Sensoriamento Remoto



*Empresa Brasileira de Pesquisa Agropecuária
Embrapa Informática Agropecuária
Ministério da Agricultura, Pecuária e Abastecimento*

DOCUMENTOS 157

Estado da Arte da Classificação Automática de Áreas Agrícolas Usando Imagens de Sensoriamento Remoto

Jayme Garcia Arnal Barbedo

Exemplares desta publicação podem ser adquiridos na:

Embrapa Informática Agropecuária

Av. Dr. André Tosello, 209 - Cidade Universitária
Campinas, SP, Brasil
CEP. 13083-886
Fone: (19) 3211-5700
<https://www.embrapa.br/informatica-agropecuaria>

Comitê Local de Publicações da
Embrapa Informática Agropecuária

Presidente

Stanley R. de M. Oliveira

Secretária-Executiva

Carla Cristiane Osawa

Membros

*Adriana Farah Gonzalez, Carla Geovana do
Nascimento Macário, Flávia Bussaglia Fiorini, Jayme
Barbedo, Kleber X. Sampaio de Souza, Luiz Antonio
Falaguasta Barbosa, Maria Goretti G. Praxedes,
Paula Regina K. Falcão, Ricardo Augusto Dante,
Sônia Ternes*

Suplentes

Michel Yamagishi e Goran Nesic

Supervisão editorial

Kleber X. Sampaio de Souza

Revisão de texto

Adriana Farah Gonzalez

Normalização bibliográfica

Maria Goretti G. Praxedes

Projeto gráfico da coleção

Carlos Eduardo Felice Barbeiro

Editoração eletrônica

Flávia Bussaglia Fiorini

Foto da capa

Freepik

1ª edição

Versão digital (2018)

Todos os direitos reservados.

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

Dados Internacionais de Catalogação na Publicação (CIP).

Embrapa Informática Agropecuária

Barbedo, Jayme Garcia Arnal.

Estado da Arte da classificação automática de áreas agrícolas usando imagens de sensoriamento remoto / Jayme Garcia Arnal. - Campinas : Embrapa Informática Agropecuária, 2018.

40 p. -- (Documentos / Embrapa Informática, ISSN 1677-9274 ; 156).

1. Classificação de culturas. 2. Identificação de objetos. 3. Imagens de satélites. 4. Espectro visível.
5. processamento de imagens, 6. Aprendizagem de máquina. I. Título. II. Embrapa Informática Agropecuária.
IV. Série

CDD 006.6

Autor

Jayme Garcia Arnal Barbedo

Engenheiro eletricitista, doutor em Engenharia Elétrica, pesquisador da Embrapa Informática Agropecuária, Campinas, SP

Apresentação

A classificação de áreas agrícolas é muito importante para a previsão de safra, formulação de políticas públicas, gestão de recursos naturais, entre outros. A classificação manual dessas áreas é um processo trabalhoso, caro e sujeito a erros, tornando prioritária a busca por alternativas viáveis. À medida que mais imagens de satélite de alta qualidade se tornam disponíveis, a automação (pelo menos parcial) do processo de classificação usando processamento de imagens e aprendizado de máquina surge como uma opção viável. Porém, há muitos desafios que ainda precisam ser superados, os quais ainda impedem esse tipo de estratégia de ser utilizada na prática. Os objetivos deste documento são os seguintes: 1) identificar tais desafios e como eles foram tratados por diferentes autores ao longo das últimas décadas; e 2) servir como fonte de ideias para futuras pesquisas em segmentação automática e classificação de áreas agrícolas em imagens de sensoriamento remoto, com foco em dados de satélite compreendendo as bandas do infravermelho próximo e da luz visível.

Silvia Maria Fonseca Silveira Massruhá

Chefe-geral

Embrapa Informática Agropecuária

Sumário

Introdução	9
Métodos aplicados à classificação de culturas	10
Milho	10
Trigo	12
Arroz	13
Soja	15
Alfafa	17
Algodão	18
Discussão	18
Conclusões	24
Referências	24
Apêndice 1 - Siglas	34
Apêndice 2 - Lista de trabalhos citados.....	36

Introdução

Sensoriamento remoto pode contribuir significativamente por meio do fornecimento de uma visão rápida e acurada do setor agrícola, dada sua capacidade de coletar informações sobre vastas áreas com alta frequência de revisitas (Atzberger, 2013). A classificação de culturas é particularmente importante, uma vez que informações acuradas a respeito da localização das lavouras são essenciais para guiar políticas públicas e para estimar safras, o que em última análise afeta toda a cadeia de produção. Classificações relativamente acuradas de áreas agrícolas podem ser obtidas combinando dados de sensoriamento remoto com informações auxiliares tais como dados de solo, dados climáticos, bases de dados geográficos, entre outros. Essa é a abordagem adotada em muitos sistemas de larga escala (Baruth et al., 2008; Becker-Reshef et al., 2010; Wu et al., 2015; Estados Unidos, 2017; FAO, 2017; União Européia, 2017). Porém, informações auxiliares nem sempre são confiáveis (Bellón et al., 2017). Como resultado, alternativas podem ser necessárias para a obtenção de estimativas mais acuradas.

Devido à ausência de métodos automáticos capazes de atender às exigências associadas à maioria das situações, a classificação de áreas agrícolas é em grande parte uma tarefa manual, em um processo trabalhoso, caro e sujeito a erros relacionados à subjetividade envolvida nessa atividade. Por esse motivo, a busca por alternativas mais baratas e rápidas tem crescido continuamente ao longo das duas últimas décadas. Técnicas automáticas e semiautomáticas combinando processamento digital de imagens e aprendizado de máquina têm recebido atenção considerável, e avanços significativos têm sido alcançados. Porém, a complexidade das cenas capturadas nas imagens de satélite é tal que mesmo as tarefas de identificação mais simples podem ser desafiadoras (Lobo, 1997). Como resultado, a maior parte das soluções propostas até o momento, particularmente as totalmente automáticas, não possuem generalidade suficiente para serem usadas na prática. Nesse contexto, o principal objetivo deste trabalho foi identificar os principais gargalos que impedem métodos de classificação de culturas baseados em imagens de serem mais usados na prática, e propor algumas possíveis soluções. Foi dada ênfase às dificuldades técnicas e aos desafios que ainda precisam ser superados. Técnicas e abordagens usadas em cada trabalho citado são apenas brevemente mencionadas para contextualização. Essa decisão foi motivada pelo fato de quase todos os métodos propostos na literatura se basearem em técnicas clássicas de aprendizado de máquina tais como Support Vector Machine (SVM), “Random Forest” e Modelos Ocultos de Markov, os quais já foram exaustivamente explorados na literatura. Adicionalmente, técnicas mais recentes (particularmente aquelas baseadas em aprendizado profundo) são ainda muito incipientes no contexto da análise de imagens de satélite para merecerem uma discussão aprofundada.

Este texto foca em estudos usando imagens capturadas no espectro visível e no infravermelho próximo. Assim, estudos baseados em Radar de Abertura Sintética, da sigla em inglês Synthetic Aperture Radar (SAR) e Light Detection and Ranging (Lidar) não foram considerados, a menos que tenham também empregado imagens no espectro visível e infravermelho. Estudos explorando imagens hiperespectrais (Tarabalka et al., 2010; Nidamanuri; Zbell, 2011; Zhang et al., 2012), por outro lado, foram considerados quando os métodos propostos tinham potencial de serem estendidos a outros tipos de imagens. Todas as referências citadas neste artigo identificam ao menos um tipo específico de cultura – estudos lidando com o problema de classificação cultura/não-cultura não foram considerados, uma vez que este é um assunto com suas próprias características e objetivos.

Como este texto usa um grande número de abreviaturas e acrônimos, eles são definidos no Apêndice 1 ao final do artigo.

Métodos aplicados à classificação de culturas

Apesar de o número de artigos lidando com segmentação e classificação de culturas agrícolas ter aumentado ao longo do tempo, esse número é baixo em comparação com outras aplicações como a detecção de objetos em áreas urbanas e a classificação mais geral de uso e cobertura de terras. Isso provavelmente é devido aos muitos desafios envolvidos na tarefa, como detalhado nesta seção. Apesar de o problema estar longe de ser resolvido, progresso considerável já foi feito. Esta seção apresenta algumas das mais importantes contribuições à análise de áreas agrícolas usando imagens de sensoriamento remoto.

Esta seção é focada no detalhamento dos requisitos e desafios específicos a cada cultura. A variedade de culturas plantadas ao redor do mundo é extensa, de modo que não seria prático considerar todas. Por esse motivo, as culturas foram selecionadas de acordo com dois critérios principais: a área plantada no mundo deveria ser de ao menos 30 milhões de hectares e a literatura pesquisada deveria conter ao menos 20 artigos relacionados a essa cultura. Esses critérios, apesar de arbitrários, foram bem-sucedidos em selecionar as culturas mais relevantes: milho (180 M ha, 67 artigos), trigo (220 M ha, 51 artigos), arroz (163 M ha, 43 artigos), soja (120 M ha, 40 artigos), alfafa (30 M há, 27 artigos) e algodão (33 M ha, 20 artigos). Nenhuma outra cultura atendeu aos critérios estabelecidos. As culturas selecionadas representam mais de 50% da área agrícola mundial (Thenkabail et al., 2013).

Nesse ponto, é importante destacar que é muito difícil determinar quão gerais são os problemas e os desafios reportados pelos autores e reproduzidos ao longo desta seção. Como resultado, alguns dos problemas podem estar conectados às condições específicas encontradas nesses estudos. Apesar disso, é importante estar preparado para lidar com todos os tipos de problemas que podem ser encontrados na prática, uma vez que é difícil antecipar quais de fato terão um impacto. Ao final do texto, são também feitas algumas considerações a respeito das especificidades encontradas no Brasil e o que vem sendo feito para superar as dificuldades associadas.

O Apêndice 2 apresenta uma lista de todas as referências citadas nesta seção, contendo as seguintes informações: referências; sensores; classificadores usados nesses estudos; culturas consideradas em cada referência; e locais dos estudos.

Milho

O milho foi uma das primeiras culturas a serem consideradas para a identificação automática usando imagens de sensoriamento remoto (Ulaby et al., 1982). Nesse primeiro trabalho, publicado em 1982, imagens Landsat foram combinadas com dados de radar para diferenciar lavouras de milho de áreas contendo palha de trigo, pousio e pasto.

Em geral, milho pode ser separado de outras culturas explorando diferentes índices de vegetação (Peña-Barragán et al., 2011) e perfis temporais. Huang et al. (2014) enfatizaram a importância de explorar informação temporal, uma vez que o milho é plantado em rotação com trigo e, em alguns casos, com arroz. Hao et al. (2014) empregaram informação temporal para separar milho de algodão, explorando o fato de que na área estudada o milho entra mais cedo na fase de senescência. Por outro lado, Zhong et al. (2014) observaram que diferenças interanuais na qualidade da imagem e nos estágios de crescimento da cultura frequentemente levam a erros quando somente atributos espectrais são usados, destacando que as taxas de erro podem ser significativamente reduzidas pelo uso de parâmetros fenológicos, fato este também observado por Li et al. (2014). Informações

fenológicas foram exploradas por Waldhoff et al. (2017) para separar milho de outras culturas: dados do meio da primavera foram usados para separar milho de culturas de inverno, e dados do meio do verão e do início do outono foram combinados para separar milho de beterraba e batata.

Um problema que é comum à maioria das culturas, e particularmente proeminente no caso de milho, é o fato de ser improvável que modelos e métodos desenvolvidos para uma dada região funcionem para outras áreas. Isso foi exemplificado no estudo conduzido por Durgun et al. (2016), os quais compararam os perfis de Normalized Difference Vegetation Index (NDVI) obtidos para campos de milho localizados na Bélgica e no Brasil, mostrando que os períodos de plantio e colheita neste último são significativamente mais longos.

Outra dificuldade frequentemente associada com o mapeamento de lavouras de milho e sua similaridade com áreas de sorgo. Em regiões nas quais ambas as culturas são comuns, elas frequentemente são agrupadas na mesma categoria (Löw et al., 2013; Löw; Duveiller, 2014), do contrário, dados auxiliares precisam ser utilizados para resolver ambiguidades. Löw e Duveiller (2014) observaram que a classe milho/sorgo usualmente tem um maior grau de incerteza associado quando um classificador SVM é utilizado. Essa observação foi confirmada por Löw e Duveiller (2014), os quais observaram que independentemente do tamanho e pureza do pixel, não foi possível identificar lavouras de milho de maneira acurada, embora isso possa se dever ao fato de que tais lavouras ocupavam apenas pequenas áreas da região coberta pelo estudo. Em contraste, Hao et al. (2015) alcançaram um alto grau de separabilidade entre essas culturas explorando o fato de que milho é plantado mais cedo e emerge mais cedo que sorgo na área analisada. Diferenças temporais entre milho e sorgo foram também exploradas por Forkuor et al. (2014), os quais destacaram que nem todos os produtores seguem os calendários esperados, limitando a efetividade da estratégia.

Algumas culturas, além do sorgo, podem ser difíceis de diferenciar do milho. Foi observado um alto grau de confusão entre milho e soja devido a períodos de plantio, reprodução e colheita similares (Li et al., 2015; Hu et al., 2016; Navarro et al., 2016; Skakun et al., 2016; Zhang et al., 2016; Zhong et al., 2016). Pelas mesmas razões, erros de classificação entre milho e feijão são também comuns (Navarro et al., 2016). Adicionalmente, Massey et al. (2017) colocaram que milho e soja são difíceis de distinguir em imagens de baixa resolução, tais como Modis 250 m, o que levou os autores a combinarem essas culturas em uma única classe. Eles destacaram que pequenas diferenças fenológicas entre as culturas podem ser exploradas para separá-las, enfatizando que essa abordagem só funciona para um dado ano se o algoritmo é treinado usando referências de solo para aquele período, uma vez que diferentes anos podem ter condições meteorológicas muito diferentes. Em alguns casos, o objetivo do estudo foi identificar e quantificar campos de milho e soja agrupados, em cujo caso suas similaridades na verdade contribuíram para aumentar a acurácia Shao et al. (2016).

Um alto grau de similaridade entre milho e girassol pode levar também a altas taxas de erro (Waldner et al., 2015; Durgun et al., 2016), com essas classes às vezes sendo agrupadas para reduzir as taxas de erro (Roumenina et al., 2015). Ozdarici-Ok et al. (2015) observaram que, dependendo do sensor, campos de milho podem apresentar similaridades com culturas como pasto (sensor Ikonos), arroz e trigo (Komsat-2).

Outros fatores podem impactar a detecção de lavouras de milho. Haertel e Landgrebe (1999) e Roumenina et al. (2015) afirmaram que é difícil identificar culturas no início da temporada de crescimento, uma vez que a maior contribuição à resposta espectral vem do solo. Eles argumentaram que imagens hiperespectrais podem ser a melhor opção nesse contexto. Essa suposição foi testada

numa região contendo milho e soja, levando a bons resultados quando grandes aglomerados (clusters) foram considerados. Além disso, em áreas montanhosas, a vegetação natural pode ser tão densa que mesmo pequenas áreas podem alterar completamente os perfis temporais e espectrais das culturas. Alguns autores observaram que este tipo de problema é particularmente impactante em áreas produtoras de milho e soja na região sul do Brasil (Zhong et al., 2016). O alto grau de fragmentação de áreas plantadas em áreas tropicais chuvosas, em conjunto com a presença de vegetal natural, foi também identificado como uma importante fonte de erro (Lebourgeois et al., 2017).

