



7 Tecnologias desenvolvidas em Agricultura de Precisão

Célia Regina Grego
Eduardo Antonio Speranza
Gustavo Costa Rodrigues
Ariovaldo Luchiarini Júnior
Laurimar Gonçalves Vendrusculo
Cristina Aparecida Gonçalves Rodrigues
Ricardo Yassushi Inamasu
Carlos Manuel Pedro Vaz
Ladislau Marcelino Rabello
Lúcio André de Castro Jorge
Cornélio Alberto Zolin
Júlio Cezar Franchini dos Santos
Carlos Cesar Ronquim

1 Introdução

A Agricultura de Precisão (AP) é uma estratégia de gestão que considera a variabilidade temporal e espacial para melhorar a sustentabilidade da produção agrícola (International Society of Precision Agriculture, 2020). Por meio dela reúnem-se, processam-se e analisam-se dados temporais, individuais e espaciais, combinando-os com outras informações para apoiar as decisões de gerenciamento, de acordo com a variabilidade estimada para melhorar a eficiência no uso de recursos, a produtividade, a qualidade, a rentabilidade e a sustentabilidade da produção agropecuária.

Desenvolver metodologias em campos experimentais ou por inferência de funcionamento, em ambiente idealizado por quem não vivencia o campo, pode resultar em propostas muito difíceis de serem absorvidas pelo setor produtivo. Posto isso, vamos desenvolver o capítulo como os primeiros passos para a implementação da AP, focando nas tecnologias habilitadoras.

É importante entender que a lavoura não é uniforme e possui variabilidade. Há regiões em lavouras com trechos que inundam com facilidade e outros que apresentam uma boa drenagem. Lavouras que podem variar de solo argiloso para solo arenoso, ou de solo mais ácido para menos ácido, e assim por diante, definindo características diferenciadas que implicam na variação da produtividade na mesma lavoura. É de forma intuitiva que se compreende que, em áreas que produzem duas a quatro vezes mais, a necessidade de insumo é diferente, e que de alguma forma há uma aplicação excessiva de insumo em uma área, ou está se perdendo a produtividade por falta desse insumo em outra. Em ambas as situações, o produtor está perdendo um retorno econômico importante do seu negócio e, por que não dizer, um retorno ambiental.

Apesar da variabilidade da produtividade nas áreas, as máquinas convencionais são rígidas, ou seja, seus ajustes são mecânicos e não podem ser alterados durante uma operação de campo. No caso de máquinas para AP, como o ajuste é programável, a liberação de insumos pode ser ajustada de acordo com um mapa de recomendação. A sua atuação é flexível, com possibilidade de reagir aos valores obtidos por sensores em tempo real.

Assim, ao iniciar AP com máquinas que mapeavam a produtividade da lavoura e possibilitavam aplicar insumos de acordo com a coordenada geográfica, o ciclo aparentemente se fechava – ou seja, o ciclo fundamental de controle, que consiste de leitura, análise e atuação, como ilustrado na Figura 1.

Foi nesse ponto que a AP avançou, provavelmente superou o pico da “expectativa inflada” do hiperciclo de Gartner¹ e mergulhou no trecho da “desilusão”. Houve um número não reduzido de relatos de que as máquinas estavam sendo operadas no campo com os controles eletrônicos desativados. Houve



Figura 1. Ciclo de controle utilizado na Agricultura de Precisão – AP.

¹ Ciclo que representa maturidade, adoção e aplicação social de determinadas tecnologias.

e ainda há problemas operacionais. Os vários formatos proprietários que geram a falta de compatibilidade de sistemas digitais, tanto de comunicação entre equipamentos como para troca de arquivos e de dados, são problemas operacionais recorrentes. Mas talvez o de maior importância seja o fato de as metodologias utilizadas na etapa de análise, o “coração” do ciclo de controle, ainda estarem baseadas na agricultura convencional. As metodologias de análise convencional não levam em conta as variáveis que diferenciam regiões da lavoura. As metodologias apresentadas neste capítulo, como as criadas em sistema *onfarm* (procedimentos por experimentação conforme planejamento dentro da fazenda ou na fazenda), são uma tentativa de desenvolver e suprir a ausência dessas informações e metodologias.

2 Coleta, armazenamento e análise de dados em AP

Uma parte importante do ciclo de aplicação da AP é a obtenção de dados e mapas de atributos relevantes que influenciam na variabilidade espacial e temporal da produtividade das culturas. Os mapas de produtividade expressam variações naturais e antrópicas do solo, como a topografia, a textura, a fertilidade, a compactação, dentre outras; e das plantas, como respostas aos atributos do solo, do clima e do manejo das culturas.

Existem, comercialmente, muitos equipamentos, sensores, técnicas e abordagens que podem ser utilizados para o mapeamento das variabilidades das culturas em AP (Leroux; Tisseyre, 2019; Molin; Tavares, 2019). O número de camadas de informações irá depender do nível da variabilidade da área e do interesse do usuário. Entretanto, em geral, uma abordagem adequada deve incluir um mapeamento da variabilidade do solo, um outro das plantas e, ao final do ciclo, o mapa da colheita. Para a seleção das técnicas e dos instrumentos mais adequados, devem-se considerar o sistema de produção, a disponibilidade de instrumentação e a escala ou a dimensão dos talhões.

Para o mapeamento do solo, a medida da Condutividade Elétrica aparente (CEa) tem se mostrado uma ferramenta muito útil (Corwin; Plant, 2005), pois integra fatores físicos, como textura, densidade, compactação, retenção de água; químicos, CTC (Capacidade de Troca Catiônica) e matéria orgânica; e mineralógicos. Assim, pode identificar variabilidades globais do solo, que podem levar a regiões de maior (ou menor) produtividade dentro do talhão. Para o mapeamento das plantas, Índices de Vegetação (IV) obtidos por imagens de satélite, aeronaves remotamente pilotadas (ARP) e sensores ativos de dossel (Lee et al., 2010) possibilitam traçar o vigor da cultura, tanto espacialmente como temporalmente (ao longo do ciclo da cultura). Em geral, com os mapas desses três atributos (CEa, IV e produtividade) é possível se estabelecerem zonas de manejo que podem ser utilizadas para amostragens mais detalhadas

de atributos adicionais, como doenças e pragas e compactação do solo. Outras variáveis de grande importância em AP são os nutrientes das plantas (fertilidade) e a textura do solo, que podem ser obtidos em uma grade regular ou por zonas de manejo definidas a partir dos mapas de CEa, IV e produtividade.

Nesta seção, são apresentados procedimentos e instrumentos utilizados na coleta de dados em AP, bem como em seu armazenamento e análise.

2.1 Identificação da variabilidade espacial do solo

2.1.1 Amostragem de solo

A amostragem do solo é um procedimento essencial em AP, pois possibilita o conhecimento da fertilidade e das características que influenciam na produtividade. O procedimento em grade regular é o mais utilizado. Para tanto, o recomendado é que a densidade amostral seja de uma amostra por talhão em áreas extensivas de produção de grãos, por exemplo. Em áreas de fruticultura, onde são comuns talhões de alguns poucos hectares, a densidade amostral pode ser de algumas dezenas de amostras por hectare. Outro critério a ser considerado são os conhecimentos prévios e as análises visuais de variabilidades no talhão. Em talhões com grande variabilidade, observada visualmente e reconhecida ao longo dos anos pelo produtor, a densidade amostral deve ser maior do que naqueles com pouca variabilidade já verificada. A Figura 2A ilustra alguns exemplos reais de grades amostrais, onde as amostras foram coletadas para fins de fertilidade e textura do solo, ambas em sistema de





Figura 2. Exemplos de grades amostrais em AP, para a determinação de atributos de fertilidade e da textura do solo, em áreas de produção de soja-algodão em Mato Grosso (A), e os mapas de potássio no solo (B) dessas duas áreas.

produção soja-algodão, nos municípios de Pedra Preta-MT e Sapezal-MT. As áreas dos talhões são de 110ha e 200ha e os números de amostras coletadas foram de 70 e 135 amostras, respectivamente. Ou seja, ambas com cerca de 1 amostra a cada hectare e meio. Na Figura 2B observam-se os mapas de potássio dessas duas áreas, obtidos por interpolação espacial.

Outras questões importantes que devem ser consideradas na amostragem em AP estão relacionadas aos equipamentos utilizados para a coleta e a fase da cultura. Em sistemas intensivos de produção, onde são produzidas duas ou até três safras ao ano, os intervalos de tempo entre a colheita da primeira safra e o plantio da segunda safra são muito curtos. Para a utilização de quadriciclos equipados com amostradores de solo, o ideal é que a amostragem seja realizada após a colheita da primeira safra (verão) ou após a colheita da segunda safra (inverno), evitando danos às plantas pela circulação do quadriciclo na área. Caso seja necessária a coleta em um período em que a cultura esteja em uma fase bem desenvolvida no campo, deve-se utilizar a tradição manual. Nos dois casos, o georreferenciamento das amostras é sempre necessário. Para a coleta com o quadriciclo, recomenda-se a extração do solo em pelo menos 9 subamostras, em um círculo ao redor do ponto georreferenciado, na profundidade 0-20cm. Já para a amostragem com trado holandês, o número de subamostras ao redor do ponto pode ser reduzido para 5, uma vez que a quantidade de solo coletada por furo é maior.

Da mesma forma como ocorre para a coleta de amostras de solo, a medida da compactação do solo pode ser feita por penetrômetros acoplados em quadriciclos ou por dispositivos manuais. Os equipamentos acoplados em quadriciclos são recomendados para os períodos após a colheita da safra de verão, uma vez que na colheita da safra de inverno o solo estará com uma condição de umidade muito baixa, inadequada a esse tipo de determinação. A Figura 3 apresenta os mapas de resistência à penetração, medidos com penetrômetro manual e gerados a partir de interpolação espacial, em talhões com produção de algodão no município de Pedra Preta-MT (Figura 3A) e Sapezal-MT (Figura 3B).

Figura 3. Mapas de resistência à penetração na camada 10-40cm em área de plantio de algodão em Pedra Preta-MT (A) e Sapezal-MT (B).



Amostragens do solo e de raízes para a quantificação de fitonematoides devem ser realizadas também durante o ciclo da cultura, não sendo assim recomendado o uso de amostradores em quadriciclo, e sim a gradagem do solo e a coleta manual de raízes. A Figura 4 apresenta mapas de fitonematoides da espécie *Rotylenchulus reniformis* no solo e na raiz, obtidos por krigagem a partir de 70 amostras coletadas em uma área de produção de soja, em Pedra Preta-MT.




Figura 4. Mapas de nematoides (*Rotylenchulus reniformis*) no solo (A) e na raiz da soja (B).

2.1.2 Condutividade elétrica

A condutividade elétrica aparente do solo (CEa) é utilizada em escala de campo no mapeamento da variabilidade espacial de muitas propriedades edáficas, tais como textura, concentração de sais e umidade. É uma ferramenta mais rápida, confiável e fácil de utilizar em comparação com outras técnicas, e que frequentemente está correlacionada com o rendimento das culturas. Por isso, está entre as mais utilizadas em pesquisa na AP para a caracterização espaço-temporal das propriedades edáficas e antropogênicas que influenciam a produtividade da cultura. As medidas de CEa são obtidas normalmente a partir do método conhecido como sistema de quatro pontos (Smtis, 1958), que consiste em utilizar quatro eletrodos de metal alinhados sequencialmente com espaçamentos conhecidos (Figura 5).




Figura 5. Sistema quatro pontos para medida de CEa.

Fonte: Rabello et al. (2014).

Encontram-se no mercado alguns sistemas já desenvolvidos para a medida de CEa, tanto para o tradicional sistema de quatro pontos quanto para o sistema por indução magnética, ambos de fabricação estrangeira. A Embrapa também desenvolveu um sistema de medida de CEa baseado no sistema de quatro pontos.

A CEa fornece uma alta densidade de dados, possibilitando, de modo rápido, uma visão geral da área que permite dividi-la em regiões homogêneas, facilitando a sua interpretação e, conseqüentemente, as tomadas de decisão de gerenciamento.

2.2 Identificação da variabilidade espacial da cultura

2.2.1 Mapeamento da produtividade

Para analisar a variabilidade espacial da produtividade, em AP se utiliza o conjunto de valores da produção nas coordenadas geográficas, registrados e armazenados pela máquina durante a colheita. A integração do sistema é conceitualmente simples. Consiste de um sensor de massa, um receptor GNSS e um sistema de registro dos dados. O primeiro sistema surgiu em colhedora de grãos. Para a medição de massa, utiliza-se atualmente uma placa sensor de força (semelhante às balanças eletrônicas), localizada onde os grãos são lançados por elevadores. Quanto maior o fluxo dos grãos, maior o impacto na placa. Esses valores são acumulados na memória e, a cada coordenada enviada pelo receptor GNSS, os valores acumulados são integrados e registrados. Cada fabricante registra de uma forma, e não há um padrão. Entretanto, é possível afirmar que todos armazenam pelo menos a coordenada geográfica, o horário e o valor da massa. O sensor de força é como uma balança eletrônica e deve ser calibrado com certa frequência. Alguns modelos mais atuais de colhedora realizam autocalibração, mas é comum, a cada colheita, a repetição desse processo.

Como cada fabricante desenvolveu o seu processo, os aplicativos e os formatos de arquivos são próprios e proprietários. Há esforços na padronização, e espera-se que a incompatibilidade entre sistemas não seja mais um problema para o produtor. As dificuldades no campo não são poucas. Nas colheitas realizadas em frotas, comuns em regiões exportadoras como o Cerrado, caso uma ou mais máquinas não possuam a capacidade de mapeamento, inviabiliza-se a composição dos dados. Todo o processo em conjunto frustra a visualização da sua produção. Por isso, a colheita em AP requer atenção e, sobretudo, dedicação. No caso da colheita da primeira safra, essa operação guarda um estado de tensão causado pela espera do momento em que a umidade dos grãos chega ao ponto correto, pela possibilidade de a chuva interromper a operação (ocorre em meio à estação chuvosa) e pela necessidade de abrir a área para realizar o plantio da segunda safra.


Observando que, caso o plantio não ocorra no seu melhor momento, a cultura não expressará a máxima produtividade. Há outros fatores importantes para que se alcance uma produtividade diferenciada, mas é importante salientar que a janela de oportunidade é estreita e a gestão de tempo é diretamente relacionada à eficiência da lavoura. Portanto, é compreensível que uma operação de calibração de máquinas possa não ser prioridade entre a grande maioria dos produtores, principalmente em equipes reduzidas, eficientes e enxutas.

As primeiras culturas nas quais a medição da produtividade por máquinas ocorreu de forma comercial foram as de grãos como milho, soja e trigo. São máquinas de grande porte. Além da cultura de grãos, as culturas de café e de algodão também contam com colhedoras com capacidade para registrar a produtividade – observando que, para o caso do algodão, os sensores não são de impacto e são baseados em radares utilizando sinais de infravermelho e, mais recentemente, micro-ondas. Para a cultura de cana-de-açúcar, os sensores de produtividade em máquinas ainda não são sucessos comerciais, visto ser a medição, nessa cultura, algo bastante complexo e difícil de ser realizado automaticamente, por conta da dificuldade no desenvolvimento de sensores capazes de identificar com precisão o fluxo de biomassa. Nas demais culturas que não contam com máquinas colhedoras com sensor de produção, os mapas têm sido obtidos por meio de amostragem, de forma semelhante à amostragem de solo. É necessário um protocolo de colheita, com coordenada de cada amostra e sua pesagem, e há ainda de existir dependência espacial para viabilizar um processo de interpolação preciso. Alguns trabalhos acadêmicos podem ser encontrados, mas na cultura de cana-de-açúcar, ainda não estão disponíveis no mercado. Sensoriamento por meio de câmeras e reconstrução 3D podem ser considerados promissores (Santos et al., 2017).