O surgimento do conceito de aprendizado profundo tem causado um grande impacto na maneira como problemas de processamento de imagens são tratados. Esse conceito está agora começando a ser aplicado a problemas de sensoriamento remoto. Recentemente, avanços significativos na detecção de campos de trigo foram alcançados pela adoção de Redes Neurais Convolucionais, especialmente por meio da redução de falsos negativos (Kussul et al., 2017).

Trigo

Devido ao trigo ser cultivado durante as estações mais frias, não é viável detectar essa cultura usando imagens capturadas no fim da primavera ou no verão (Siachalou et al., 2015), uma vez que isso poderia causar confusão com outros tipos de cobertura de solo (Stavrakoudis et al., 2011). Outra consequência do fato de o trigo ser um cereal de inverno é que as mesmas áreas muitas vezes são usadas na produção de outras culturas, tais como arroz (Ulbaý et al., 1982), milho (Conrad et al., 2014) e soja (Wang et al., 2017). Este fato deve ser levado em consideração na análise temporal de qualquer área. Por outro lado, as peculiaridades de lavouras de trigo levam a uma baixa incerteza de classificação (Löw et al., 2013). Isto foi corroborado por Hao et al. (2014, 2015), os quais observaram que durante o início da temporada o trigo tinha uma fração de vegetação relativamente elevada, enquanto no verão o trigo já havia sido colhido e culturas de verão já estavam desenvolvendo. Esse pode também ser o motivo pelo qual trigo foi a única cultura que não se beneficiou do uso de um conjunto de classificadores no estudo conduzido por Löw et al. (2015), já que a maior parte da informação discriminativa entre esta e outras culturas tende a ser suficientemente distintiva para ser capturada por classificadores individuais.

Por outro lado, Peña-Barragán et al. (2011) observaram um alto grau de confusão entre trigo e outros cereais de inverno como aveia e centeio. Porém, eles destacaram que certos índices de vegetação poderiam ser usados para identificar a condição da lavoura após a colheita (quantidade de resíduos ou solo nu). A tendência do trigo de ter características similares a outros cereais de inverno foi também observada por Petitjean et al. (2012), cujo algoritmo de agrupamento (clustering) consistentemente agrupou trigo com cevada e canola; por Nidamanuri e Zebell (2011), os quais observaram um alto grau de similaridade entre as assinaturas espectrais do trigo, cevada e centeio (mas boa separabilidade entre canola e outros cereais de inverno); por Potgieter et al. (2013), os quais reportaram confusão entre trigo, cevada e grão-de-bico; por Waldhoff et al. (2017) (trigo e centeio); e por Zheng et al. (2015), Chellasamy et al. (2016) e Inglada et al. (2015) (trigo e cevada). Tal confusão levou alguns autores a agrupar trigo e cevada em uma única classe (Vaudour et al., 2015; Inglada et al., 2016; Massey et al., 2017). Como trigo e cevada compartilham diversas características, incluindo consumo de água e calendário, este agrupamento é razoável em muitas circunstâncias (Zheng et al., 2015).

Em certas situações, a discriminação entre trigo e cevada é importante, especialmente quando monitoramento detalhado de culturas é necessário. Por esse motivo, Gerstmann et al. (2016) focaram seu estudo na otimização de índices espectrais para separação de trigo e cevada. Os novos índices otimizados resultaram em menores taxas de erro. Os autores argumentaram que os atributos espectrais mais relevantes estavam localizados entre o vermelho e o infravermelho próximo, e o melhor período de discriminação na área estudada foi o começo do verão – alguns estudos apontaram que o final da primavera também é um bom momento para execução da tarefa (Waldhoff et al., 2017). Eles acrescentaram ainda que os testes foram realizados usando imagens contendo apenas duas classes de interesse, e que sob condições mais realistas a incerteza de classificação provavelmente aumentaria.

Apesar de a maioria dos erros encontrados para trigo se originarem de sua similaridade com outras culturas de inverno, níveis de confusão relativamente elevados foram também observados quando outros tipos de culturas foram considerados. Por exemplo, certa confusão entre trigo e tomate foi observada na China (Hao et al., 2014). Khan et al. (2016) reportaram níveis moderados de confusão entre trigo e trevo devido a respostas espectrais similares. Eles acrescentaram que, na região considerada em seu estudo, zonas com culturas misturadas (trigo + trevo, trigo + mostarda, trigo + árvores frutíferas) são comuns, tornando mais difícil detectar as assinaturas espectrais do trigo.

Como no caso da maioria das culturas, outra importante fonte de erro na detecção de campos de trigo é a presença de nuvens e respectivas sombras (Vaudour et al., 2015), o que pode causar problemas consideráveis se as imagens disponíveis não cobrem diferentes momentos e estações. Alternativamente, Skakun et al. (2016) mostraram que a substituição de imagens espectrais com imagens de SAR é uma opção viável no caso de haver presença de nuvens. Li et al. (2015) e Wang et al. (2017) observaram que, em muitas áreas, é prática comum plantar soja e trigo concomitantemente. Como consequência, eles consideraram o par soja-trigo como uma classe separada. O alto grau de confusão entre trigo e campos com duas culturas nas áreas estudadas foi em grande parte causada por dados de referência pouco confiáveis.

Löw e Duveiller (2014) obtiveram valores muito diferentes para o tamanho ótimo de pixel à medida que diferentes áreas foram consideradas. Apesar de na maioria dos casos uma ampla gama de tamanhos de pixel ser aceitável, sob certas condições, identificações acuradas somente são possíveis usando pixels pequenos (dezenas de metros).

Arroz

O arroz é frequentemente apontado como uma das culturas mais fáceis de serem detectadas em imagens de sensoriamento remoto. Isso pode ser explicado pelo fato desta cultura normalmente ser plantada em campos inundados, os quais apresentam características distintas devido ao efeito da água nas bandas do infravermelho próximo e do infravermelho de ondas curtas (Schmedtmann; Campagnolo; 2015). Isto não significa, porém, que não há dificuldades envolvidas na tarefa, especialmente considerando a heterogeneidade das áreas onde arroz é plantado. Muitos dos requisitos e desafios envolvidos no mapeamento de áreas de arroz foram abordados em revisões de literatura abrangentes (Kuenzer; Knauer, 2013; Dong; Xiao, 2016). Eles destacaram que o arroz possui quatro fases de crescimento, cada qual com suas características espectrais (Chang et al., 2005). Esse fato torna difícil discriminar áreas de arroz se informação temporal não é utilizada, uma vez que cada fase pode compartilhar similaridades espectrais com outras culturas e vegetações (Wang et al., 2012; Kim; Yeom, 2014). Em particular, arroz, trigo e milho têm assinaturas espectrais similares no pico da temporada de crescimento (Zhang et al., 2015). Por outro lado, Singha et al. (2016)

observaram que o uso de atributos fenológicos pode reduzir significativamente os erros devidos a similaridades espectrais.

Como arroz é frequentemente plantado em áreas alagadas, água tem importante papel na identificação dessa cultura. Uma consequência recorrente desse fato é que campos de arroz são frequentemente confundidos com corpos d'água (Löw et al., 2015; Wang et al., 2015). Esse problema pode ser mitigado dando ênfase a imagens capturadas quando o arroz está completamente desenvolvido (Su, 2017). Outra consequência é o fato de que campos de arroz são frequentemente confundidos com outras culturas irrigadas por superfície (Teluguntla et al., 2015). Em particular, alguns estudos detectaram confusão entre arroz e alfafa irrigada (Peña-Barragán et al., 2011). A tarefa de identificar áreas de arroz é ainda dificultada pela variação causada por diferentes condições de cultivo (Song et al., 2011). O clima predominante também influencia a identificação (Zhang et al., 2015), o que levou Dong et al. (2016) a focarem no problema menos explorado de identificação de campos de arroz em climas mais frios. Uma possível maneira de superar essas dificuldades é realizar uma análise temporal considerando a evolução das culturas ao longo de seu ciclo inteiro (Kontgis et al., 2015; Löw et al., 2015; Quin et al., 2015; Zhang et al., 2015); um estudo sobre o número de aquisições ótimo foi realizado por Conrad et al. (2014). É importante considerar, porém, que uma dada área pode ser usada no cultivo de mais de uma cultura. Por exemplo, arroz e trigo podem ser cultivados na mesma área nos períodos mais quentes e frios, respectivamente (Conrad et al., 2014).

Em muitas partes do mundo, campos de arroz tendem a ser pequenos (Kontgis et al., 2015) e frequentemente estão localizados em terreno acidentado (Shi; Huang, 2015; Clauss et al., 2016; Singha et al., 2016). Como resultado, atributos relacionados a tamanho podem ser úteis, especialmente se uma abordagem de classificação baseada em objetos é utilizada (Dong et al., 2016). Imagens de alta resolução podem ser necessárias a fim de capturar detalhes finos de áreas pequenas como essas (Clauss et al., 2016). Isso reduz a ocorrência de pixels misturados (Qin et al., 2015), o que pode causar problemas, especialmente ao longo das bordas dos campos (Wang et al., 2015). Porém, a relação entre tamanho do pixel, pureza do pixel e acuidade não é trivial (Löw; Duveiller, 2014). Esses autores observaram que o tamanho de pixel ótimo depende fortemente das características locais e, no caso específico do arroz, o tamanho ideal pode variar de alguns poucos metros a 1 quilômetro. Ainda mais contraintuitivo, eles observaram que a presença de mais pixels homogêneos não é sempre positiva para a identificação da cultura. Isso é particularmente verdadeiro para arroz, o qual, sob certas condições, pode ser mais bem identificado com níveis moderados a elevados de contaminação de sinal (Löw; Duveiller, 2014).

Outro problema que afeta severamente o mapeamento de áreas de arroz é o ruído relacionado à presença de nuvens (Kim; Yeom, 2014; Quin et al., 2015; Teluguntla et al., 2015; Zhou et al., 2016; Su, 2017). Apesar desse fato virtualmente afetar todos os mapeamentos baseados em imagens de satélite, ele é particularmente prejudicial no caso de arroz, dada a importância de se ter informação temporal consistente e o fato de que a maioria das regiões produtoras de arroz se localizarem em áreas altamente sujeitas à cobertura por nuvens (Motohka et al., 2009). Há alguns métodos para identificar e remover nuvens e respectivas sombras (Quin et al., 2015), mas mesmo quando esses são bem-sucedidos, a informação contida nessas regiões é perdida. Há ainda algumas técnicas para preenchimento de falhas, mas essas fornecem apenas uma estimativa grosseira (Zhang et al., 2015), e se muitos pontos de dados são afetados, informação será inevitavelmente perdida (Shi; Huang, 2015). Por outro lado, à medida que novas fontes de dados entram em operação, esse problema tende a diminuir (Dong et al., 2016), especialmente se as imagens de diferentes fontes são combinadas por alguma técnica de fusão de dados (Singha et al., 2016). Adicionalmente, Kontgis et al. (2015) colocaram que muitos dos problemas causados pela perda de dados relacionada à

cobertura de nuvens podem ser superados pelo uso de séries temporais longas cobrindo vários anos, enfatizando que áreas alagadas são particularmente importantes para a caracterização de campos de arroz. Alternativamente, SAR pode ser usado em combinação com imagens ópticas para reduzir o impacto da cobertura de nuvens (Gumma et al., 2015).

Em algumas regiões do mundo, o arroz é cultivado concomitantemente com outras culturas. Por essa razão, Forkuor et al. (2014) observaram um alto grau de confusão entre arroz e batata doce, já que produtores na África Ocidental frequentemente plantam essas duas culturas em conjunto, a fim de maximizar a utilização da terra. Eles destacaram, contudo, que o uso de imagens de radar diminuiu a confusão.

O mapeamento de arroz em grandes áreas com características distintas pode ser complicado, o que levou Manjunath et al. (2015) a integrar imagens de sensoriamento remoto com dados auxiliares (mapas de elevação, irrigação, alagamentos e chuva) para mapear campos de arroz em uma região englobando 13 países asiáticos. Além de delimitar os campos de arroz, os autores classificaram essas áreas de acordo com padrões de plantio e tipos culturais.

Zhang et al. (2017) mostraram que é possível coletar dados de uma região e aplica-los a áreas próximas de difícil acesso. Nesse estudo, campos de arroz foram distinguidos de milho e soja usando imagens do sensor Modis 250 m.

Soja

Os campos de soja, como em outras culturas, podem apresentar considerável heterogeneidade relacionada ao clima, à variedade, ao calendário e ao manejo (Zhong et al., 2014). Esse problema foi investigado por Durgun et al. (2016), os quais observaram diferenças significativas nas lavouras de áreas geográficas muito próximas, como o Sul da Rússia e Ucrânia. Como consequência, classificadores treinados em áreas limitadas podem não ser suficientemente genéricos para funcionarem corretamente em outras regiões e em diferentes anos (Villa et al., 2015). Porém, essas diferenças entre lavouras podem ser exploradas para resolver algumas das ambiguidades que ocorrem na discriminação entre soja e outras culturas, como discutido abaixo.

Farag et al. (2005) reportaram taxas significativas de erros entre campos de soja e solo exposto, e os experimentos realizados por Wang et al. (2017) revelaram que muitos campos de soja tendem a ser classificados como capim. Foi também observada confusão elevada entre milho e soja devido a calendários e ciclos de desenvolvimento similares (Hao et al., 2015; Navarro et al., 2016; Skakun et al., 2016; Song et al., 2017; Wang et al., 2017), e em alguns estudos ambas as culturas foram agrupadas em uma única classe (Massey et al., 2017). Por outro lado, há estudos mostrando que a banda do infravermelho de ondas curtas, da sigla em inglês, Short-Wave Infrared (SWIR) separa bem soja de milho em certos períodos devido a diferenças na estrutura do dossel (Li et al., 2015) e King et al. (2017) indicaram que uma possível solução para reduzir a confusão entre soja e milho seria usar atributos de textura. Adicionalmente, Haertel e Landgrebe (1999) argumentaram que é difícil identificar a cultura quando a maior contribuição à resposta espectral vem do fundo (solo), o que é normalmente o caso no início da temporada. Em resposta, eles usaram imagens hiperespectrais para diferenciar soja de milho. Liu et al. (2014) observaram altas taxas de confusão entre soja e algodão, também devido a perfis espectrais similares na área estudada. Soja e feijão, além de todas as similaridades mencionadas para outras culturas, têm estruturas de dossel similares, tornando difícil sua separação (Navarro et al., 2016; Zhong et al., 2016). Áreas de soja também compartilham perfis espectrais similares com algumas culturas tropicais. Schultz et al. (2015) observaram que

campos de mandioca e amendoim têm comportamento espectral similar à soja, especialmente no meio da estação. De qualquer forma, é importante notar que muitos erros de classificação em áreas de soja são devidos aos pixels localizados nas bordas dessas áreas, os quais frequentemente contêm informação misturada (Souza et al., 2015; Song et al., 2017).