Uma vez que se obtenham dados de colheita com máquinas, o pré-processamento é fundamental para correta interpretação. A Figura 6 ilustra, em sistema de informação geográfica, dados de produtividade reais de colheita de algodão coletados de uma máquina. Cada ponto ilustra a coordenada e o valor colhido, agrupados em quatro classes, que variam do vermelho (produção baixa) ao laranja, verde claro e verde mais intenso (produção máxima). As primeiras quatro Figuras, 6A, 6B, 6C e 6D, são provenientes de quatro arquivos diferentes, ou coletados de máquinas distintas ou realizados em horários distintos; a Figura 6E ilustra a composição dos quatro arquivos em um. A colheita é realizada intercalando linhas de plantio. Há interrupção durante o processo de colheita, podendo ocorrer também movimentação de manobras e deslocamento. Nesses casos, se o operador mantiver o sistema de registro ligado, há registro de produtividade zero, portanto é importante que esses pontos sejam excluídos.

Figura 6.

Ilustração de dados de colheita (A, B, C, D) e sua composição (E).



2.2.2 Sensoriamento proximal

Vários tipos de sensores vêm sendo desenvolvidos para auxiliar na aquisição de dados de monitoramento do solo e das plantas, permitindo gerar dados de forma eficiente e com menor custo, fornecendo estimativas confiáveis do desenvolvimento da cultura para melhorar a estimativa do potencial de produção. Para o monitoramento vegetativo das plantas, os índices vegetativos (IV) NDVI e NDRE (Red Edge com diferença normalizada) podem ser obtidos por sensores de reflectância, como o Crop Circle® (Holland Scientific, Lincoln, EUA).

A tecnologia LiDAR (do inglês *Light Detection and Ranging*) é uma metodologia de sensoriamento remoto proximal baseada em conceitos ópticos. O principal objetivo é identificar distâncias para um objeto-alvo, que são determinadas por diferenças de tempo entre a emissão de um pulso de laser ao objeto-alvo e a detecção do sinal refletido por esse objeto (Reutebuch et al., 2005). A partir de um sensor LiDAR, é possível reconstruir objetos em três dimensões de forma rápida e precisa, o que torna essa tecnologia factível de ser utilizada em diversas atividades agrícolas realizadas por implementos terrestres providos de automação. Em AP, sensores LiDAR podem ser embarcados em implementos pulverizadores, em conjunto com sensores de reflectância, para detecção da altura das plantas e aplicação on-line de reguladores de crescimento (Figura 7).

2.2.3 Sensoriamento suborbital e remoto

Sensores com disponibilização gratuita de imagens pela internet, resoluções espaciais entre 10 m e 30 m, e resoluções temporais entre 5 e 15 dias, como Sentinel-2/MSI e LandSat-8/OLI, podem dar suporte a diversas atividades dentro do contexto da AP, principalmente em talhões com áreas mais extensas. Na agricultura brasileira, essas áreas estão concentradas em regiões produtoras de cana-de-açúcar e grãos. Para essas regiões, o sensoriamento remoto possibilita a análise da variabilidade espacial dos talhões, a partir de índices de vegetação que podem ser obtidos por combinações das bandas no espectro do visível e do infravermelho.

Análises referentes à presença de biomassa podem ser realizadas a partir de mapas de IV obtidos a partir de combinações com bandas do espectro



Foto: Ricardo Yasushti Inamasu

Figura 7. Utilização de sensor LiDAR em conjunto com sensores de reflectância Crop Circle®, embarcados em implemento para detecção de altura de plantas.

infravermelho. Por meio desses índices, é possível estabelecer correlações com a disponibilidade de nitrogênio e outros nutrientes nas plantas, acompanhar a evolução do crescimento da cultura e realizar estimativas de produtividade em diferentes regiões dentro de um mesmo talhão (Candiago et al., 2015). A presença de água nas plantas também pode ser avaliada especialmente a partir de mapas de índices que combinam bandas do espectro visível com bandas do espectro infravermelho de ondas curtas, como o NDWI (*Normalized Difference Water Index*) (Zhang et al., 2019). Combinados com dados relacionados à variabilidade do solo e à produtividade da cultura, os IV podem se tornar importantes para estratégias de subdivisão da área para tratamentos especializados, como o delineamento de zonas de manejo (Figura 8) e a experimentação *onfarm*.




Figura 8. Mapas de área de cana-de-açúcar: composição de NDVI (A) e NDWI (B) de imagens de satélite Sentinel-2/MSI de fevereiro a maio de 2017; e mapa de zonas de manejo (ZM) (C) a partir de atributos do solo e da cultura entre 2012 e 2016.

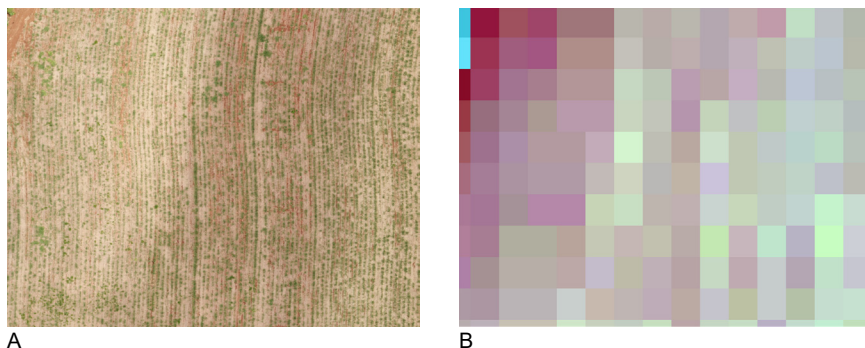
As imagens de sensoriamento remoto com resoluções espaciais abaixo de 10 m ainda não estão disponíveis gratuitamente. Entretanto, a necessidade de se obterem dados com maior precisão para atividades de AP, que permitam, por exemplo, identificar pragas e doenças e presença de plantas invasoras, e até mesmo estimar a produtividade, fez com que o uso de câmeras multi e

hiperespectrais a bordo de aeronaves remotamente pilotadas (ARP) fosse intensificado nos últimos anos (Jorge; Inamasu, 2014). O custo dessa tecnologia tem decaído ano a ano, o que faz com que, gradativamente, a sua adoção venha crescendo por parte dos produtores.

Além da redução dos custos, o uso de ARPs em AP também dá ao produtor a vantagem de planejar o momento da coleta dos dados, evitando assim problemas com dias chuvosos ou com alta incidência de nuvens que, por muitas vezes, acontecem com os dados coletados pelos satélites. Outro fator importante é a possibilidade de planejar a altura do voo a ser realizado, o que permite a obtenção de imagens com diferentes resoluções espaciais utilizando uma mesma câmera. Com isso, é possível identificar, por exemplo, falhas de plantio que imagens de sensoriamento remoto não conseguem captar (Figura 9). ARPs que incluem funções de atuação também permitem ao produtor realizar a aplicação de insumos e corretivos agrícolas de forma localizada, o que as torna uma alternativa interessante à automação convencional realizada por implementos agrícolas tradicionais (Mogili; Deepak, 2018). Entretanto, a operacionalização das ARPs ainda necessita ser realizada por profissionais especializados na maioria das aplicações. Outro ponto negativo é a autonomia e a capacidade de geração de imagens dos equipamentos. Uma única ARP tem a capacidade de gerar imagens que cobrem algumas centenas de hectares em um único dia, imagens estas que devem ser posteriormente processadas por computadores de alto desempenho para a geração de mosaicos.

Figura 9.

Exemplo de recorte de imagens, com cerca de 120 × 120 m de área, de um talhão de cana-de-açúcar, obtidas em outubro de 2019, utilizando: ARP com câmera embarcada, com resolução espacial de 2 cm/pixel (A); e satélite Sentinel-2/MSI, com resolução de 10 m/pixel e incidência de nuvens (B).



Acompanhando a evolução das ARPs e das câmeras multiespectrais, empresas privadas de tecnologia aeroespacial têm colocado em órbita satélites e, mais recentemente, constelações de nanosatélites, providos de sensores capazes de capturar imagens com resolução espacial abaixo de 1 m. O mercado atual permite a associação do produtor a diversas plataformas de acesso a essas imagens, já em forma de produtos prontos para o uso, normalmente a um custo elevado. Porém, diferentemente do que ocorrem com as ARPs, em

um dia é possível obter imagens que cobrem áreas extensas. Em resumo, tanto as imagens de satélite com resolução espacial submétrica quanto as imagens capturadas por ARPs ainda exigem investimentos por parte do produtor, que deve compor uma relação de custo e benefício que depende da aplicação. Nessa relação, questões como a época em que se deseja obter as imagens e a necessidade de resoluções espaciais devem ser levadas em consideração.

2.3 Armazenamento de dados em nuvem

A Rede de AP da Embrapa (Rede AP) tem realizado um trabalho de conscientização dos pesquisadores e dos parceiros no sentido de incentivar o compartilhamento dos dados finalísticos produzidos em suas pesquisas. Assim, a ferramenta GeoNode (<http://geonode.org>), software livre e de código aberto, foi avaliada e adaptada para absorver os requisitos específicos da comunidade, proporcionando o desenvolvimento de uma nova versão do repositório de dados da Rede AP (<http://www.redeap.cnptia.embrapa.br>). A catalogação de metadados é a principal funcionalidade do repositório, no sentido de garantir a integridade dos dados ao longo do tempo. A partir dos metadados é possível verificar, além dos dados de autoria, os equipamentos e metodologias utilizados, as condições ambientais e as dificuldades encontradas durante a coleta dos dados. Essas informações são subsídios importantes para futuras reutilizações e análises de um determinado conjunto de dados.

2.4 Análise de Dados em AP

2.4.1 Mineração de dados e extração de padrões

As técnicas computacionais para mineração de dados são de extrema importância para o processo de análise de dados. Essas técnicas têm como principal objetivo a descoberta de padrões em bancos de dados, a partir de ferramentas disponibilizadas pelas áreas de inteligência artificial, aprendizado de máquina e estatística (Majumdar et al., 2017). Nesse contexto, normalmente são considerados métodos de aprendizado não supervisionados (agrupamento) e supervisionados (classificação).

Em AP, observa-se uma crescente popularização de algoritmos derivados de métodos de agrupamento e classificação para a realização de diferentes análises a partir dos dados. Classificadores como as redes neurais artificiais e convolucionais são utilizados para a identificação semiautomática de diversos eventos que ocorrem na cultura, tais como falhas de plantio e surgimento de pragas e plantas invasoras, a partir de imagens (Tang et al., 2017). A produtividade de uma cultura também pode ser estimada a partir de regressores e dados multiespectrais da vegetação (Al-Gaadi et al., 2016). Já os métodos de agrupamento são utilizados essencialmente para a subdivisão de áreas de

cultivo em regiões com potencial produtivo similar, conhecidas como zonas de manejo (Luchiari Jr et al., 2000).

Independentemente do método utilizado, essa análise que trata da extração de padrões está inserida em um processo mais amplo, conhecido como descoberta de conhecimento em bancos de dados (KDD – do inglês Knowledge Discovery in Databases). Desse modo, etapas anteriores, como a filtragem, a limpeza e a normalização dos dados; e posteriores, como a validação estatística dos modelos aplicados, devem ser realizadas, respectivamente, antes e depois da utilização dos métodos de mineração de dados. Quanto mais completo for o processo de KDD utilizado na análise dos dados, maior a chance de se obterem resultados mais precisos e condizentes com a realidade.

2.4.2 Ferramentas de filtragem e limpeza de dados

Por meio das ferramentas de filtragem e limpeza de dados, amostras de dados obtidas em campo com erros de posicionamento ou valores discrepantes associados podem ser eliminadas do conjunto de dados a ser analisado, evitando-se, assim, erros de interpretação nas etapas posteriores. Em AP, a maior preocupação está com os dados de produtividade obtidos por colheadoras, devido à sua alta densidade amostral e à diversidade de fabricantes. Desse modo, algoritmos e softwares baseados em metodologias estatísticas e parâmetros de variabilidade informados pelo usuário podem ser usados nessa tarefa (Sudduth; Drummond, 2007; Vega et al., 2019). Além dos dados de produtividade, qualquer outro conjunto de dados oriundo de sensoriamento proximal sujeito a erros de coleta deve passar por essa etapa de limpeza e filtragem antes de ser utilizado na etapa de mineração de dados.

2.4.3 Geoestatística e interpolação espacial

A análise geoestatística aplicada a AP é fundamental para garantir melhor precisão no mapeamento de dados interpolados no espaço. Segundo Vieira (2000), a geoestatística é uma ferramenta que permite analisar o grau de dependência espacial de dados que variam no espaço, seja em milhares de hectares, seja em um pequeno talhão, como numa parcela experimental de 30x30m, conforme demonstrado em Grego e Vieira (2005).

A geoestatística parte do princípio de que quanto maior o número de amostras, melhor representatividade da real variabilidade espacial será expressa pela ferramenta. Contudo, sabe-se que, na prática, é necessário atender as necessidades do usuário, considerando principalmente o recurso disponível, a mão de obra e o tempo operacional para amostragem. Para auxiliar essa etapa, é possível recorrer às informações históricas da área e a dados obtidos por sensores e imagens de satélite, otimizando, dessa forma, a quantidade de amostras.

De posse dos dados georreferenciados, é feita uma investigação quanto à existência ou não da dependência espacial, e, em caso positivo, é possível realizar a interpolação de dados por krigagem, que garante variância mínima e não tendenciosidade nos valores interpolados. O resultado baseia-se nos mapas precisos em que são observadas as manchas de variabilidade espacial, que podem ser correlacionadas formando uma plataforma de informação espacial durante os ciclos da cultura. Esse mapeamento, conforme detalhado em Bernardi et al. (2014), auxilia na identificação de zonas de manejo diferenciadas para aplicação localizada de insumos.

2.4.4 Delineamento de zonas de manejo

No âmbito da AP, atividades como plantio, intervenções com aplicação de insumos e irrigação podem ser geridas de maneira uniforme, a partir da delimitação de subáreas conhecidas como zonas de manejo (ZM). Uma ZM pode ser definida como uma porção de terreno estável no tempo, onde o potencial de produção, a eficiência do uso de insumos e o risco de impacto ambiental são essencialmente uniformes (Doerge, 1999; Luchiari Jr. et al., 2000). Para que sejam obtidas ZMs com essas características, o principal pré-requisito é a utilização de atributos não antrópicos, relacionados à gênese do solo e da cultura (Molin et al., 2015). Desse modo, fatores como o relevo, a condutividade elétrica, a textura e os atributos físicos do solo, os índices de biomassa e a produtividade histórica devem ser utilizados para dar suporte ao delineamento de ZMs (Kitchen et al., 2005; Li et al., 2007; Scudiero et al., 2013).