O problema da separação entre soja e milho foi estudada com maior profundidade por Zhong et al. (2016). Eles colocaram que “a diferença de fenologia entre soja e milho às vezes tem uma magnitude menor que a variabilidade interanual ou regional”. Como resultado, regras rigorosas aplicadas às variáveis fenológicas só seriam confiáveis para o período de tempo para o qual elas foram derivadas. Eles concluíram afirmando que um classificador automático dependeria do desenvolvimento de regras universais independentes do tempo, o que é significativamente mais difícil que gerar classificadores treinados usando dados compreendendo um curto período. Uma alternativa explorada pelos autores foi o uso de propriedades espectrais em certos estágios fenológicos para reduzir a sensibilidade à dinâmica de crescimento da cultura, obtendo relativo sucesso. Outra observação interessante feita pelos autores foi que devido à área de soja estudada ser altamente mecanizada, áreas não plantadas nas bordas tendem a ser classificadas como soja. Eles acrescentaram que muitas áreas pequenas de soja não foram identificadas devido à presença de pixels misturados, problema este recorrente para pequenas propriedades, especialmente se estas estão espalhadas entre outros tipos de culturas (Hu et al., 2016). Pixels misturados são também importantes na presença de pequenas áreas (menores que um pixel) de vegetação natural, o que pode prejudicar a separação de soja e milho. É importante notar, contudo, que dependendo da situação, é desejável agrupar milho e soja (Shao et al., 2016).

A fim de reduzir o erro causado por classificações erradas de pixels, Song et al. (2017) realizaram uma amostragem estratificada em dois estágios para coletar dados no campo, os quais, por sua vez, foram usados para calibrar um mapa nacional de cultivo de soja obtido a partir de imagens Landsat. Os autores afirmaram que o método era particularmente útil para uso em países em desenvolvimento, onde sistemas avançados de mapeamento e levantamento podem não existir, fornecendo assim mapas relativamente acurados e de baixo custo (acurácia entre 84 e 86%). Por outro lado, eles observaram que o desafio de obter estimativas acuradas pode ser consideravelmente mais elevado em regiões tropicais, as quais possuem maior diversidade de culturas, ciclos e calendários, bem como uma variedade de técnicas de manejo. Eles sugeriram que uma possível solução para lidar com tal complexidade seria estratificar a área de estudo, a fim de considerar as condições específicas de cada área.

Em um dos poucos estudos no qual campos de soja eram claramente dissimilares a outras culturas, Hao et al. (2015) observaram um alto grau de separabilidade entre soja e sorgo devido às diferentes taxas de emergência e senescência.

O cultivo duplo de produção durante o ano-safra, no qual duas culturas diferentes são plantadas na mesma área em períodos diferentes, vem se tornando cada vez mais comum em diversos lugares, e em especial no Brasil. Adicionalmente, duas safras de soja vêm também sendo adotadas em algumas áreas (Kastens et al., 2017). Essa complexidade no uso da terra faz com que certas áreas demandem uma análise temporal cuidadosa para uma caracterização confiável. Por sua vez, esta análise temporal traz consigo a necessidade de criar novas classes para levar em conta os diferentes usos de certas áreas ao longo do tempo. Isso levou Picoli et al. (2018) a adotar, além das categorias individuais, novas classes combinando soja com milho, algodão, girassol e milheto. Além dessas classes combinadas, Brown et al. (2013) criaram também as classes soja-sorgo e

soja-feijão. Portanto, com a intensificação da agricultura, o uso de informação temporal vem se tornando uma necessidade.

Recentemente, a exemplo do que ocorreu para o milho, a introdução de redes neurais convolucionais, da sigla em inglês Convolutional Neural Networks (CNN) para lidar com a detecção de campos de soja resultou em um aumento dos índices de acerto (Kussul et al., 2017).

Alfafa

A identificação de áreas de alfafa pode se beneficiar consideravelmente de informação temporal ao longo de uma temporada inteira, uma vez que essa cultura pode ser colhida até 10 vezes por ano (Peña-Barragán et al., 2011, 2014). Esse fato levou Siachalou et al. (2015) a comentar que, quando Modelos Ocultos de Markov (HMM) são usados, o número necessário de capturas de imagens para detectar corretamente campos de alfafa deve ser ao menos igual ao número de colheitas no ano. Em outras palavras, como campos de alfafa são normalmente colhidos em diferentes momentos, as imagens usadas para calibrar os algoritmos devem conter uma grande variedade de momentos de corte para diminuir erros de classificação (Zheng et al., 2015).

De acordo com Li et al. (2014), uma maneira efetiva de capturar variações na fenologia esperada para alfafa seria usar atributos relacionados ao perfil NDVI integrados com atributos relacionados ao perfil de crescimento da cultura. A grande variabilidade espectral de campos de alfafa também explica a fraca relação entre os espectros de reflectância do campo de alfafa com as respectivas imagens hiperespectrais (Nidamanuri; Zbell, 2011).

A idade dos campos de alfafa pode ter uma influência significativa nas suas características. No primeiro ano, esses campos ainda contêm grandes quantidades de plantas silvestres. Após diversas colheitas, as ervas tendem a desaparecer, alterando as assinaturas temporais e espectrais desses campos (Löw et al., 2013). Esses mesmos autores observaram que alfafa, com frequência, não pode ser apropriadamente discriminada de terras não cultivadas, algo que foi corroborado por Johnson (2008). Isto foi também observado por Löw e Duveiller (2014), os quais acrescentaram que a alfafa requer que os pixels tenham tamanhos mais grosseiros e maior pureza que outras culturas para serem corretamente identificados. Sob certas condições, observou-se também confusão entre alfafa e culturas lenhosas (Peña-Barragán et al., 2011; Peña et al., 2014), e alfafa e várzea (Stavrakoudis et al., 2011). Isto ocorre porque essas culturas retêm a coloração verde durante o verão (Zheng et al., 2015), diminuindo assim as diferenças espectrais e, como resultado, sua separabilidade (Peña et al., 2014). Adicionalmente, Zhu et al. (2017) observaram que discriminar alfafa de pastagem é difícil, já que ambos têm ciclos de crescimento e corte similares.

Erros de classificação elevados foram também observados por Farag et al. (2005), mas nesse caso esses erros foram mais relacionados ao fato de que a classe “alfafa” não estava suficientemente representada no conjunto de dados, gerando uma probabilidade a priori baixo para a classe. Uma observação similar foi feita por Tarabalka et al. (2010) usando um classificador SVM.

Em contraste, em alguns casos observou-se que alfafa possui poucas similaridades com culturas, tais como milho, sorgo e soja, durante a maior parte da temporada, exceto durante o verão, quando as outras culturas já se desenvolveram (Hao et al., 2015). A exceção foi quando os campos de alfafa e soja eram pequenos, cujo grau de confusão foi significativamente maior.

Algodão

O algodão é uma das culturas para as quais a identificação usando imagens de sensoriamento remoto é mais bem-sucedida. Isso provavelmente se deve a particularidades espectrais e fenológicas que podem ser extraídas das imagens capturadas. Por exemplo, You et al. (2014) não observaram confusão entre campos de algodão e arroz. Além disso, no estudo conduzido por Hartfield et al. (2013), algodão foi consistentemente a cultura com taxas de acerto mais elevadas. Esses autores afirmaram que na região considerada no seu estudo, campos de algodão são irrigados, tornando sua fenologia consistente de ano para ano. Como resultado, é possível usar o treinamento realizado em dado ano para produzir mapas acurados para outro ano.

Apesar do relativo sucesso alcançado na identificação de algodão, ainda há desafios a serem vencidos. Conrad et al. (2014) observaram que perfis de NDVI do algodão são similares àqueles do milho e sorgo, apesar destes possuírem estruturas de dossel completamente diferentes. Os autores apontaram que uma possível solução para este problema seria explorar outras bandas espectrais como infravermelho. Diferenças temporais entre as fenologias dessas culturas foram exploradas por Hao et al. (2014) e Zheng et al. (2015) para melhorar sua separabilidade. Similarmente, Liu et al. (2014) combinaram a alta resolução espacial das imagens Landsat com a baixa resolução espacial das imagens o Moderate-Resolution Imaging Spectroradiometer (Modis), estas últimas possuindo uma resolução temporal muito mais elevada, para diminuir significativamente a confusão entre algodão e milho. Informação temporal foi também utilizada para separar áreas exclusivas de algodão de áreas contendo soja e de áreas em que dois ciclos de produção (algodão e soja) foram adotados no ano-safra (Kastens et al., 2017). Os autores tiveram dificuldades em separar áreas de algodão daquelas, adotando dois ciclos de produção.

Siachalou et al. (2015) também experimentaram um alto grau de confusão entre algodão e outras culturas de verão, destacando que isso foi devido à alta variabilidade espectral interna resultante de diferentes práticas de manejo. Löw et al. (2015), por sua vez, detectaram um alto grau de confusão entre algodão e áreas não agrícolas. Este problema foi minimizado usando múltiplos classificadores e uma técnica de fusão de decisões. Mathur e Foody (2008) observaram um aumento na confusão entre algodão e arroz em áreas alagadas.

Em relação ao tamanho e à pureza dos pixels, Löw e Duveiller (2014) observaram um comportamento similar ao arroz, isto é, os valores ótimos dependem das características do local analisado. Porém, algodão foi mais bem identificado com pixels menores. Além disso, campos de algodão foram identificados com mais facilidade no final da temporada – esse fenômeno é observado para a maioria das culturas, porém mais intensamente para algodão. Adicionalmente, Löw et al. (2015) chegaram à conclusão que bons resultados para algodão não dependiam do uso de múltiplas imagens ao longo do tempo.

Discussão

Apesar dos esforços colocados no desenvolvimento de novas estratégias para segmentação automática e classificação de imagens de sensoriamento remoto, os métodos propostos até o momento não são suficientemente acurados para a maioria das aplicações. Isso levou alguns autores a argumentar que métodos totalmente automáticos não são viáveis e que a assistência de pessoas com conhecimento no domínio da aplicação continuará sendo essencial (Udupa et al., 2006). A explicação para isso vai além dos desafios técnicos discutidos na seção anterior. Os autores argumentaram

que há um significativo descasamento na maneira como humanos e computadores realizam a tarefa de segmentação: enquanto humanos se baseiam no processo de alto nível de reconhecimento (determinação rudimentar da localização dos objetos), computadores usam o processo de baixo nível de delineamento (determinação precisa da extensão espacial e composição ponto-a-ponto). Em outras palavras, humanos são majoritariamente qualitativos, enquanto algoritmos computacionais são mais quantitativos.

Uma solução que tem sido adotada em vários sistemas é a combinação de dados de sensoriamento remoto com dados auxiliares, tais como calendários de plantio, informação de solo, dados climáticos, bases de dados geográficas (Esch, 2014; Manjunath et al., 2014; Mukashema et al., 2014), entre outros. Esse tipo de sistema baseado em conhecimento integra toda essa informação em uma interpretação para as cenas, normalmente fornecendo também um nível de confiança associado, a qual pode ser usada para orientar o envolvimento humano complementar (Janssen; Middelkoop; 1992; Cohen; Shoshany, 2005). Essa tem sido a abordagem adotada na maioria dos sistemas regionais e globais de monitoramento agrícola (Atzberger, 2013), tais como o Projeto de Monitoramento Agrícola Global, da sigla em inglês Global Agricultural Monitoring (Glam) (Becker-Reshef et al., 2010), o sistema de alerta precoce de fome, da sigla em inglês Famine Early Warning System Network (FEWS-NET) (Estados Unidos, 2017), o Sistema Global de Informação e Alerta Precoce, da sigla em inglês Global Information and Early Warning System (GIEWS) (FAO, 2018), o Sistema de Monitoramento de Recursos Agrícolas, da sigla em inglês Monitoring Agricultural ResourceS (MARS) (Baruth et al., 2008), o Programa de Monitoramento Global de Segurança Alimentar, da sigla em inglês, Global Monitoring for Food Security (GMFS) (União Européia, 2017), e o Programa de Monitoramento de Culturas (Wu et al., 2015). Apesar de todos esses sistemas proverem informações úteis, eles às vezes são prejudicados por informações auxiliares incompletas e/ou de baixa qualidade (Bellón et al., 2017), levando a resultados pouco confiáveis. Além disso, sua resolução especial é relativamente baixa. Alguns estudos em como explorar os dados gerados pelos novos satélites de alta resolução como o Sentinel-2 vêm sendo conduzidos (Inglada et al., 2015), o que deve melhorar a resolução espacial desses sistemas no futuro. De qualquer modo, há muitas aplicações que requerem resultados mais refinados e um grau de automação mais elevado, um fato que vem motivando um crescente número de estudos sobre o assunto. Nesse contexto, técnicas de aprendizado profundo vêm ganhando momento, já que esses são particularmente efetivos na extração de informação contida em imagens digitais (Goodfellow et al., 2016).

Técnicas de aprendizado profundo tentam modelar abstrações de alto nível presentes nos dados extraindo padrões a partir de dados não rotulados. No caso específico de dados de sensoriamento remoto, esse tipo de técnica tem o potencial de gerar bons resultados sem levar explicitamente em conta os muitos fatores que influenciam a classificação, tais como heterogeneidade e diversidade da cultura, ruído, incerteza de segmentação, etc. Em outras palavras, se imagens suficientes são usadas para treinamento, técnicas de aprendizado profundo podem ser capazes de extrair informação suficiente para substituir ao menos alguns dos passos que fazem parte dos sistemas baseados em conhecimento discutidos no parágrafo anterior. Até recentemente, não era viável aplicar aprendizado profundo à análise de imagens de sensoriamento remoto devido à falta de bases de dados rotuladas suficientemente grandes para treinamento apropriado dos algoritmos (Cheng; Han, 2016). É esse o motivo de haver tão poucas tentativas de aplicar essa técnica à classificação de culturas (Ma et al., 2016; Zhao; Du, 2016; Kussul et al., 2017). Porém, à medida que mais imagens e poder computacional ficam disponíveis, esse tipo de técnica tende a ser utilizada com mais frequência.

Independentemente das abordagens adotadas para enfrentar o problema, há vários desafios específicos que sempre afetam seus resultados. Culturas que compartilham arquiteturas de dossel simi-

lares, tais como milho e cana de açúcar, são difíceis de discriminar usando imagens de satélite, dado que produzem texturas similares, mesmo quando diferentes bandas espectrais são consideradas. Ainda mais complicado, as texturas geradas por uma cultura podem variar consideravelmente (Vieira et al., 2012). Em casos como esse, os problemas de classificação não podem ser resolvidos usando imagens incluindo um único momento ou curtos períodos, porque normalmente as diferenças entre culturas somente se manifestam consistentemente quando seu comportamento ao longo do tempo é considerado (Kim; Yeom, 2014). Assim, com exceção de alguns poucos casos (Mukashema et al., 2014; Noonii et al., 2014; Ozdarici-Ok et al., 2015), séries temporais extraídas de imagens de satélite são parte essencial da maioria dos métodos de classificação de culturas. Para serem efetivas, as séries temporais devem incluir a temporada de crescimento (Aguilar et al., 2015), que é quando comportamentos distintos podem ser observados e regras efetivas podem ser derivadas. A temporada de crescimento varia de região para região, e pode variar significativamente na mesma região, dependendo do ano considerado (Dong; Xiao, 2016). Por esse motivo, é aconselhável que dados espectrais e fenológicos sejam usados para classificação apenas no ano em que estes foram coletados. Porém, quando os dados para um dado ano estão ausentes, é possível obter classificações relativamente acuradas a partir de dados de outros anos (Hartfield et al., 2013). Massey et al. (2017) sugeriram que uma maneira de aplicar dados de um ano para outros seria separar os anos cuja precipitação foi abaixo da média, na média e acima da média para treinamento, ajustando assim os dados de acordo com as diferentes condições climáticas. Alguns autores acrescentaram que cada problema de classificação tem um número ideal de momentos no tempo que deveriam ser considerados, acima do qual o ganho em acurácia se torna desprezível (Conrad et al., 2014). Em geral, problemas de classificação que envolvem variabilidade intraclasse e similaridade interclasse substanciais requerem resolução temporal mais elevada (Hu et al., 2016). Além disso, considerar períodos ótimos pode ser uma melhor opção, ao invés de considerar a temporada inteira (Hao et al., 2015).