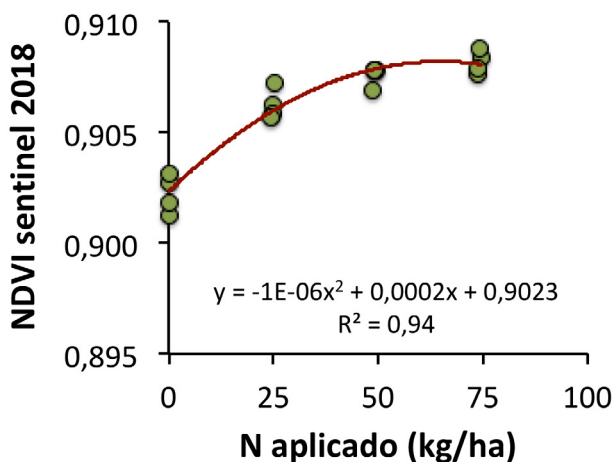
Atualmente, é possível gerar mapas de ZM combinando inúmeros conjuntos de dados e algoritmos de aprendizado de máquina, proporcionando uma maior precisão e assertividade para o produtor. Devido à atual alta disponibilidade de dados, ainda é incipiente, porém necessária, a adaptação desses algoritmos para que possam lidar com conjuntos de dados massivos, de forma que possam aproveitar ao máximo a capacidade computacional de processamento disponível no ambiente em que são executados.

2.4.5 Experimentação *onfarm*, correlação espacial e recomendações

A experimentação *onfarm* consiste na definição de parcelas virtuais, dentro de uma área de cultivo experimental, para que sejam avaliadas diferentes taxas de aplicação, com repetições, em intervenções como plantio (população), adubação nitrogenada de cobertura e reguladores de crescimento. Os procedimentos por parcelas devem ser realizados conforme planejamento do produtor e com os implementos agrícolas disponíveis – daí a utilização do termo *onfarm* (ou na fazenda) (Shiratsuchi et al., 2014). Os experimentos devem ser realizados por algumas safras para que, ao final, seja possível estabelecer recomendações de doses de população e insumos espacialmente diferenciadas e adequadas

para a área estudada, considerando a produtividade da cultura como resposta. As recomendações de intervenções podem ser obtidas a partir da utilização de ferramentas de análises de correlação espacial. Em AP, o coeficiente de determinação (Nagelkerke, 1991) é um resultado do modelo de regressão linear que permite identificar a correlação e a tendência dos valores (Figura 10).

Figura 10. Exemplo de coeficiente de correlação R^2 , obtido a partir de médias de valores de NDVI e nitrogênio (N), aplicado em parcelas de experimentação *onfarm*.



As medidas de correlação entre atributos são subsídios importantes para o estabelecimento de recomendações para áreas com características específicas em AP. Em áreas homogêneas com relação ao solo e livre de pragas, por exemplo, é possível inferir taxas de nitrogênio adequadas que devem ser aplicadas até que se atinja um limiar de produtividade máxima para a cultura naquelas condições.

3 Aplicações práticas em Agricultura de Precisão

3.1 Caracterização da variabilidade espacial dos sistemas de produção de cafés especiais do sul de Minas Gerais

Com o objetivo de avaliar espacialmente as áreas representativas de produção de café arábica (*Coffea arabica*), classificados como especiais do sul de Minas Gerais, Rodrigues et al. (2019a) utilizaram os índices vegetativos e de clorofila para identificar a existência de variabilidade espacial para aplicação da Cafeicultura de Precisão. No período pós-floração, em 2017, foram coletados dados relacionados a biomassa, clorofila e altitude das plantas, em duas fazendas do Sul de Minas Gerais. Foi observada a ocorrência de variabilidade

espacial e, na Fazenda Santa Cruz, foi observada uma relação inversa entre altitude e NDVI, sendo que os maiores valores de NDVI foram encontrados nas áreas mais baixas do campo. Tais fatos indicam que técnicas de manejo devem ser realizadas em função dessa variabilidade. Na Fazenda Morro Alto, a face de exposição ao sol da direita apresentou maior uniformidade (Figura 11).




Figura 11. Mapas de valores interpolados por krigagem ordinária para os dados de NDVI das fazendas de café Santa Cruz (A) e Morro Alto (B).
Fonte: Rodrigues et al.(2019b)

Com o intuito de definir quais das variáveis estudadas por Rodrigues et al. (2019a) foram capazes de auxiliar no delineamento de ZM, permitindo diferenciar a qualidade do café produzido, Speranza et al. (2019a) correlacionaram mapas de potenciais ZM com os mapas compostos pelas faces de exposição ao sol em cada área. Houve alta correlação das faces de exposição ao sol com o índice IRC e um melhor desempenho geral do índice NDRE com relação ao NDVI para esse contexto. Essa diferença pode ser explicada pelo fato de os dados terem sido coletados no início do período reprodutivo, logo após a floração, quando existia uma mistura de folhas completamente expandidas e outras com crescimento vegetativo inicial. Tanto Rodrigues et al. (2019b) quanto Speranza et al. (2019a) ressaltam que as respostas espaciais do café em relação aos índices de vegetação e de clorofila serão complementadas em análises futuras previstas, considerando as diferentes fases fenológicas do cafeeiro. Mapas de produtividade e qualidade de bebida também serão gerados e correlacionados com as variáveis biofísicas e microclimáticas.

3.2 Comportamento espacial e espectral em cana-de-açúcar correlacionado com a condutividade elétrica do solo

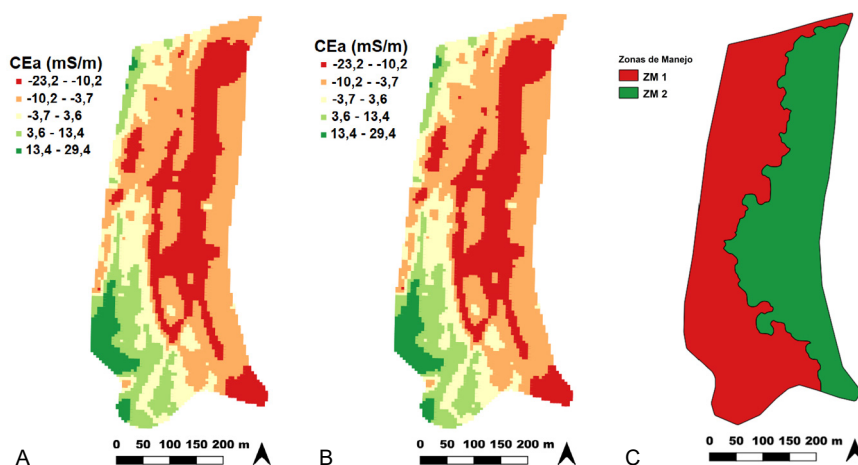
Os índices de vegetação (IV), obtidos a partir de imagens de satélites, são ferramentas poderosas que há anos vêm monitorando e contribuindo com

informações quase em tempo real sobre as culturas agrícolas, especialmente a cana-de-açúcar. A CEa do solo apresenta similaridade do comportamento espacial com os IVs obtidos tanto por sensoriamento remoto (Rodrigues et al., 2019a) como por sensoriamento proximal e suborbital (Speranza et al., 2019b), e também com a produção da cana-de-açúcar (Sanches et al., 2019). Nesse contexto, a Rede de Agricultura de Precisão da Embrapa, por meio de uma parceria com a Usina Santa Cruz, pertencente ao grupo São Martinho, desenvolve experimentação *onfarm* em talhão de cana de 15,7 hectares (Grego et al., 2019; Rodrigues et al., 2019a). Por meio da geoestatística e de algoritmos de aprendizado de máquina, identificaram-se duas zonas de manejo (ZM) simplificadas para a área, que refletem a textura do solo: ZM 1 – área mais argilosa (55% da área), na parte mais baixa, do lado oeste do talhão, porém com variabilidade maior com relação à CEa; e ZM 2 – área mais arenosa (45%), na parte mais alta, do lado leste do talhão e com variabilidade menor com relação à CEa (Figura 12). A diferença entre ZM 1 e ZM 2 para TCH foi de aproximadamente 16 t/ha.

Figura 12.

Condutividade Elétrica aparente (CEa) em dois espaçamentos de bobina: 0,5m (A), e 1m (B); zonas de manejo delineadas (ZM 1 e ZM 2) (C).