É também importante considerar que a efetividade de séries temporais derivadas de imagens de satélite pode ser seriamente comprometida por cobertura de nuvens e respectivas sombras (Dong et al., 2016). A literatura sugere algumas maneiras de enfrentar esse problema. Em áreas onde cobertura de nuvens é comum, é usual combinar imagens multiespectrais com dados fornecidos por sensores SAR (Esch et al., 2014; Karila et al., 2014; Gumma et al., 2015; Whitcraft et al., 2015; Cheng et al., 2016; Kussul et al., 2016). Sensores SAR são muito menos afetados por fenômenos meteorológicos (Inglada et al., 2016) e são sensíveis a características da superfície do terreno, estrutura das folhas e arquitetura do dossel, o que pode ajudar a identificar culturas (Forkuor et al., 2014). Como alternativa, há alguns algoritmos que podem remover, ou ao menos corrigir parcialmente, áreas afetadas pelas nuvens (Bontemps et al., 2015; Dong et al., 2016), com alguma perda de informação. Uma desvantagem dessa abordagem é que erros no procedimento de triagem por nuvens pode ter grande impacto na acurácia da classificação se estes coincidem com os dados de referência utilizados no treinamento do algoritmo (Ingada et al., 2016). Uma alternativa viável, a qual depende de disponibilidade de dados, é o uso de dados hipertemporais e/ou vários anos de dados para aumentar a probabilidade de que todas as áreas serão representadas por ao menos algumas imagens livres de nuvens (Dong; Xiao, 2016). Kontgis et al. (2015) enfatizaram que mesmo quando uma grande porção da imagem está coberta por nuvens, as regiões que não são afetadas podem conter informação útil, de modo que a imagem deve ser processada de maneira apropriada ao invés de ser completamente descartada.

A inclusão de informação temporal não garante a separabilidade de diferentes classes de culturas. Primeiro, a mesma cultura pode ser semeada e colhida em diferentes datas (Forkuor et al., 2014;

Aguilar et al., 2015; Grzegozewski et al., 2016; Kawakubo; Machado, 2016), alterando as assinaturas espectrais (Hu et al., 2016) e as fenologias (Peña; Benning, 2015) e, como consequência, tornando difícil encontrar padrões. As assinaturas espectrais e fenológicas podem também variar consideravelmente dependendo da quantidade de precipitação durante a temporada (Massey et al., 2017), especialmente em áreas não irrigadas. Adicionalmente, perfis espectrais similares são comuns entre certas culturas, e.g. trigo e cevada (Gerstmann et al., 2016), tornando-as difíceis de discriminar. Esse fato explica a maior parte dos erros de classificação reportados na literatura (Akar; Güngör, 2015). A classificação de culturas é também altamente suscetível à heterogeneidade espacial, o que pode ser causado por impureza amostral (e.g. culturas misturadas) (Fan et al., 2015) e heterogeneidade de paisagem (riqueza e uniformidade dos tipos de cobertura de solo, complexidade da estrutura espacial dos tipos de cobertura de solo) (Löw; Duveiller, 2014; Chein et al., 2016). Heterogeneidade espacial é particularmente prevalente em regiões com paisagens altamente fragmentadas (Forkuor et al., 2014), tornando difícil encontrar áreas homogêneas para extração apropriada dos atributos que caracterizam cada cultura. Porém, há algumas alternativas que podem ser exploradas para superar algumas dessas dificuldades, desde que os dados necessários estejam disponíveis. As alternativas de maior interesse são o uso de dados auxiliares, como comentado anteriormente, e o uso de técnicas para fusão de dados (imagens), como discutido a seguir.

A estratégia de fundir informações advindas de diferentes fontes vem sendo usada por algum tempo. A ideia é que a fusão de imagens pode integrar diferentes dados a fim de obter mais informação do que seria derivado a partir de imagens isoladas (Pohl; Genderen, 1998). À medida que novos satélites são lançados e mais dados se tornam disponíveis, essa opção se torna mais atraente. De acordo com Simone et al. (2002), há cinco diferentes tipos de fusão de imagens: 1) dados obtidos por diferentes sensores (fusão de imagens multissensor) (Liu et al., 2014; Zhu et al., 2017); 2) dados obtidos pelo mesmo sensor varrendo a mesma cena em diferentes datas (fusão de imagens multitemporais); 3) dados obtidos pelo mesmo sensor operando em diferentes bandas espectrais (fusão de imagens multifrequência) (Castillejo-González et al., 2009); 4) dados obtidos pelo mesmo sensor em diferentes polarizações (fusão de imagens multipolarização); 5) dados obtidos pelo mesmo sensor localizado em diferentes plataformas aéreas localizadas em diferentes altitudes (fusão de imagens multirresolução). Um sexto tipo de fusão de imagens, no qual técnicas de “pansharpening” são aplicadas ao mesmo material e as imagens resultantes são fundidas, foi proposto por Johnson et al. (2014). A literatura mostra que a fusão de imagens funciona bem em muitas situações, mas tem também algumas desvantagens: a aquisição de imagens adicionais pode ser cara; imagens de diferentes fontes normalmente têm diferentes resoluções, de modo que algum processamento deve ser cuidadosamente aplicado a fim de tornar as imagens compatíveis sem introduzir artefatos danosos; um registro cuidadoso das imagens deve ser realizado para cada imagem de modo que estas se alinhem perfeitamente durante a fusão; a qualidade da fusão das imagens pode ser severamente afetada se essas imagens são capturadas em diferentes momentos do dia ou do ano (Pohl; Genderen, 1998). Em última análise, a decisão de aplicar ou não fusão de dados dependerá da importância de obter máxima acurácia e a relação custo/benefício que pode ser tolerada (Castillejo-González et al., 2009). Mais informações sobre todos os aspectos envolvidos na fusão de imagens podem ser encontradas em Pohl e Genderen (1998) e Simone et al., (2002).

Métodos baseados em pixels têm dominado a análise de imagens de sensoriamento remoto desde seu início. Porém, dado que as regiões em uma imagem fornecem mais informação do que pixels individuais, a análise de imagens baseada em objetos começou a receber atenção (Benz et al., 2004; Kim; Yeom, 2014). Esse deslocamento na direção de abordagens orientadas a objetos tem continuamente ganhado momento, especialmente à medida de imagens de satélite de alta resolução se

tornam mais acessíveis (Blaschke et al., 2008). Um estudo a respeito da relação entre resolução espacial e classificação mostrou que sensores como Modis (250 m) podem ser apropriados para identificar grandes classes de culturas usando uma abordagem baseada em pixels, enquanto sensores como o Landsat (30 m) podem ser considerados para classificação baseada em objetos (Löw; Duveiller, 2014). Abordagens baseadas em objetos tendem a ser vantajosas, combinadas com sensores de alta resolução, porque estes aumentam significativamente a variabilidade espectral intra-classe e, como resultado, diminuem a separabilidade estatística entre as classes quando abordagens baseadas em pixels são utilizadas (Blaschke et al., 2014). Consequentemente, a acurácia da classificação é reduzida, e os resultados usualmente apresentam um efeito sal-e-pimenta (Yu et al., 2006). Isso é particularmente verdadeiro quando um alto grau de heterogeneidade espectral está presente, uma vez que técnicas de classificação por pixel não conseguem lidar apropriadamente com esse tipo de situação tendo como base apenas o conteúdo espectral das imagens. Técnicas orientadas a objetos, por outro lado, reconhecem que muitos elementos importantes não estão representados em pixels individuais, mas em objetos e suas relações mútuas (Mathieu et al., 2007), os quais podem transmitir informações semânticas relevantes para a interpretação da imagem (Durand et al., 2007; Gamanya et al., 2007; Li et al., 2015). Laliberte et al. (2004) acrescentaram que muita informação está contida na relação entre pixels adjacentes, incluindo informação de textura e forma, o que permite a identificação de objetos individuais ao invés de pixels, aproximando-se da maneira como humanos interpretam informações. Abordagens baseadas em objetos também possibilitam classificação adequada de áreas faltando pixels, desde que haja informação suficiente nas partes não afetadas para classificar o objeto (Long et al., 2013). Apesar de métodos baseados em objetos não operarem de maneira apropriada com dados de baixa resolução, técnicas de “pansharpening” podem entregar resolução suficiente para obtenção de resultados aceitáveis (Karakizi et al., 2016).

Um importante fator a ser considerado em métodos baseados em objetos é a escala para ser usada como referência para o tamanho dos objetos (Li et al., 2015). Uma escala grosseira demais pode levar a objetos excessivamente heterogêneos, enquanto uma escala fina demais pode gerar objetos muito pequenos a partir dos quais não é possível extrair atributos úteis. Uma variação da abordagem baseada em objetos, chamada classificação baseada em talhões, lida com o problema de escala adotando um critério fixo para a segmentação (Kussul et al., 2016). As características de ambas as abordagens são quase as mesmas. A única exceção é que os talhões podem conter múltiplos tipos de culturas dentro de seus limites, um fato que deve ser considerado para evitar erros de classificação.

Apesar de todas as vantagens dos métodos baseados em objetos, abordagens baseadas em pixels ainda são vantajosas sob certas circunstâncias. Imagens com baixa resolução espacial ainda têm um papel importante na comunidade de sensoriamento remoto, especialmente considerando que elas normalmente têm alta resolução temporal e/ou espectral (Atzberger, 2013; Löw; Duveiller, 2014) e que possuem longas séries históricas (Chen et al., 2016). Além disso, a aquisição da maioria das imagens de satélite de alta resolução é cara (Gallego et al., 2014), embora imagens com resolução relativamente elevada estejam sendo disponibilizadas gratuitamente por novas iniciativas como o Sentinel (Inglada et al., 2015). Como imagens de baixa resolução não entregam detalhes suficientes para a correta delimitação dos objetos, especialmente no caso de talhões e propriedades pequenas (Durgun et al., 2016), considerar cada pixel de forma individual provavelmente levará a melhores resultados. Adicionalmente, métodos baseados em objetos incluem, implícita ou explicitamente, algum tipo de segmentação, a qual é outra potencial fonte de erros além da própria classificação (Blaschke, 2010). Outro fator que favorece abordagens baseadas em pixels é o fato que estas são, em geral, mais fáceis de projetar, implementar, testar e validar (Castillejo-González et al., 2009).

Finalmente, é importante destacar que se detalhes subpixel devem ser identificados, o que é particularmente importante em situações com pixels contendo alto grau de impureza (Löw; Duveiller, 2014), soluções híbridas combinando ambos os tipos de classificação (pixel e objeto) pode ser a melhor opção (Shackelford; Davis, 2003; Bhaskaran et al., 2010).

Todas as imagens têm algum nível de ruído, o que pode afetar adversamente a classificação, especialmente no caso de abordagens baseadas em pixels (Elia et al., 2003), uma vez que abordagens baseadas em objetos podem reduzir significativamente os efeitos do ruído (Li et al., 2015). Ruídos podem causar sobressegmentação, reduzir a acurácia do delineamento de bordas (Ali; Clausi, 2001), reduzir a efetividade da recuperação de informações (Atzberger et al., 2014), entre outros efeitos deletérios. Um estudo abrangente dos efeitos de diferentes tipos de ruído sobre imagens de satélite foi apresentado por Ben Salah et al. (2011), e um estudo sobre o ruído causado pela compressão de imagens foi conduzido por Zabala e Pons (2013). A maneira mais óbvia de lidar com ruído é a aplicação de um filtro passa-baixas, mas essa estratégia pode também remover informação útil. Uma abordagem alternativa foi idealizada por Inglada et al. (2007), os quais observaram que a aplicação de interpolação e reamostragem à imagem com a origem deslocada produziu um efeito de suavização que reduziu o ruído sem perda significativa de informação. Chen et al. (2012), por outro lado, empregaram Campos Aleatórios de Markov para produzir resultados mais agregados, reduzindo os erros causados por ruído do tipo sal-e-pimenta. Uma revisão sobre técnicas de remoção de ruído foi apresentada por Atzberger (2013).

Muitos estudos na literatura visam detectar uma única cultura, resultando numa classificação binária, na qual a distribuição de classes é inerentemente desbalanceada devido ao tamanho e à diversidade da classe “outros” (Clauss et al., 2016). Classificação binária é particularmente comum para arroz, dada sua importância e predominância em partes do sul e sudeste asiático. Como resultado desse desbalanceamento, muitos algoritmos de aprendizado de máquina supervisionados não lidam bem com o problema, sendo SVM a única exceção notável (Clauss et al., 2016). Mack et al. (2014) exploraram este tema com profundidade, afirmando que “a classificação de classe única está repleta de incerteza e automação completa é difícil, devido à limitada informação de referência disponível para treinar o classificador”. Como resultado, eles propuseram uma estratégia de classificação de classe única orientada ao usuário baseada na visualização e interpretação dos resultados durante o processamento dos dados, fornecendo assim ferramentas para corrigir inconsistências.

Dentre os fatores extrínsecos que afetam o desenvolvimento de ferramentas baseadas em sensoriamento remoto para classificação de culturas, o uso de dados de referência pouco confiáveis é frequentemente apontado como o mais importante (Esch et al., 2014). Sem dados de referência apropriados para treinamento, teste e validação, a propagação de erros se torna um problema (Chellasamy et al., 2016), a incerteza aumenta (Hao et al., 2015), e a avaliação da real contribuição do método proposto se torna menos confiável (Kontgis et al., 2015). A falta de dados de referência apropriados levou alguns autores a usar imagens do Google Earth para produzir dados de referência rotulados (Manjunath et al., 2015). Esse processo, apesar de estar sujeito a efeitos visuais e psicológicos bem conhecidos, pode produzir referências confiáveis quando dados melhores não estão disponíveis (Gong et al., 2013). A dificuldade envolvida na obtenção de dados de referência levou Atzberger (2013) a incluir o estabelecimento de redes de locais de validação como uma das principais recomendações para futuros esforços em sensoriamento remoto aplicado à agricultura.

Vale destacar que a complexidade da tarefa de segmentação e classificação é fortemente dependente da aplicação. Em casos para os quais as condições da imagem são relativamente controladas e os objetos a serem identificados são bem definidos e diferentes de seus arredores, alguns

métodos encontrados na literatura ultrapassam 85% de acerto, valor este frequentemente mencionado como o limiar para uso prático (Nooni et al., 2014; Löw et al., 2015). Assim, apesar de a segmentação e a classificação de culturas usando imagens de sensoriamento remoto serem essencialmente um problema aberto, a tecnologia evoluiu o suficiente para ser usada com sucesso em diversas situações.

Todos os fatores discutidos nesta seção se aplicam, em maior ou menor grau, às condições específicas encontradas no Brasil. Porém, alguns aspectos merecem ser enfatizados. O Brasil é um país de grande extensão territorial contendo diferentes zonas climáticas e uma estrutura fundiária que é fortemente dependente da região geográfica que se considera. Para que seja possível lidar com tal variedade de condições, a abordagem que considera a evolução temporal dos espectros de cada área vem sendo a preferida (Kastens et al., 2017), uma vez que ela propicia identificar a dinâmica da vegetação em diversas escalas temporais. Como resultado, torna-se possível caracterizar os ciclos fenológicos e suas variações ao longo do tempo, o que por sua vez possibilita caracterizar a dinâmica das transições entre diferentes usos e coberturas da terra. Esses fatos vêm inspirando a criação de algoritmos baseados na combinação entre séries temporais de imagens de satélite e técnicas de aprendizado de máquina para a classificação das áreas agrícolas brasileiras (Brown et al., 2013; Kastens et al., 2017; Picoli et al., 2018). A tendência é que, com a disponibilização de mais dados de referência de qualidade para o treinamento dos novos algoritmos, a classificação automática de áreas agrícolas se torne mais confiável e amplamente utilizada, tanto no Brasil quanto no restante do mundo.