Fonte: adaptado de Speranza et al. (2019b)



O delineamento de ZM para essa área (Figura 12C) permitiu programar amostragens de solo mais adensadas na ZM 1, com maior variabilidade no solo; e menos adensada na ZM 2, com menor variabilidade no solo, subsidiando a definição da experimentação *onfarm*. A medição da CEa do solo otimiza indiretamente a amostragem espacial de áreas de cultivo, promovendo a economia de quantidade de coletas e custos para a análise do solo.

Para correlacionar as CEas aos IVs de imagens de sensoriamento remoto, foram coletadas 18 imagens da área de estudo, entre março de 2018 (mês do plantio) e julho de 2019, do sensor MSI/Sentinel-2A e 2B. Os resultados indicaram correlação significativa entre a CEa do solo (0,5 m e 1,0 m) e os IVs para a maioria das datas avaliadas. A correlação entre as variáveis IVs e

CEa foi positiva de março até setembro de 2018, ou seja, os IVs tenderam a mover-se na mesma direção relativa (mas não necessariamente a uma taxa constante) até aproximadamente 223 dias após o plantio. A partir desse período até a data final da colheita da cana, a correlação foi negativa (Figura 13). Houve similaridade de comportamento espacial e de valores de correlação com os índices de vegetação e CEa do solo. Portanto, a CEa do solo pode ser um indicador para manejos diferenciados na mesma safra da lavoura de cana.




Figura 13. Boxplot de valores de NDVI e NDRE2 em 18 datas de observação dos IVs na lavoura de cana-de-açúcar em Ibaté (SP).

Fonte: Rodrigues et al. (2019a).


3.3 Tecnologias de AP em sistemas de manejo de fibras e grãos no estado de Mato Grosso

As regiões cotonicultoras oeste e sudeste do Mato Grosso são aquelas que mais utilizam percentualmente os instrumentos: barra de luz, piloto automático e controle de seção (pulverizadores e semeadores). Os implementos mais utilizados são o piloto automático (61%) e o controle de seção de pulverizadores (58%). O percentual médio de adoção de técnicas instrumentalizadas de AP nesse estado é de 42%, sendo a região oeste a de maior taxa (54%). A região oeste também está acima da média no uso de outros instrumentos para gerenciamento sob a abordagem da AP. Nela, 51% utilizam mapas de fertilidade, 22% mapas de colheita, 27% mapas de pragas doenças e plantas invasoras, 49% aplicação a taxa variável e 49% aplicações por zonas de manejo.

Devido à grande quantidade de equipamentos, existe uma preocupação urgente em capacitar continuamente a mão de obra atuando no campo em atividades de regulagem, manutenção preventiva e corretiva, tecnologia das máquinas e operações agrícolas. Após o treinamento, a região meio-norte do estado foi aquela que obteve maior aumento de eficiência percentualmente (81%), comparada com a taxa média de 71% de todo o estado. O estudo aponta que a maioria das propriedades no MT utiliza alguma das técnicas de AP, todavia a falta de mão de obra qualificada não só para operações de campo, mas para análise dos dados constitui uma limitação para a manutenção ou o crescimento dessa abordagem de gerenciamento no MT. Outro ponto importante

refere-se à coleta e ao armazenamento das análises físico-químicas do solo, de forma sistemática, associados à produtividade de talhões como forma de buscar efetividade no manejo do solo. Na Figura 14, a alta correlação de CTC e matéria orgânica, nas duas profundidades, reflete a importância da aplicação dos fertilizantes para evitar mudanças bruscas de pH, que por vezes exigem maiores aplicações de dose de calcário (Ronquim, 2010).

Figura 14. Matriz de correlação de variáveis do solo a profundidade de 0-10 cm (A) e 10-20 cm (B) em propriedade localizada no norte do Mato Grosso.



Como forma de otimizar o controle químico utilizado para identificação de plantas daninhas tem-se o uso de imagens processadas de ARPs, as quais permitem o uso específico nas porções com infestação das plantas invasoras (Figura 15). A utilização de mapas de aplicação de herbicidas reduz sensivelmente o número de ações, impactando diretamente na redução do custo de produção da cultura.

Apesar de contarem com máquinas de alto desempenho, providas de piloto automático, a gestão da variabilidade para as culturas de grãos e fibras não é comum. As áreas planas apresentam uma variabilidade espacial que não incentiva os produtores a aplicar a Agricultura de Precisão. Outro fator que desencoraja os produtores relaciona-se às versões e aos modelos de máquinas. Nessa região, são intercalados dois plantios ao ano. No caso do algodão, a cultura com a qual se realiza rotação é a soja. Cada talhão possui uma dimensão média de 200 hectares. A colheita da soja é realizada com uma frota de máquinas, entre as quais nem todas possuem monitor de colheita. Assim, mapas ficam incompletos. Não é o caso do algodão, em que, devido ao bom retorno econômico, há a possibilidade de encontrar modelos similares durante a colheita, permitindo a obtenção de mapas completos.

A Rede de Agricultura de Precisão da Embrapa iniciou, em 2018, uma parceria com o Instituto Matogrossense do Algodão (IMAm) para pesquisas em quatro talhões experimentais de grandes produtores dos municípios de Sapezal e Rondonópolis, no estado de MT. As safras de algodão de 2018 e 2019 foram monitoradas a partir da obtenção de mapas de CEa, textura e fertilidade do solo; mapas de IV a partir de sensoriamento remoto e suborbital; mapas de




Figura 15. Imagem de ARP processada para identificação e geolocalização de milho voluntário e capim amargoso em propriedade localizada no norte do Mato Grosso.

distribuição de fitonematoides; e mapas de produtividade. Atualmente, três dos quatro talhões estudados adotaram o processo de experimentação *onfarm*, em que já é possível visualizar a resposta da cultura com relação à aplicação de diferentes doses de adubação nitrogenada nas parcelas virtuais (Figura 16).

Os dados coletados são corrigidos, filtrados e disponibilizados em nuvem para acesso e análise por parte das equipes de trabalho da Embrapa e do IMAmt e dos produtores. Apesar das recomendações serem aplicadas em talhões experimentais específicos, estas podem ser estendidas para talhões

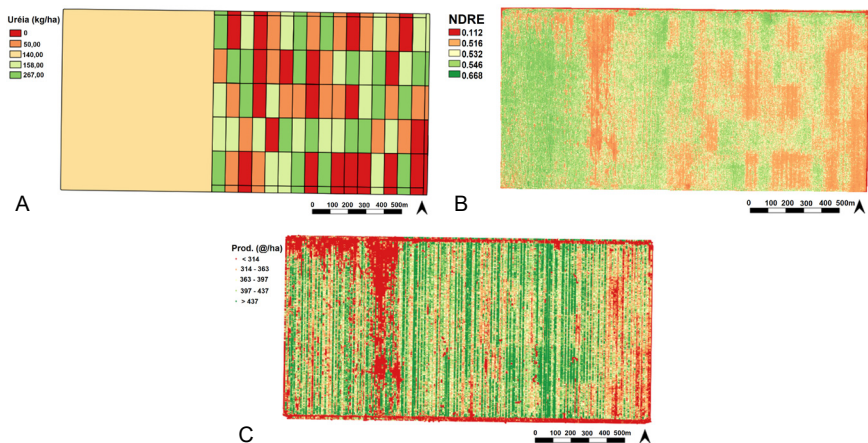



Figura 16. Experimentação *onfarm* realizada em talhão de cultivo de algodão em MT: (A) mapa de aplicação de adubação nitrogenada (Ureia) realizada em março de 2019; (B) índice de vegetação (NDRE) em maio de 2019; (C) produtividade em setembro/2019.

com características similares, potencializando a adoção da AP por parte dos produtores da região.