Conclusões

Este artigo apresentou uma visão geral do progresso feito na classificação de áreas agrícolas. Uma análise crítica do cenário passado, presente e futuro para esta linha de pesquisa foi apresentado, onde a evolução dos principais desafios e respectivas soluções foi discutida. A principal conclusão é que há ainda uma grande lacuna a ser preenchida a fim de aumentar o grau de automação dos processos, mantendo-os ao mesmo tempo suficientemente acurados para uso prático. Por outro lado, com mais imagens de alta qualidade e mais poder computacional se tornando disponíveis, a exploração de técnicas de aprendizado de máquina mais poderosas, como aprendizado profundo, se torna factível. Isto, aliado a avanços em fusão de imagens e no uso efetivo de dados auxiliares, pode fazer com que seja possível superar ao menos algumas das limitações que ainda afetam a usabilidade de ferramentas de classificação de culturas.

Referências

- AGUILAR, M. A.; VALLARIO, A.; AGUILAR, F. J.; LORCA, A. G.; PARENTE, C. Object-based greenhouse horticultural crop identification from multi-temporal satellite imagery: A case study in Almeria, Spain. **Remote Sensing**, v. 7, n. 6, p. 7378-7401, Jun. 2015. DOI:10.3390/rs70607378.
- AKAR, Ö.; GÜNGÖR, O. Integrating multiple texture methods and NDVI to the random forest classification algorithm to detect tea and hazelnut plantation areas in Northeast Turkey. **International Journal of Remote Sensing**, v. 36, n. 2, p. 442-464, Jan. 2015. DOI: 10.1080/01431161.2014.995276.
- ALI, M.; CLAUSI, D. Using the canny edge detector for feature extraction and enhancement of remote sensing images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2001, Sidney. **Proceedings...** [New York]: IEEE, 2001. DOI: 10.1109/IGARSS.2001.977981.

ATZBERGER, C. Advances in remote sensing of agriculture: context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, Feb. 2013. DOI:10.3390/rs5020949.

ATZBERGER, C.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; UDELHOVEN, T.; MATTIUZZI, M.; SANCHEZ, G. A.; ARAI, E. Obtaining crop-specific time profiles of NDVI: the use of unmixing approaches for serving the continuity between SPOT-VGT and PROBA-V time series. **International Journal of Remote Sensing**, v. 35, n. 7, p. 2615-2638, Apr. 2014. DOI: <https://doi.org/10.1080/01431161.2014.883106>.

BARUTH, B.; ROYER, A.; KLISCH, A.; GENOVESE, G. The use of remote sensing within the mars crop yield monitoring system of the European commission. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, pt. B8, p. 935-939. Edição dos proceedings do XXI ISPRS Congress, Beijing, July 2008. Disponível em: <<https://pdfs.semanticscholar.org/f5af/eccea975c3e8bb11d8c5859232981e514440.pdf>>. Acesso em: 19 nov. 2018.

BECKER-RESHEF, I.; JUSTICE, C.; SULLIVAN, M.; VERMOTE, E.; TUCKER, C.; ANYAMBA, A.; SMALL, J.; PAK, E.; MASUOKA, E.; SCHMALTZ, J.; HANSEN, M.; PITTMAN, K.; BIRKETT, C.; WILLIAMS, D.; REYNOLDS, C.; DOORN, B. Monitoring global croplands with coarse resolution earth observation: the global agriculture monitoring (GLAM) project. **Remote Sensing**, v. 2, n. 6, p. 1589-1609, June 2010. DOI:10.3390/rs2061589.

BELLÓN, B.; BÉGUÉ, A.; LO SEEN, D.; ALMEIDA, C. A.; SIMÕES, M. A remote sensing approach for regional-scale mapping of agricultural land-use systems based on NDVI time series. **Remote Sensing**, v. 9, n. 6, p. 1-17, June 2017. Article 600. DOI: 10.3390/rs9060600.

BEN SALAH, M.; MITICHE, A.; AYED, I. B. Multiregion image segmentation by parametric kernel graph cuts. **IEEE Transactions on Image Processing**, v. 20, n. 2, p. 545-557, Feb. 2011. DOI: 10.1109/TIP.2010.2066982.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, n. 3-4, p. 239-258, Jan. 2004. DOI: 10.1016/j.isprsjprs.2003.10.002.

BHASKARAN, S.; PARAMANANDA, S.; RAMNARAYAN, M. Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data. **Applied Geography**, v. 30, n. 4, p. 650-665, Dec. 2010. DOI: 10.1016/j.apgeog.2010.01.009.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 2-16, Jan. 2010. DOI: 10.1016/j.isprsjprs.2009.06.004.

BLASCHKE, T.; LANG, S.; HAY, G. J. (Ed.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer-Verlag, 2008. 803 p. (Lecture notes in geoinformation and cartography).

BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; MEER, F. van der; WERFF, H. van der; COILLIE, F. van; TIEDE, D. Geographic object-based image analysis towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180-191, Jan. 2014. DOI: 10.1016/j.isprsjprs.2013.09.014.

BONTEMPS, S.; ARIAS, M.; CARA, C.; DEDIEU, G.; GUZZONATO, E.; HAGOLLE, O.; INGLADA, J.; MATTON, N.; MORIN, D.; POPESCU, R.; RABAUTE, T.; SAVINAUD, M.; SEPULCRE, G.; VALERO, S.; AHMAD, I.; BÉGUÉ, A.; WU, B.; ABELLEYRA, D. de; DIARRA, A.; DUPUY, S.; FRENCH, A.; AKHTAR, I. H.; KUSSUL, N.; LEBOURGEOIS, V.; LE PAGE, M.; NEWBY, T.; SAVIN, I.; VERÓN, S.; KOETZ, B.; DEFOURNY, P. Building a data set over 12 globally distributed sites to support the development of agriculture monitoring applications with Sentinel-2. **Remote Sensing**, v. 7, n. 12, p. 16062-16090, Dec. 2015. DOI: 10.3390/rs71215815.

BROWN, J. C.; KASTENS, J. H.; COUTINHO, A. C.; VICTORIA, D. C.; BISHOP, C. R. Classifying multiyear agricultural land use data from Mato Grosso using time-series Modis vegetation index data. **Remote Sensing of Environment**, v. 130, p. 39-50, Mar. 2013. DOI: 10.1016/j.rse.2012.11.009.

CASTILLEJO-GONZÁLEZ, I. L.; LÓPEZ-GRANADOS, F.; GARCÍA-FERRER, A.; PEÑA-BARRAGÁN, J. M.; JURADO-EXÓSITO, M.; SÁNCHEZ DE LA ORDEN, M. DE; GONZÁLEZ-AUDICANA, M. Object- and pixel-based analysis for mapping crops and their agro-environmental associated measures using Quickbird imagery. **Computers and Electronics in Agriculture**, v. 68, n. 2, p. 207-215, Oct. 2009. DOI: 10.1016/j.compag.2009.06.004.

CHANG, K.-W.; SHEN, Y.; LO, J.-C. Predicting rice yield using canopy reflectance measured at booting stage. **Agronomy Journal**, v. 97, n. 3, p. 872-878, May 2005. DOI: 10.2134/agronj2004.0162.

CHELLASAMY, M.; FERRÉ, T. P. A.; GREVE, M. H. Evaluating an ensemble classification approach for crop diversity verification in Danish greening subsidy control. **International Journal of Applied Earth Observation and Geoinformation**, v. 49, p. 10-23, July 2016. DOI: 10.1016/j.jag.2016.01.008..

- CHEN, X.; CHEN, J.; SHI, Y.; YAMAGUCHI, Y. An automated approach for updating land cover maps based on integrated change detection and classification methods. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 71, p. 86-95, July 2012. DOI: 10.1016/j.isprsjprs.2012.05.006.
- CHEN, Y.; SONG, X.; WANG, S.; HUANG, J.; MANSARAY, L. R. Impacts of spatial heterogeneity on crop area mapping in Canada using MODIS data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 451-461, Sept. 2016. DOI: 10.1016/j.isprsjprs.2016.07.007.
- CHENG, G.; HAN, J. A survey on object detection in optical remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 117, p. 11-28, July 2016. DOI: 10.1016/j.isprsjprs.2016.03.014.
- CHENG, Y.; YU, L.; CRACKNELL, A. P.; GONG, P. Oil palm mapping using Landsat and Palsar: a case study in Malaysia. **International Journal of Remote Sensing**, v. 37, n. 22, p. 5431-5442, Nov. 2016. DOI: 10.1080/01431161.2016.1241448.
- CLAUSS, K.; YAN, H.; KUENZER, C. Mapping paddy rice in China in 2002, 2005, 2010 and 2014 with Modis time series. **Remote Sensing**, v. 8, n. 5, May 2016. Article 434. DOI: 10.3390/rs8050434.
- COHEN, Y.; SHOSHANY, M. Analysis of convergent evidence in an evidential reasoning knowledge-based classification. **Remote Sensing of Environment**, v. 96, n. 3-4, p. 518-528, Jun. 2005. DOI: 10.1016/j.rse.2005.04.009.
- CONRAD, C.; DECH, S.; DUBOVYK, O.; FRITSCH, S.; KLEIN, D.; LÖW, F.; SCHORCHT, G.; ZEIDLER, J. Derivation of temporal windows for accurate crop discrimination in heterogeneous croplands of Uzbekistan using multitemporal RapidEye images. **Computers and Electronics in Agriculture**, v. 103, p. 63-74, Apr. 2014. DOI: 10.1016/j.compag.2014.02.003.
- DONG, J.; XIAO, X. Evolution of regional to global paddy rice mapping methods: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 214-227, Sept. 2016. DOI: 10.1016/j.isprsjprs.2016.05.010.
- DONG, J.; XIAO, X.; MENARGUEZ, M. A.; ZHANG, G.; QIN, Y.; THAU, D.; BIRADAR, C.; MOORE III, B. Mapping paddy rice planting area in Northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth engine. **Remote Sensing of Environment**, v. 185, p. 142-154, Nov. 2016. DOI: 10.1016/j.rse.2016.02.016.
- DURAND, N.; DERIVAUX, S.; FORESTIER, G.; WEMMERT, C.; GANCARSKI, P. Ontology-based object recognition for remote sensing image interpretation. IEEE INTERNATIONAL CONFERENCE ON TOOLS WITH ARTIFICIAL INTELLIGENCE, 19., 2007, Patras. **Proceedings...** Los Alamitos: IEEE Computer Society, 2007. p. 472-479. DOI: 10.1109/ICTAI.2007.111.
- DURGUN, Y. O.; GOBIN, A.; KERCHOVE, R. van den; TYCHON, B. Crop area mapping using 100-m Proba-V time series. **Remote Sensing**, v. 8, n. 7, July 2016. Article 585. DOI:10.3390/rs8070585.
- ELIA, C. d'; POGGI, G.; SCARPA, G. A tree-structured Markov random field model for Bayesian image segmentation. **IEEE Transaction on Image Processing**, v. 12, n. 10, p. 1259-1273, Oct. 2003. DOI: 10.1109/TIP.2003.817257.
- ESCH, T.; METZ, A.; MARCONCINI, M.; KEIL, M. Combined use of multi-seasonal high and medium resolution satellite imagery for parcel-related mapping of cropland and grassland. **International Journal of Applied Earth Observation and Geoinformation**, v. 28, p. 230-237, May 2014. DOI: 10.1016/j.jag.2013.12.007.
- ESTADOS UNIDOS. Agency for International Development. **Famine early warning system network** (Fews Net). Disponível em: <<http://fews.net>>. Acesso: 31 out. 2017.
- FAN, H.; FU, X.; ZHANG, Z.; WU, Q. Phenology-based vegetation index differencing for mapping of rubber plantations using Landsat OLI data. **Remote Sensing**, v. 7, n.5, p. 6041-6058, May 2015. DOI:10.3390/rs70506041.
- FAO. **GIEWS - global information and early warning system**. 2018. Disponível em: <fao.org/giews/en>. Acesso em: 31 out. 2018.
- FARAG, A. A.; MOHAMED, R. M.; EL-BAZ, A. A unified framework for map estimation in remote sensing image segmentation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 7, p. 1617-1634, July 2005. DOI: 10.1109/TGRS.2005.849059.
- FORKUOR, G.; CONRAD, C.; THIEL, M.; ULLMANN, T.; ZOUNGRANA, E. Integration of optical and synthetic aperture radar imagery for improving crop mapping in Northwestern Benin, West Africa. **Remote Sensing**, v. 6, n. 7, p. 6472-6499, July 2014. DOI: 10.3390/rs6076472.
- GALLEGO, F. J.; KUSSUL, N.; SKAKUN, S.; KRAVCHENKO, O.; SHELESTOV, A.; KUSSUL, O. Efficiency assessment of using satellite data for crop area estimation in Ukraine. **International Journal of Applied Earth Observation and Geoinformation**, v. 29, p. 22-30, June 2014. DOI: 10.1016/j.jag.2013.12.013.

GAMANYA, R.; DE MAEYER, P.; DE DAPPER, M. An automated satellite image classification design using object-oriented segmentation algorithms: A move towards standardization. **Expert Systems with Applications**, v. 32, n. 2, p. 616-624, Fev. 2007. DOI: 10.1016/j.eswa.2006.01.05.

GERSTMANN, H.; MÖLLER, M.; GLÄßER, C. Optimization of spectral indices and long-term separability analysis for classification of cereal crops using multi-spectral RapidEye imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 115-125, Oct. 2016.

GONG, P.; WANG, J.; YU, L.; ZHAO, Y.; ZHAO, Y.; LIANG, L.; NIU, Z.; HUANG, X.; FU, H.; LIU, S.; LI, C.; LI, X.; FU, W.; LIU, C.; XU, Y.; WANG, X.; CHENG, Q.; HU, L.; YAO, W.; ZHANG, H.; ZHU, P.; ZHAO, Z.; ZHANG, H.; ZHENG, Y.; JI, L.; ZHANG, Y.; CHEN, H.; YAN, A.; GUO, J.; YU, L.; WANG, L.; LIU, X.; SHI, T.; ZHU, M.; CHEN, Y.; YANG, G.; TANG, P.; XU, B.; GIRI, C.; CLINTON, N.; ZHU, Z.; CHEN, J.; CHEN, J. Finer resolution observation and monitoring of global land cover: First mapping results with Landsat TM and ETM+ data. **International Journal of Remote Sensing**, v. 34, n. 7, p. 2607-2654, Apr. 2013. DOI: 10.1080/01431161.2012.748992.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016. 775 p. il. (Adaptive computation and machine learning).

GRZEGOZEWSKI, D. M.; JOHANN, J. A.; URIBE-OPAZO, M. A.; MERCANTE, E.; COUTINHO, A. C. Mapping soya bean and corn crops in the state of Paraná, Brazil, using EVI images from the Modis sensor. **International Journal of Remote Sensing**, v. 37, n. 6, p. 1257-1275, Mar. 2016. DOI: 10.1080/01431161.2016.1148285.

GUMMA, M. K.; UPPALA, D.; MOHAMMED, I. A.; WHITBREAD, A. M.; MOHAMMED, I. R. Mapping direct seeded rice in Raichur district of Karnataka, India. **Photogrammetric Engineering & Remote Sensing**, v. 81, n. 11, p. 873-880, Nov. 2015. DOI: 10.1080/01431161.2016.1148285.

HAERTEL, V.; LANDGREBE, D. A. On the classification of classes with nearly equal spectral response in remote sensing hyperspectral image data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 5, p. 2374-2386, Sept. 1999. Disponível em: <<https://www.lume.ufrgs.br/bitstream/handle/10183/27563/000294411.pdf;sequence=1>>. Acesso em: 21 nov. 2018.

HAO, P.; WANG, L.; NIU, Z.; AABLIKIM, A.; HUANG, N.; XU, S.; CHEN, F. The potential of time series merged from Landsat-5 TM and HJ-1 CCD for crop classification: a case study for Bole and Manas counties in Xinjiang, China. **Remote Sensing**, v. 6, n. 8, p. 7610-7631, Aug. 2014. Disponível em: <<https://pdfs.semanticscholar.org/dbf6/a3bcc2e9fd6c990e3a2ca562a995ed977dbc.pdf>>. Acesso em 21 nov. 2018.

HAO, P.; ZHAN, Y.; WANG, L.; NIU, Z.; SHAKIR, M. Feature selection of time series Modis data for early crop classification using random forest: a case study in Kansas, USA. **Remote Sensing**, v. 7, n. 5, p. 5347-5369, Apr. 2015. DOI:10.3390/rs70505347.

HARTFIELD, K. A.; MARSH, S. E.; KIRK, C. D.; CARRIÉRE, Y. Contemporary and historical classification of crop types in Arizona. **International Journal of Remote Sensing**, v. 34, n. 17, p. 6024-6036, Aug. 2013. DOI: 10.1080/01431161.2013.793861.

HU, Q.; WU, W.; SONG, Q.; YU, Q.; LU, M.; YANG, P.; TANG, H.; LONG, Y. Extending the pairwise separability index for multicrop identification using time-series Modis images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 11, p. 6349-6361, July 2016. DOI: 10.1109/TGRS.2016.2581210.

HUANG, J.; WANG, H.; DAI, Q.; HAN, D. Analysis of NDVI data for crop identification and yield estimation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 11, p. 4374-4384, Aug. 2014. DOI: 10.1109/JSTARS.2014.2334332.

INGLADA, J.; MURON, V.; PICHARD, D.; FEUVRIER, T. Analysis of artifacts in subpixel remote sensing image registration. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 1, p. 254-264, Jan. 2007. DOI: 10.1109/TGRS.2006.882262.

INGLADA, J.; VINCENT, A.; ARIAS, M.; MARAIS-SICRE, C. Improved early crop type identification by joint use of high temporal resolution SAR and optical image time series. **Remote Sensing**, v. 8, n. 5, May 2016. Article 362. DOI: 10.3390/rs8050362.

INGLADA, J.; ARIAS, M.; TARDY, B.; HAGOLLE, O.; VALERO, S.; MORIN, D.; DEDIEU, G.; SEPULCRE, G.; BONTEMPS, S.; DEFOURNY, P.; KOETZ, B. Assessment of an operational system for crop type map production using high temporal and spatial resolution satellite optical imagery. **Remote Sensing**, v. 7, n. 9, p. 12356-12379, Sep. 2015. DOI: 10.3390/rs70912356.

JANSSEN, L. L. F.; MIDDELKOOP, H. Knowledge-based crop classification of a Landsat Thematic Mapper image. **International Journal of Remote Sensing**, v. 13, n. 15, p. 2827-2837, July 1992.

- JOHNSON, D. M. A comparison of coincident Landsat-5 TM and Resourcesat-1 AWIFS imagery for classifying croplands. **Photogrammetric Engineering & Remote Sensing**, v. 74, n. 11, p. 1413-1423, Nov. 2008.
- JOHNSON, B. A.; SCHEYVENS, H.; SHIVAKOTI, B. R. An ensemble pansharpening approach for finer-scale mapping of sugarcane with Landsat 8 imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, p. 218-225, Dec. 2014. DOI: 10.1016/j.jag.2014.06.003.
- KARAKIZI, C.; OIKONOMOU, M.; KARANTZALOS, K. Vineyard detection and vine variety discrimination from very high resolution satellite data. **Remote Sensing**, v. 8, n. 3, Mar. 2016. Article 235. DOI: 10.3390/rs8030235.
- KARILA, K.; NEVALAINEN, O.; KROOKS, A.; KARJALAINEN, M.; KAASALAINEN, S. Monitoring changes in rice cultivated area from SAR and optical satellite images in Ben Tre and Tra Vinh provinces in Mekong Delta, Vietnam. **Remote Sensing**, v. 6, n. 5, p. 4090-4108, May 2014. DOI: 10.3390/rs6054090.
- KASTENS, J. H.; BROWN, J. C.; COUTINHO, A. C.; BISHOP, C.; ESQUERDO, J. C. D. M. Soy moratorium impacts on soybean and deforestation dynamics in Mato Grosso, Brazil. **PLoS One**, v. 12, Apr. 2017. Article: e0176168. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0176168>>. Acesso em: 21 nov. 2018.
- KAWAKUBO, F. S.; MACHADO, R. P. P. Mapping coffee crops in Southeastern Brazil using spectral mixture analysis and data mining classification. **International Journal of Remote Sensing**, v. 37, n. 14, p. 3414-3436, July 2016. DOI: 10.1080/01431161.2016.1201226.
- KHAN, A.; HANSEN, M. C.; POTAPOV, P.; STEHMAN, S. V.; CHATTA, A. A. Landsat-based wheat mapping in the heterogeneous cropping system of Punjab, Pakistan. **International Journal of Remote Sensing**, v. 37, n. 6, p. 1391-1410, Feb. 2016. DOI: 10.1080/01431161.2016.1151572.
- KIM, H.-O.; YEOM, J.-M. Effect of red-edge and texture features for object-based paddy rice crop classification using RapidEye multi-spectral satellite image data. **International Journal of Remote Sensing**, v. 35, n. 19, p. 7046-7068, Oct. 2014. DOI: 10.1080/01431161.2014.965285.
- KING, L.; ADUSEI, B.; STEHMAN, S. V.; POTAPOV, P. V.; SONG, X.-P.; KRYLOV, A.; DI BELLA, C.; LOVELAND, T. R.; JOHNSON, D. M.; HANSEN, M. C. A multi-resolution approach to national-scale cultivated area estimation of soybean. **Remote Sensing of Environment**, v. 195, p. 13-29, June 2017. DOI: <https://doi.org/10.1016/j.rse.2017.03.047>.
- KONTGIS, C.; SCHNEIDER, A.; OZDOGAN, M. Mapping rice paddy extent and intensification in the Vietnamese Mekong river delta with dense time stacks of Landsat data. **Remote Sensing of Environment**, v. 169, p. 255-269, Nov. 2015. DOI: <https://doi.org/10.1016/j.rse.2015.08.004>.
- KUENZER, C.; KNAUER, K. Remote sensing of rice crop areas. **International Journal of Remote Sensing**, v. 34, n. 6, p. 2101-2139, Mar. 2013. DOI: 10.1080/01431161.2012.738946.
- KUSSUL, N.; LAVRENIUK, M.; SKAKUN, S.; SHELESTOV, A. Deep learning classification of land cover and crop types using remote sensing data. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 5, p. 778-782, May 2017. DOI: 10.1109/LGRS.2017.2681128.
- KUSSUL, N.; LEMOINE, G.; GALLEG0, F. J.; SKAKUN, S. V.; LAVRENIUK, M.; SHELESTOV, A. Y. Parcel-based crop classification in Ukraine using Landsat-8 data and Sentinel-1A data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 6, p. 2500-2508, May 2016. DOI: 10.1109/JSTARS.2016.2560141.
- LALIBERTE, A.; RANGO, A.; HAVSTAD, K.; PARIS, J.; BECK, R.; MCNEELY, R.; GONZALEZ, A. Object-oriented image analysis for mapping shrub encroachment from 1937 to 2003 in Southern New Mexico. **Remote Sensing of Environment**, v. 93, n. 1-2, p. 198-210, Oct. 2004. DOI: <https://doi.org/10.1016/j.rse.2004.07.011>.
- LEBOURGEOIS, V.; DUPUY, S.; VINTROU, E.; AMELINE, M.; BUTLER, S.; BÉGUÉ, A. A combined random forest and OBIA classification scheme for mapping smallholder agriculture at different nomenclature levels using multisource data (simulated Sentinel-2 time series, VHRS and DEM). **Remote Sensing**, v. 9, n.3, p. 1-20, Mar. 2017. Article 259. DOI: 10.3390/rs9030259.
- LI, Q.; WANG, C.; ZHANG, B.; LU, L. Object-based crop classification with Landsat-MODIS enhanced time-series data. **Remote Sensing**, v. 7, n. 12, p. 16091-16107, Dec. 2015. DOI: 10.3390/rs71215820.
- LI, Q.; CAO, X.; JIA, K.; ZHANG, M.; DONG, Q. Crop type identification by integration of high-spatial resolution multispectral data with features extracted from coarse-resolution time-series vegetation index data. **International Journal of Remote Sensing**, v. 35, n. 16, p. 6076-6088, Aug. 2014. DOI: 10.1080/01431161.2014.943325.
- LI, X.; HUI, N.; SHEN, H.; FU, Y.; ZHANG, L. A robust mosaicking procedure for high spatial resolution remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 109, p. 108-125, Nov. 2015. DOI: <https://doi.org/10.1016/j.isprsjprs.2015.09.009>.

LIU, M. W.; OZDOGAN, M.; ZHU, X. Crop type classification by simultaneous use of satellite images of different resolutions. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 6, p. 3637-3649, Jun. 2014. DOI: 10.1109/TGRS.2013.2274431.

LOBO, A. Image segmentation and discriminant analysis for the identification of land cover units in ecology. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 5, p. 1136-1145, Sept. 1997. DOI: 10.1109/36.628781.

LONG, J. A.; LAWRENCE, R. L.; GREENWOOD, M. C.; MARSHALL, L.; MILLER, P. R. Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest. **GIScience & Remote Sensing**, v. 50, n. 4, p. 418-436, Apr. 2013. DOI: 10.1080/15481603.2013.817150.

LÖW, F.; DUVEILLER, G. Defining the spatial resolution requirements for crop identification using optical remote sensing. **Remote Sensing**, v. 6, n. 9, p. 9034-9063, Sept. 2014. DOI: <https://doi.org/10.3390/rs6099034>.

LÖW, F.; CONRAD, C.; MICHEL, U. Decision fusion and non-parametric classifiers for land use mapping using multi-temporal RapidEye data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 191-204, Oct. 2015. DOI: <https://doi.org/10.1016/j.isprsjprs.2015.07.001>.

LÖW, F.; KNOFEL, P.; CONRAD, C. Analysis of uncertainty in multi-temporal object-based classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 91-106, Jul. 2015. DOI: <https://doi.org/10.1016/j.isprsjprs.2015.03.004>.

LÖW, F.; MICHEL, U.; DECH, S.; CONRAD, C. Impact of feature selection on the accuracy and spatial uncertainty of per-field crop classification using support vector machines. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 85, p. 102-119, Nov. 2013. DOI: <https://doi.org/10.1016/j.isprsjprs.2013.08.007>.

MA, X.; WANG, H.; WANG, J. Semisupervised classification for hyperspectral image based on multi-decision labeling and deep feature learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 120, p. 99-107, Oct. 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.09.001>.

MACK, B.; ROSCHER, R.; WASKE, B. Can I trust my one-class classification? **Remote Sensing**, v. 6, n. 9, p. 8779-8802, Sep. 2014. DOI: 10.3390/rs6098779.

MANJUNATH, K. R.; MORE, R. S.; JAIN, N. K.; PANIGRAHY, S.; PARIHAR, J. S. Mapping of rice-cropping pattern and cultural type using remote-sensing and ancillary data: a case study for south and Southeast Asian countries. **International Journal of Remote Sensing**, v. 36, n. 24, p. 6008- 6030, Nov. 2015. DOI: <https://doi.org/10.1080/0143116.2015.1110259>.

MASSEY, R.; SANKEY, T. T.; CONGALTON, R. G.; YADAV, K.; THENKABAIL, P. S.; OZDOGAN, M.; SÁNCHEZ MEADOR, A. J. Modis phenology-derived, multi-year distribution of conterminous U.S. crop types. **Remote Sensing of Environment**, v. 198, p. 490-503, Sep. 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.033>.

MATHIEU, R.; FREEMAN, C.; ARYAL, J. Mapping private gardens in urban areas using object-oriented techniques and very high-resolution satellite imagery. **Landscape and Urban Planning**, v. 81, n. 3, p. 179-192, Jun. 2007.

MATHUR, A.; FOODY, G. M. Crop classification by support vector machine with intelligently selected training data for an operational application. **International Journal of Remote Sensing**, v. 29, n. 8, p. 2227-2240, Apr. 2008. DOI: 10.1080/01431160701395203.

MOTOHKA, T.; NASAHARA, K. N.; MIYATA, A.; MANO, M.; TSUCHIDA, S. Evaluation of optical satellite remote sensing for rice paddy phenology in monsoon Asia using a continuous in situ dataset. **International Journal of Remote Sensing**, v. 30, n. 17, p. 4343-4357, Sept. 2009. DOI: 10.1080/01431160802549369.

MUKASHEMA, A.; VELDKAMP, A.; VRIELING, A. Automated high resolution mapping of coffee in Rwanda using an expert Bayesian network. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, p. 331-340, Dec. 2014. DOI: <https://doi.org/10.1016/j.jag.2014.05.005>.

NAVARRO, A.; ROLIM, J.; MIGUEL, I.; CATALÃO, J.; SILVA, J.; PAINHO, M.; VEKERDY, Z. Crop monitoring based on SPOT-5 Take-5 and Sentinel-1A data for the estimation of crop water requirements. **Remote Sensing**, v. 8, n. 6, p. 1-20, June 2016. Article 525. DOI: 10.3390/rs8060525.

NIDAMANURI, R. R.; ZBELL, B. Use of field reflectance data for crop mapping using airborne hyperspectral image. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 683-691, May 2011. DOI: 10.1016/j.isprsjprs.2011.05.001.

NOONI, I. K.; DUKER, A. A.; VAN DUREN, I.; ADDAE-WIREKO, L.; OSEI JR., E. M. Support vector machine to map oil palm in a heterogeneous environment. **International Journal of Remote Sensing**, v. 35, n. 13, p. 4778-4794, June 2014. DOI: 10.1080/01431161.2014.930201.

OZDARICI-OK, A.; OK, A. O.; SCHINDLER, K. Mapping of agricultural crops from single high-resolution multispectral images - data-driven smoothing vs. parcel-based smoothing. **Remote Sensing**, v. 7, n. 5, p. 5611–5638, May 2015. DOI: 10.3390/rs70505611.

PEÑA, M. A.; BRENNING, A. Assessing fruit-tree crop classification from Landsat-8 time series for the Maipo Valley, Chile. **Remote Sensing of Environment**, v. 171, p. 234-244, Dec. 2015. DOI: 10.1016/j.rse.2015.10.029.