3.4 Aplicações de ARPs em diferentes culturas


As aplicações de ARPs na agricultura têm aumentado muito com o avanço da tecnologia e de sensores disponíveis, destacando-se a estimativa da biomassa e da produtividade, a avaliação nutricional, a detecção de pragas e doenças, a avaliação da necessidade hídrica das plantas e o mapeamento do solo com sensores RGB, multiespectral, hiperespectral, LIDAR, Thermal, dentre outros (Hatfield et al., 2008; d'Oliveira et al., 2020). Avaliando-se valores de refletância em certas regiões do espectro eletromagnético, é possível observar diferenças entre plantas e o solo e entre a vegetação verde saudável e com deficiência nutricional e hídrica ou atacada por pragas e doenças (Jorge; Inamasu, 2014). Dentre as aplicações com mais destaque tem-se o monitoramento do vigor das plantas com os índices de vegetação, os estudos para adubação nitrogenada utilizando sensores embarcados em ARPs, o uso de imagens aéreas multiespectrais para avaliação da variabilidade espacial do solo e da biomassa e as estimativas da produtividade de algodão, soja e milho. Também com os dados obtidos por ARP embarcado com sensores por imagens e LiDAR, destacam-se estudos para contagem de plantas. Na Figura 17, pode-se observar uma área de citros com contagem automática por técnicas de *deep learning*, descritas por Osco et al. (2020a). Na Figura 18 pode-se observar a determinação de altura de plantas de algodão por LIDAR embarcado em ARP, visando desenvolver metodologia de aplicação de regulador de crescimento.

Figura 17. Parcela de um talhão de citros adensado com identificação de plantas (A) e linhas (B, C) por técnicas de *deep learning*.





A




B


Figura 18. (A) Imagem de ARP e (B) Nuvem de pontos de LIDAR.

Fonte: adaptado de Sun et al. (2018).

Os sensores embarcados em ARP têm evoluído muito e possibilitado estudar a assinatura espectral da cultura a partir de hiperespectros, como na Figura 19A, e avaliar a presença de pragas na lavoura logo no início da infestação (Osco et al., 2020b). Na Figura 19B, pode-se observar o resultado da análise hiperespectral quando da ocorrência de lagartas das vagens (*Spodoptera eridania*) logo nas primeiras horas.



A



B

Figura 19. hiperespectro obtido pixel a pixel em imagens hiperespectrais em ARP (A) e análise hiperespectral quando da ocorrência de lagartas das vagens (*Spodoptera eridania*) logo nas primeiras horas (B).

4 Considerações finais

De maneira consolidada, quando se trata de AP, é importante entender que a lavoura não é uniforme e, portanto, a variabilidade espacial deve ser considerada para que o produtor tenha retorno econômico e ambiental em sua propriedade.

A AP avançou e superou expectativas principalmente no uso de máquinas operadas no campo. Contudo, ainda há problemas operacionais devido à falta de compatibilidade de sistemas digitais, tanto de comunicação entre equipamentos como para troca de arquivos e de dados, tornando-se um desafio operacional atualmente.

Uma parte importante do ciclo de aplicação da AP é a etapa de obtenção, armazenamento e análise de dados e mapas de atributos relevantes que influenciam na variabilidade espacial e temporal da produtividade das culturas.

Os mapas de produtividade expressam variações naturais e antrópicas do solo. Vários tipos de sensores terrestres, orbitais e suborbitais vêm sendo utilizados para auxiliar na aquisição de dados de monitoramento do solo e das plantas, permitindo gerar dados de forma eficiente e com menor custo, fornecendo estimativas confiáveis do desenvolvimento da cultura para melhorar a estimativa do potencial de produção.

Todos esses avanços em AP, apresentados neste capítulo, levam à agricultura atual inovações voltadas ao gerenciamento espacial e detalhado do sistema de produção agrícola, na busca de potencializar o retorno econômico e reduzir o impacto ambiental.

As metodologias e os resultados apresentados neste trabalho foram desenvolvidos com a colaboração de várias Unidades de Pesquisa da Embrapa e da gestão e de equipes técnicas de diversos parceiros como os grupos Gatto, 3D Engenharia, Amaggi, Scheffer, Sementes Petrovina, Usina de cana Santa Cruz, Fazendas de café Santa Cruz e Fazenda Morro Alto. Além disso, ressaltamos o apoio técnico nos trabalhos de campo do Instituto Matogrossense do Algodão (IMAmt) e do engenheiro agrônomo Guy Carvalho.

5 Referências

- AL-GAADI, K. A.; HASSABALLA, A. A.; TOLA, E.; KAYAD, A. G.; MADUGUNDU; BANDER ALBLEWI, R.; ASSIRI, F. Prediction of potato crop yield using precision agriculture techniques. **PLoS One**, v. 11, n. 9, 2016. DOI: [10.1371/journal.pone.0162219](https://doi.org/10.1371/journal.pone.0162219).
- BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. 596 p.
- CANDIAGO, S.; REMONDINO, F.; DE GIGLIO, M.; DUBBINI, M.; GATTELLI, M. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. **Remote sensing**, v. 7, n. 4, p. 4026-4047, 2015. DOI: [10.3390/rs70404026](https://doi.org/10.3390/rs70404026).
- CORWIN, D. L.; PLANT, R. E. Applications of apparent soil electrical conductivity in precision agriculture. **Computers and Electronics in Agriculture**, v. 46, n. 1-3, p. 1-10, 2005. DOI: [10.1016/j.compag.2004.10.004](https://doi.org/10.1016/j.compag.2004.10.004).
- D'OLIVEIRA, M. V. N.; BROADBENT, E. N.; OLIVEIRA, L. C.; ALMEIDA, D. R. A.; PAPA, D. A.; FERREIRA, M. E.; ZAMBRANO, A. M. A.; SILVA, C. A.; AVINO, F. S.; PRATA, G. A.; MELLO, R. A.; FIGUEIREDO, E. O.; JORGE, L. A. C.; JUNIOR, L.; ALBUQUERQUE, R. W.; BRANCALION, P. H. S.; WILKINSON, B.; OLIVEIRA-DA-COSTA, M. Aboveground biomass estimation in Amazonian tropical forests: a comparison of Aircraft- and GatorEye UAV-borne LiDAR Data in the Chico Mendes Extractive Reserve in Acre, Brazil. **Remote Sensing**, v. 12, n. 1, May 2020. DOI: [10.3390/rs12111754](https://doi.org/10.3390/rs12111754).
- DOERGE, T. Defining management zones for precision farming. **Crop Insights**, v. 8, n. 21, p. 1-5, 1999.
- FALKER. **SoloDrill amostrador de solo hidráulico**. Disponível em: <https://falker.com.br>. Acesso em: 3 set. 2020.
- GREGO, C. R.; SPERANZA, E. A.; RODRIGUES, C. A. G.; NOGUEIRA, S. F.; BAYMA, G.; CIFERRI, R. R.; LUCHIARI JR., A. Definição de zonas de manejo em cana-de-açúcar usando séries temporais

de NDVI derivados do satélite Sentinel-2A. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. 3 p.

GREGO, C. R.; VIEIRA, S. R. Variabilidade espacial de propriedades físicas do solo em uma parcela experimental. **Revista Brasileira de Ciência do Solo**, v. 29, n. 2, p. 169-177, maio/abr. 2005. DOI: [10.1590/S0100-06832005000200002](https://doi.org/10.1590/S0100-06832005000200002).

HATFIELD, J. L.; GITELSON, A. A.; SCHEPERS, J. S.; WALTHALL, C. L. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, v. 100, n. S3, S117-S131, 2008. DOI: [10.2134/agronj2006.0370c](https://doi.org/10.2134/agronj2006.0370c).

INTERNATIONAL SOCIETY OF PRECISION AGRICULTURE. Disponível em: <https://ispag.org>. Acesso em: 11 jun. 2020.

JORGE, L. A. de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 109-134.