PEÑA, J. M.; GUTIERREZ, P. A.; HERVAS-MARTINEZ, C.; SIX, J.; PLANT, R. E.; LOPEZ-GRANADOS, F. Object-based image classification of summer crops with machine learning methods. **Remote Sensing**, v. 6, n. 6, p. 5019-5041, May 2014. DOI: 10.3390/rs6065019.

PEÑA-BARRAGÁN, J. M.; NGUGI, M. K.; PLANT, R. E.; SIX, J. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. **Remote Sensing of Environment**, v. 115, n. 6, p. 1301-1316, June 2011. DOI:10.1016/j.rse.2011.01.009.

PETITJEAN, F.; KURTZ, C.; PASSAT, N.; GANCARSKI, P. Spatio-temporal reasoning for the classification of satellite image time series. **Pattern Recognition Letters**, v. 33, n. 13, p. 1805-1815, Oct. 2012. DOI: <https://doi.org/10.1016/j.patrec.2012.06.009>.

PICOLI, M. C. A.; CAMARA, G.; SANCHES, I.; SIMÕES, R.; CARVALHO, A.; MACIEL, A.; COUTINHO, A.; ESQUERDO, J.; ANTUNES, J.; BEGOTTI, R. A.; ARVOR, D.; ALMEIDA, C. Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, Part B, p. 328-339, 2018. DOI: <https://doi.org/10.1016/j.isprsjprs.2018.08.007>.

POHL, C.; GENDEREN, J. L. van. Review article multisensor image fusion in remote sensing: concepts, methods and applications. **International Journal of Remote Sensing**, v. 19, n. 5, p. 823-854, Mar. 1998. DOI: <https://doi.org/10.1080/014311698215748>.

POTGIETER, A. B.; LAWSON, K.; HUETE, A. R. Determining crop acreage estimates for specific winter crops using shape attributes from sequential Modis imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 254-263, Aug. 2013. DOI: <https://doi.org/10.1016/j.jag.2012.09.009>.

QIN, Y.; XIAO, X.; DONG, J.; ZHOU, Y.; ZHU, Z.; ZHANG, G.; DU, G.; JIN, C.; KOU, W.; WANG, J.; LI, X. Mapping paddy rice planting area in cold temperate climate region through analysis of time series Landsat 8 (OLI), Landsat 7 (ETM+) and Modis imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 220-233, July 2015. DOI: <https://doi.org/10.1016/j.isprsjprs.2015.04.008>.

ROUMENINA, E.; ATZBERGER, C.; VASSILEV, V.; DIMITROV, P.; KAMENOVA, I.; BANOV, M.; FILCHEV, L.; JELEV, G. Single- and multi-date crop identification using Proba-V 100 and 300 m S1 products on Zlatia test site, Bulgaria. **Remote Sensing**, v. 7, n. 10, p. 13843-13862, Oct. 2015. DOI: 10.3390/rs71013843.

SCHMEDTMANN, J.; CAMPAGNOLO, M. L. Reliable crop identification with satellite imagery in the context of common agriculture policy subsidy control. **Remote Sensing**, v. 7, n. 7, p. 9325-9346, July 2015. DOI: 10.3390/rs70709325.

SCHULTZ, B.; IMMITZER, M.; FORMAGGIO, A. R.; DEL' ARCO SANCHES, I.; LUIZ, A. J. B.; ATZBERGER, C. Self-guided segmentation and classification of multi-temporal Landsat 8 images for crop type mapping in Southeastern Brazil. **Remote Sensing**, v. 7, n. 11, p. 14482-14508, Nov. 2015. DOI: 10.3390/rs71114482.

SHACKELFORD, A. K.; DAVIS, C. H. A combined fuzzy pixel-based and object-based approach for classification of high-resolution multispectral data over urban areas. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 10, p. 2354-2364, Oct. 2003. DOI: 10.1109/TGRS.2003.815972.

SHAO, Y.; TAFF, G. N.; REN, J.; CAMPBELL, J. B. Characterizing major agricultural land change trends in the Western Corn Belt. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 122, p. 116-125, Dec. 2016. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.10.009>.

SHI, J.; HUANG, J. Monitoring spatio-temporal distribution of rice planting area in the Yangtze river delta region using Modis images. **Remote Sensing**, v. 7, n. 7, p. 8883-8905, July 2015. DOI: [doi:10.3390/rs70708883](https://doi.org/10.3390/rs70708883).

SIACHALOU, S.; MALLINIS, G.; TSAKIRI-STRATI, M. A Hidden Markov models approach for crop classification: Linking crop phenology to time series of multi-sensor remote sensing data. **Remote Sensing**, v. 7, n. 4, p. 3633-3650, Apr. 2015. DOI: 10.3390/rs70403633.

SIMONE, G.; FARINA, A.; MORABITO, F. C.; SERPICO, S. B.; BRUZZONE, L. Image fusion techniques for remote sensing applications. **Information Fusion**, v. 3, n. 1, p. 3-15, Mar. 2002. DOI: [https://doi.org/10.1016/S1566-2535\(01\)00056-2](https://doi.org/10.1016/S1566-2535(01)00056-2).

SINGHA, M.; WU, B.; ZHANG, M. An object-based paddy rice classification using multi-spectral data and crop phenology in Assam, northeast India. **Remote Sensing**, v. 8, n. 6, June 2016. Article 479. DOI: 10.3390/rs8060479.

- SKAKUN, S.; KUSSUL, N.; SHELESTOV, A. Y.; LAVRENIUK, M.; KUSSUL, O. Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 8, p. 3712–3719, Aug. 2016. DOI: 10.1109/JSTARS.2015.2454297.
- SONG, S. L.; GONG, W.; ZHU, B.; HUANG, X. Wavelength selection and spectral discrimination for paddy rice, with laboratory measurements of hyperspectral leaf reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 672–682, Sep. 2011. DOI: 10.1016/j.isprsjprs.2011.05.002.
- SONG, X.-P.; POTAPOV, P. V.; KRYLOV, A.; KING, L.; DI BELLA, C. M.; HUDSON, A.; KHAN, A.; ADUSEI, B.; STEHMAN, S. V.; HANSEN, M. C. National-scale soybean mapping and area estimation in the united states using medium resolution satellite imagery and field survey. **Remote Sensing of Environment**, v. 190, p. 383–395, Mar. 2017. DOI: <https://doi.org/10.1016/j.rse.2017.01.008>.
- SOUZA, C. H. W.; MERCANTE, E.; JOHANN, J. A.; LAMPARELLI, R. A. C.; URIBE-OPAZO, M. A. Mapping and discrimination of soya bean and corn crops using spectro-temporal profiles of vegetation indices. **International Journal of Remote Sensing**, v. 36, n. 7, p. 1809–1824, Apr. 2015. DOI: <https://doi.org/10.1080/01431161.2015.1026956>.
- STAVRAKLOUDIS, D. G.; THEOCHARIS, J. B.; ZALIDIS, G. C. A boosted genetic fuzzy classifier for land cover classification of remote sensing imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 4, p. 529–544, Apr. 2011. DOI: 10.1016/j.isprsjprs.2011.01.010.
- SU, T. Efficient paddy field mapping using Landsat-8 imagery and object-based image analysis based on advanced fractal net evolution approach. **GIScience & Remote Sensing**, v. 54, n. 3, p. 354–380, June 2017. DOI: <https://doi.org/10.1080/15481603.2016.1273438>.
- TARABALKA, Y.; CHANUSSOT, J.; BENEDIKTSSON, J. A. Segmentation and classification of hyperspectral images using watershed transformation. **Pattern Recognition**, v. 43, n. 7, p. 2367–2379, July 2010. DOI: <https://doi.org/10.1016/j.patcog.2010.01.016>.
- TELUGUNTLA, P.; RYU, D.; GEORGE, B.; WALKER, J.; MALANO, H. M. Mapping flooded rice paddies using time series of Modis imagery in the Krishna River Basin, India. **Remote Sensing**, v. 7, n. 7, p. 8858–8882, July 2015. DOI: 10.3390/rs70708858.
- THENKABAIL, P. S.; MARIOTTO, I.; GUMMA, M. K.; MIDDLETON, E. M.; LANDIS, D. R.; HUEMMERICH, K. F. Selection of hyperspectral narrowbands (HNBS) and composition of hyperspectral two-band vegetation indices (HVIS) for biophysical characterization and discrimination of crop types using field reflectance and Hyperion/EO-1 data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 2, p. 427–439, Feb. 2013. DOI: 10.1109/JSTARS.2013.2252601.
- UDUPA, J. K.; LEBLANC, V. R.; ZHUGE, Y.; IMIELINSKA, C.; SCHMIDT, H.; CURRIE, L. M.; HIRSCH, B. E.; WOODBURN, J. A framework for evaluating image segmentation algorithms. **Computerized Medical Imaging and Graphics**, v. 30, n. 2, p. 75–87, Mar. 2006. DOI: 10.1016/j.compmedimag.2005.12.001.
- ULABY, F. T.; LI, R. Y.; SHANMUGAN, K. S. Crop classification using airborne radar and Landsat data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 20, n. 1, p. 42–51, Jan. 1982. DOI: 10.1109/TGRS.1982.4307519.
- UNIÃO EUROPÉIA. **Global monitoring of food security (GMFS) program**. Disponível: <<http://www.gmfs.info/>>. Acesso em: 31 out. 2017.
- VAUDOUR, E.; NOIROT-COSSON, P. E.; MEMBRIVE, O. Early-season mapping of crops and cultural operations using very high spatial resolution Pleiades images. **International Journal of Applied Earth Observation and Geoinformation**, v. 42, p. 128–141, Oct. 2015. DOI: <https://doi.org/10.1016/j.jag.2015.06.003>.
- VIEIRA, M. A.; FORMAGGIO, A. R.; RENNÓ, C. D.; ATZBERGER, C.; AGUIAR, D. A.; MELLO, M. P. Object Based Image Analysis and Data Mining applied to a remotely sensed Landsat time-series to map sugarcane over large areas. **Remote Sensing of Environment**, v. 123, n. 6, p. 553–562, June 2012. DOI: 10.1016/j.rse.2012.04.011.
- VILLA, P.; STROPPIANA, D.; FONTANELLI, G.; AZAR, R.; BRIVIO, P. A. In-season mapping of crop type with optical and X-band SAR data: a classification tree approach using synoptic seasonal features. **Remote Sensing**, v. 7, n. 10, p. 12859–12886, Sept. 2015. DOI: 10.3390/rs71012859.
- WALDHOFF, G.; LUSSEM, U.; BARETH, G. Multi-data approach for remote sensing-based regional crop rotation mapping: a case study for the Rur catchment, Germany. **International Journal of Applied Earth Observation and Geoinformation**, v. 61, p. 55–69, Sept. 2017. DOI: <https://doi.org/10.1016/j.jag.2017.04.009>.

- WALDNER, F.; CANTO, G. S.; DEFOURNY, P. Automated annual cropland mapping using knowledge-based temporal features. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 110, p. 1-13, Dec. 2015. Doi: <https://doi.org/10.1016/j.isprsjprs.2015.09.013>.
- WANG, C.; FAN, Q.; LI, Q.; SOOHOO, W. M.; LU, L. Energy crop mapping with enhanced TM/MODIS time series in the BCAP agricultural lands. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 124, p. 133-143, Feb. 2017. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.12.002>.
- WANG, W.; YAO, X.; TIAN, Y.-C.; LIU, X.-J.; NI, J.; CAO, W.-X.; ZHU, Y. Common spectral bands and optimum vegetation indices for monitoring leaf nitrogen accumulation in rice and wheat. **Journal of Integrative Agriculture**, v. 11, n. 12, p. 2001-2012, Dec. 2012. DOI: [https://doi.org/10.1016/S2095-3119\(12\)60457-2](https://doi.org/10.1016/S2095-3119(12)60457-2).
- WANG, J.; HUANG, J.; ZHANG, K.; LI, X.; SHE, B.; WEI, C.; GAO, J.; SONG, X. Rice fields mapping in fragmented area using multi-temporal HJ-1A/B CCD images. **Remote Sensing**, v. 7, n. 4, p. 3467-3488, Apr. 2015. DOI: 10.3390/rs70403467.
- WHITCRAFT, A. K.; BECKER-RESHEF, I.; KILLOUGH, B. D.; JUSTICE, C. O. Meeting earth observation requirements for global agricultural monitoring: an evaluation of the revisit capabilities of current and planned moderate resolution optical earth observing missions. **Remote Sensing**, v. 7, n. 2, p. 1482-1503, Feb. 2015. DOI: 10.3390/rs70201482.
- WU, B.; GOMMES, R.; ZHANG, M.; ZENG, H.; YAN, N.; ZOU, W.; ZHENG, Y.; ZHANG, N.; CHANG, S.; XING, Q.; VAN HEIJDEN, A. Global crop monitoring: a satellite-based hierarchical approach. **Remote Sensing**, v. 7, n. 4, p. 3907-3933, Apr. 2015. DOI: 10.3390/rs70403907.
- YOU, J.; PEI, Z.; WANG, D. Crop mapping of complex agricultural landscapes based on discriminant space. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 11, p. 4356-4367, Nov. 2014. DOI: 10.1109/JSTARS.2014.2320156.
- YU, Q.; GONG, P.; CLINTON, N.; BIGING, G.; KELLY, M.; SCHIROKAUER, D. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 7, p. 799-811, July 2006. Disponível em: <<http://www.geo.umass.edu/faculty/you/YuPERS2006.pdf>>. Acesso em: 30 out. 2018.
- ZABALA, A.; PONS, X. Impact of lossy compression on mapping crop areas from remote sensing. **International Journal of Remote Sensing**, v. 34, n. 8, p. 2796-2813, Jan. 2013. DOI: 10.1080/01431161.2012.750772.
- ZHANG, Y.; SLAUGHTER, D. C.; STAAB, E. S. Robust hyperspectral vision--based classification for multi-season weed mapping. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 69, p. 65-73, Apr. 2012. DOI: 10.1016/j.isprsjprs.2012.02.006.
- ZHANG, X.; ZHANG, M.; ZHENG, Y.; WU, B. Crop mapping using Proba-V time series data at the Yucheng and Hongxing farm in China. **Remote Sensing**, v. 8, n. 11, Nov. 2016. Article 915. DOI:10.3390/rs8110915.
- ZHANG, H.; LI, Q.; LIU, J.; SHANG, J.; DU, X.; ZHAO, L.; WANG, N.; DONG, T. Crop classification and acreage estimation in North Korea using phenology features. **GIScience & Remote Sensing**, v. 54, n. 3, p. 381-406, Jan. 2017. DOI: 10.1080/15481603.2016.1276255.
- ZHANG, G.; XIAO, X.; DONG, J.; KOU, W.; JIN, C.; QIN, Y.; ZHOU, Y.; WANG, J.; MENARGUEZ, M. A.; BIRADAR, C. Mapping paddy rice planting areas through time series analysis of MODIS land surface temperature and vegetation index data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 106, p. 157-171, Aug. 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271615001483>>. Acesso em: 21 nov. 2018.
- ZHAO, W.; DU, S. Learning multiscale and deep representations for classifying remotely sensed imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 113, p. 155-165, Mar. 2016. DOI: 10.1016/j.isprsjprs.2016.01.004.
- ZHENG, B.; MYINT, S. W.; THENKABAIL, P. S.; AGGARWAL, R. M. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, p. 103-112, Feb. 2015. DOI: <https://doi.org/10.1016/j.jag.2014.07.002>.
- ZHONG, L.; GONG, P.; BIGING, G. S. Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery. **Remote Sensing of Environment**, v. 140, p. 1-13, Jan. 2014. DOI: <https://doi.org/10.1016/j.rse.2013.08.023>.
- ZHONG, L.; HU, L.; YU, L.; GONG, P.; BIGING, G. S. Automated mapping of soybean and corn using phenology. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 119, p. 151-164, Sept. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271616301071>>. Acesso em: 22 nov. 2018.

ZHOU, Y.; XIAO, X.; QIN, Y.; DONG, J.; ZHANG, G.; KOU, W.; JIN, C.; WANG, J.; LI, X. Mapping paddy rice planting area in rice-wetland coexistent areas through analysis of Landsat 8 OLI and Modis images. **International Journal of Applied Earth Observation and Geoinformation**, v. 46, p. 1-12, Apr. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0303243415300490>>. Acesso em: 22 nov. 2018.

ZHU, L.; RADELOFF, V. C.; IVES, A. R. Improving the mapping of crop types in the Midwestern U.S. by fusing Landsat and Modis satellite data. **International Journal of Applied Earth Observation and Geoinformation**, v. 58, p. 1-11, June 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0303243417300120>>. Acesso em: 21 nov. 2018.

Apêndice 1 - Siglas

Alos	Advanced Land Observing Satellite
Asar	Advanced Synthetic Aperture Radar
Aster	Advanced Spaceborne Thermal Emission and Reflection Radiometer
Aviris	Airborne Visible / Infrared Imaging Spectrometer
AWiFS	Advanced Wide Field Sensor
CCD	Charge-Coupled Device
CNN	Convolutional Neural Network
CS	Cuckoo Search
CT	Classification and Regression Tree
DEM	Digital Elevation Model
DT	Decision Tree
Envisat	Environmental Satellite
ETM+	Enhanced Thematic Mapper Plus
EVI	Enhanced Vegetation Index
GA	Genetic Algorithm
Geobia	Geographic Object-Based Image Analysis
HJ-1	Huan Jing-1
HMM	Hidden Markov Models
HVS	Human Visual System
IRS	Indian Remote Sensing
Isodata	Iterative Self-Organizing Data Analysis Technique
kNN	k-Nearest Neighbours
LDA	Linear discriminant analysis
Lidar	Light Detection and Ranging
Liss	Linear Imaging Self Scanner
LSWI	Land Surface Water Index
ML	Maximum-Likelihood
MLP	Multilayer Perceptron
Modis	Moderate Resolution Imaging Spectroradiometer
MRS	Multiresolution Segmentation
MSF	Minimum Spanning Forest
MSS	Multispectral Scanner
MTMF	Mixture Tuned Matched Filtering
NDFI	Normalized Difference Flood Index
NDTI	Normalized Difference Tillage Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NWDWI	Normalized Weighted Difference Water Index

NIR	Near Infrared
OLI	Operational Land Imager
Palsar	Phased Array type L-band Synthetic Aperture Radar
PCA	Principal Component Analysis
Proba	Project for On-Board Autonomy
RF	Random Forest
RGB	Red – Green – Blue
RGRI	Red Green Ratio Index
Rosis	Reflective optics system imaging spectrometer
SAM	Spectral Angle Mapper
SAR	Synthetic Aperture Radar
SEM	Stochastic Estimation Maximization
SFF	Spectral Feature Fitting
SITS	Satellite Image Time Series
SOM	Self-Organizing Maps
Spot	Satellite Pour l'Observation de la Terre
SVM	Support Vector Machine
TIRS	Thermal Infrared Sensor
TM	Thematic Mapper
WDO	Wind Driven Optimization

Apêndice 2 - Lista de trabalhos citados

TABELA 1
Lista de estudos lidando com a identificação de culturas agrícolas.

Ref.	Sensor	Culturas	Locais
Aguilar et al. (2015)	Landsat 8, WorldView-2	Berinjela, pepino, pimenta, tomate	Espanha
Akar e Güngör (2015)	WorldView-2	Chá, avelã	Turquia
Atzberger et al. (2014)	SPOT, PROBA-V, Landsat TM	Cana de açúcar	Brasil (São Paulo)
Bellón et al. (2017)	MODIS	Arroz, milho, soja	Brasil (Tocantins)
Brown et al. (2013)	MODIS	Arroz, milho, soja, algodão, sorgo, girassol	Brasil (Mato Grosso)
Castillejo-González et al. (2009)	QuickBird	Oliveiras, girassol, videiras	Espanha (Andalusia)
Chellassamy et al. (2016)	WorldView-2	Cevada, aveia, trigo, canola, ervilha, triticale, milho, alfafa, morango	Dinamarca
Chen et al. (2016)	MODIS	Milho, canola, soja, trigo	Canadá (Manitoba)
Cheng et al. (2016)	Landsat TM, ALOS PALSAR	Palma de óleo	Malásia
Cheng e Han (2016)	Landsat TM, ALOS PALSAR	Palma de óleo	Malásia
Clauss et al. (2016)	MODIS	Arroz	China
Conrad et al. (2014)	RapidEye	Alfafa, milho, algodão, arroz, trigo	Uzbequistão
Dong et al. (2016)	Landsat 8	Arroz	China, Japão, Coreia do Sul e do Norte
Dong e Xiao (2016)	PROBA-V	Arroz	+
Durgun et al. (2016)	PROBA-V	Milho, batata, beterraba, trigo, linho, cevada, soja, canola, açúcar, ervilha, girassol, canola	Bélgica, Brasil, Rússia, Ucrânia
Esch et al. (2014)	LISS-3, AWIFS	Milho, canola, cereais, raízes	Alemanha
Fan et al. (2015)	Landsat-8 OLI	Seringueiras	China (Xishuangbanna)
Farag et al. (2005)	?	Alfafa, trevo, milho, aveia, soja, feno	EUA (Kentucky)
Forkuor et al. (2014)	RapidEye, TerraSAR-X	Milho, algodão, arroz, sorgo, batata doce	Benin
Gallego et al. (2014)	MODIS, RapidEye, Landsat-5/TM, AWIFS, LISS-III	Trigo, cevada, milho, batata, canola, beterraba, girassol, soja	Ucrânia
Gerstmann et al. (2016)	RapidEye	Trigo, cevada	Alemanha
Grzegozewski et al. (2016)	MODIS, Landsat-8, LISS-III	Milho, soja	Brasil (Paraná)
Gumma et al. (2015)	Landsat-8, RISAT-1, MODIS	Arroz	Índia (Karnataka)
Haertel e Landgrebe (1999)	AVIRIS	Milho, soja	EUA (Indiana)
Hao et al. (2014)	Landsat-5 TM, HJ-1 CCD	Milho, algodão, tomate, videira, melancia, trigo	China (Xinjiang)
Hao et al. (2015)	MODIS	Alfafa, milho, sorgo, soja, trigo	EUA (Kansas)
Hartfield et al. (2013)	Landsat TM	Alfafa, algodão, milho, melão, citros, sorgo	EUA (Arizona)
Hu et al. (2016)	MODIS	Arroz, milho, soja, trigo	China (Heilongjiang)
Huang et al. (2014)	MODIS	Arroz, trigo, milho	China (Yunnan)
Inglada et al. (2015)	SPOT4, Landsat 8	Milho, trigo, cevada, girassol, soja, algodão, sorgo, ervilha	Argentina, Bélgica, Burkina Faso, China, França, Madagascar, Ucrânia, Marrocos, Paquistão, Rússia, África do Sul, EUA
Inglada et al. (2016)	Sentinel-1, Landsat 8	Milho, soja, trigo, cevada, alfafa, canola	França
Johnson (2008)	Landsat-5 TM, Resourcesat-1	Alfafa, milho, algodão, arroz, soja	EUA (Arkansas, Iowa, Illinois)

Johnson et al. (2014)	Landsat 8	Cana de açúcar	Nepal
Karakizi et al. (2016)	WorldView-2	Videira	Grécia
Karila et al. (2014)	SPOT, Landsat, ENVISAT	Arroz	Vietnã
Kastens et al. (2017)	ASAR	Soja, algodão	Brasil (Mato Grosso)
Kawakubo e Machado (2016)	MODIS		
Khan et al. (2016)	LISS III	Café	Brasil (Minas Gerais)
Kim e Yeom (2014)	Landsat 8 OLI, Landsat 7 ETM+	Trigo	Paquistão
King et al. (2017)	RapidEye	Arroz	Coreia do Sul
Kontgis et al. (2015)	MODIS Terra, Landsat MODIS, AVHRR	Soja	EUA, Argentina
Kussul et al. (2016)		Arroz	Vietnã
Kussul et al. (2017)	Landsat-8, Sentinel-1	Milho, trigo, canola, beterraba, soja, girassol	Ucrânia
Lebourgeois et al. (2017)	Landsat-8, Sentinel-1A	Milho, trigo, canola, beterraba, soja, girassol	Ucrânia
Li et al. (2014)	Sentinel-2	Milho, arroz, feijão, soja, mandioca, ervilha, aveia, batata, amendoim	Madagascar
Li et al. (2015)	MODIS, Landsat-5 TM	Milho, girassol, alfafa, soja, álamo	Hungria
Liu et al. (2014)	Landsat TM, MODIS	Milho, soja, trigo	EUA (Missouri)
Long et al. (2013)	Landsat TM and ETM+, MODIS	Milho, algodão, arroz, soja	EUA (Mississippi)
Löw e Duveiller (2014)	Landsat ETM+	Legumes	EUA (Montana)
Löw et al. (2013)	RapidEye	Alfafa, milho, algodão, melão, arroz, sorgo, trigo	Uzbequistão, Cazaquistão
Löw et al. (2015)	RapidEye	Alfafa, milho, algodão, melão, arroz, sorgo, trigo	Uzbequistão, Cazaquistão
Löw et al. (2015)	RapidEye	Alfafa, milho, algodão, melão, arroz, sorgo, trigo	Uzbequistão, Cazaquistão
Ma et al. (2016)	RapidEye	Alfafa, milho, algodão, melão, arroz, sorgo, trigo	Uzbequistão, Cazaquistão
Manjunath et al. (2015)	AVIRIS, ROSIS	Alfafa, milho, aveia, soja, trigo, feno	EUA (Indiana)
Massey et al. (2017)	SPOT VGT	Arroz	Sul e Sudeste da Ásia
Mathur e Foody (2008)	MODIS	Milho, soja, trigo, cevada, batata, alfafa, algodão, arroz	EUA
Mukashema et al. (2014)	IRS-1D (LISS-III)	Algodão, arroz	Índia (Punjab)
Navarro et al. (2016)	QuickBird	Café	Ruanda
Nidamanuri e Zbell (2011)	SPOT-5, Sentinel-1A	Milho, soja, feijão	Angola
Nooni et al. (2014)	HyMAP	Alfafa, cevada, canola, centeio, trigo	Alemanha (Nordeste)
Ozdarici-Ok et al. (2015)	Landsat ETM+	Palma de óleo	Gana
Peña et al. (2014)	Ikonos, QuickBird, Kompsat-2	Arroz, trigo, tomate, beterraba	Turquia
Peña e Brenning (2015)	ASTER	Alfafa, amêndoas, milho, arroz, nozes, açafraão, girassol, tomate, videira	EUA (Califórnia)
Peña-Barragán et al. (2011)		Nozes, videira, ameixa, amêndoa	Chile
Petitjean et al. (2012)	Landsat ETM+	Alfafa, amêndoas, milho, tomate, aveia, arroz, açafraão, girassol, videira, nozes	EUA (Califórnia)
Picoli et al. (2018)	ASTER	Cevada, milho, trigo, ervilha, canola, eucalipto, sorgo, girassol	França
	Formosat 2	Soja, milho, algodão	Brasil (Mato Grosso)
	MODIS		

Potgieter et al. (2013)	MODIS VI	milheto, girassol Trigo, cevada, grão-de-bico	Austrália (Queensland)
Qin et al. (2015)	Landsat 8, Landsat 7, MODIS PROBA-V	Arroz	China (Sanjiang)
Roumenina et al. (2015)		Milho, trigo, canola, girassol	Bulgária
Schmedtmann e Campagnolo (2015)	Landsat ETM+	Milho, arroz, trigo, videira, cevada, aveia, oliveiras	Portugal
Schultz et al. (2015)	RapidEye	Mandioca, amendoim, soja, cana de açúcar	Brasil (São Paulo)
Shao et al. (2016)	MODIS	Milho, soja	EUA (Meio-Oeste)
Shi e Huang (2015)	MODIS	Arroz	China (Delta do RioYangtze)
Siachalou et al. (2015)	RapidEye, Landsat ETM+	Alfafa, milho, algodão, arroz, trigo, beterraba	Grécia
Singha et al. (2016)	MODIS, HJ-1A/B	Arroz	Índia (Assam)
Skakun et al. (2016)	Landsat-8/OLI, Radarsat-2	Trigo, milho, soja, canola, beterraba, girassol, cevada	Ucrânia
Song et al. (2017)	Landsat 7 and 8, TIRS L1T	Soja	EUA
Souza et al. (2015)	MODIS	Milho, soja	Brasil (Paraná)
Stavrakoudis et al. (2011)	IKONOS	Alfafa, milho, trigo	Grécia
Su (2017)	Landsat 8 OLI	Arroz	China (Jiangsu)
Tarabalka et al. (2010)	ROSIS-03	Alfafa, milho, aveia, soja, trigo	EUA (Indiana)
Teluguntla et al. (2015)	MODIS	Arroz	Índia (Bacia do Rio Krishna)
Ulsby et al. (1982)	Landsat MSS	Milho, trigo (palha)	EUA (Kansas)
Vaudour et al. (2015)	Pléiades, SPOT4	Trigo, cevada, canola	França
Vieira et al. (2012)	Landsat TM and ETM+	Cana de açúcar	Brasil (São Paulo)
Villa et al. (2015)	Landsat 8 OLI, COSMO-SkyMed	Milho, arroz, trigo	Itália
Waldhoff et al. (2017)	ASTER, Landsat-5-8, IRS-P6, SPOT 6/7, RapidEye	Canola, cevada, trigo, centeio, batata, beterraba	Alemanha
Waldner et al. (2015)	Landsat-8, SPOT-4	Cevada, milho, canola, girassol, trigo	França
Wang et al. (2015)	HJ-1A/B	Arroz	China (Zhejiang)
Wang et al. (2017)	MODIS, Landsat TM	Milho, soja, trigo	EUA (Meio-Oeste)
Wu et al. (2015)	HJ CCD, GF-1 WFV, Landsat, MODIS	Milho, algodão, trigo	China (Xinjiang)
You et al. (2014)	SPOT 5	Arroz, algodão	China (Chizhou)
Zhang et al. (2015)	MODIS	Arroz	China (Nordeste)
Zhang et al. (2016)	PROBA-V	Milho, soja, trigo	China (Shandong, Heilongjiang)
Zhang et al. (2017)	MODIS	Arroz, milho, soja	Coreia do Norte
Zheng et al. (2015)	Landsat 5 TM and 7 ETM+	Milho, cevada, trigo, batata, algodão, sorgo, alfafa	EUA (Arizona)
Zhong et al. (2014)	Landsat TM and ETM+	Milho, soja	EUA (Kansas)
Zhong et al. (2016)	MODIS	Milho, soja	Brasil (Paraná)
Zhou et al. (2016)	MODIS LTS, Landsat 8 OLI	Arroz	China (Liaoning)
Zhu et al. (2017)	MODIS, Landsat	Alfafa, milho, trigo	EUA (Wisconsin)