KITCHEN, N. R.; SUDDUTH, K. A.; MYER, D. B.; DRUMMOND, S. T.; HONG, S. Y. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. **Computers and Electronics in Agriculture**, v. 46, n. 1-3, p. 285-308, 2005. DOI: [10.1016/j.compag.2004.11.012](https://doi.org/10.1016/j.compag.2004.11.012).

LEE, W. S.; ALCHANATIS, V.; YANG, C.; HIRAFUJI, M.; MOSHOU, M.; LI, C. Sensing technologies for precision specialty crop production. **Computers and Electronics in Agriculture**, v. 74, n. 1, p. 2-33, 2010. DOI: [10.1016/j.compag.2010.08.005](https://doi.org/10.1016/j.compag.2010.08.005).

LEROUX, C.; TISSEYRE, B. How to measure and report within-field variability: a review of common indicators and their sensitivity. **Precision Agriculture**, v. 20, p. 562-590, 2019. DOI: [10.1007/s11119-018-9598-x](https://doi.org/10.1007/s11119-018-9598-x).

LI, Y.; SHI, Z.; LI, F.; LI, H.Y. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, v. 56, n. 2, p. 174-186, 2007. DOI: [10.1016/j.compag.2007.01.013](https://doi.org/10.1016/j.compag.2007.01.013).

LUCHIARI JR., A.; SHANAHAN, J.; FRANCIS, D.; SCHLEMMER, M.; SCHEPERS, J.; LIEBIG, M.; SCHEPERS, A.; PAYTON, S. Strategies for establishing management zones for site specific nutrient management. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 5., 2000, Bloomington. **Proceedings**. Bloomington: American Society of Agronomy, 2000. p. 1-10.

MAJUMDAR, J.; NARASEEYAPPA, S.; ANKALAKI, S. Analysis of agriculture data using data mining techniques: application of big data. **Journal of Big Data**, v. 4, n. 1, article number 20, 2017. DOI: [10.1186/s40537-017-0077-4](https://doi.org/10.1186/s40537-017-0077-4).

MOGILI, U. R.; DEEPAK, B. B. V. L. Review on application of drone systems in precision agriculture. **Procedia Computer Science**, v. 133, p. 502-509, 2018. DOI: [10.1016/j.procs.2018.07.063](https://doi.org/10.1016/j.procs.2018.07.063).

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015. 224 p.

MOLIN, J. P.; TAVARES, T. R. Sensor systems for mapping soil fertility attributes: challenges, advances, and perspectives in Brazilian tropical soils. **Engenharia Agrícola**, v. 39, p. 126-147, set. 2019. Número especial. DOI: [10.1590/1809-4430-eng.agric.v39nep126-147/2019](https://doi.org/10.1590/1809-4430-eng.agric.v39nep126-147/2019).

NAGELKERKE, N. J. D. A note on a general definition of the coefficient of determination. **Biometrika**, v. 78, n. 3, p. 691-692, Sept 1991. DOI: [10.1093/biomet/78.3.691](https://doi.org/10.1093/biomet/78.3.691).

NO-TILL FARMER. **Sensor EM38**. Disponível em: <https://www.no-tillfarmer>. Acesso em: 3 set. 2020.

OSCO, L. P.; ARRUDA, M. dos S. de; MARCATO JUNIOR, J.; SILVA, N. B. da; RAMOS, A. P. M.; MORYIA, É. A. S.; IMAI, N. N.; PEREIRA, D. R.; CRESTE, J. E.; MATSUBARA, E. T.; LI, J.; GONÇALVES, W. N. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 160, p. 97-106, Feb 2020a. DOI: [10.1016/j.isprs.2019.12.010](https://doi.org/10.1016/j.isprs.2019.12.010).

OSCO, L. P.; RAMOS, A. P. M.; PINHEIRO, M. M. F.; MORYIA, É. A. S.; IMAI, N. N.; ESTRABIS, N.; IANCZYK, F.; ARAUJO, F. F. de; LIESENBERG, V.; JORGE, L. A. de C.; LI, J.; MA, L.; GONÇALVES, W. N.; MARCATO JUNIOR, J.; CRESTE, J. E. A machine learning framework to predict nutrient content in Valencia-orange leaf hyperspectral measurements. **Remote Sensing**, v. 12, n. 6, p. 906, 2020b. DOI: [10.3390/rs12060906](https://doi.org/10.3390/rs12060906).

RABELLO, L. M.; BERNARDI, A. C. de C.; INAMASU, R. Y. Condutividade elétrica aparente do solo. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 48-57.

REUTEBUCH, S. E.; ANDERSEN, H.-E.; McGAUGHEY, R. J. Light detection and ranging (LIDAR): an emerging tool for multiple resource inventory. **Journal of Forestry**, v. 103, n. 6, p. 286-292, 2005.

RODRIGUES, C. A. G.; GREGO, C. R.; SANCHES, G. M.; SPERANZA, E. A.; RONQUIM, C. C.; SILVEIRA, H. L. F.; LUCHIARI JUNIOR, A. Índices de vegetação (Sentinel-2) da cana-de-açúcar relacionados com a condutividade elétrica aparente de solo. In: SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA, 4., 2019, São Carlos, SP. **Ciência, inovação e mercado: anais**. São Carlos: Embrapa Instrumentação, 2019a. p. 151-155.

RODRIGUES, G. C.; GREGO, C. R.; LUCHIARI, A.; SPERANZA, E. A. Caracterização espacial de índices de vegetação índice relativo de clorofila em áreas de produção cafés especiais no sul de Minas Gerais. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 10., 2019, Vitória, ES. **Pesquisa, inovação e sustentabilidade dos cafés do Brasil**. Brasília, DF: Embrapa Café, 2019b. 6 p.

RONQUIM, C. C. **Conceitos de fertilidade do solo e manejo adequado para as regiões tropicais**. Campinas: Embrapa Monitoramento por Satélite, 2010. 26 p. (Embrapa Monitoramento por Satélite. Boletim de pesquisa e desenvolvimento, 8).

SACI SOLUÇÕES. **SACI TRAIL**: amostrador de solo da Saci Soluções. Disponível em: <https://www.sacisolucoes.com.br>. Acesso em: 3 set 2020.

SANCHES, G. M.; PAULA, M. T. N. de; MAGALHÃES, P. S. G.; DUFT, D. G.; VITTI, A. C.; KOLLN, O. T.; BORGES, B. M. M. N.; FRANCO, H. C. J. Precision production environments for sugarcane fields. **Scientia Agricola**, v. 76, n. 1, p. 10-17, Jan/Feb 2019. DOI: [10.1590/1678-992x-2017-0128](https://doi.org/10.1590/1678-992x-2017-0128).

SANTOS, T. T.; BASSOI, L. H.; OLDONI, H.; MARTINS, R. L. Automatic grape bunch detection in vineyards based on affordable 3D phenotyping using a consumer webcam. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 11., 2017, Campinas. **Ciência de dados na era da agricultura digital: anais**. Campinas: Ed. Unicamp: Embrapa Informática Agropecuária, 2017. v. 11, p. 89-98.

Scudiero, E.; Teatini, P.; Corwin, D. L.; Deiana, R.; Berti, A.; Morari, F. Delineation of site-specific management units in a saline region at the Venice Lagoon margin, Italy, using soil reflectance and apparent electrical conductivity. **Computers and Electronics in Agriculture**, v. 99, p. 54-64, Nov 2013. DOI: [10.1016/j.compag.2013.08.023](https://doi.org/10.1016/j.compag.2013.08.023).

SUN, S.; LI, C.; PATERSON, A. H.; JIANG, Y.; XU, R.; ROBERTSON, J. S.; SNIDER, J. L.; CHEE, P. W. In-field high throughput phenotyping and cotton plant growth analysis using LiDAR. **Frontiers in Plant Science**, v. 9, p. 16, Jan 2018. DOI: [10.3389/fpls.2018.00016](https://doi.org/10.3389/fpls.2018.00016).

SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICTORIA, D. de C.; DUCATI, J. R.; OLIVEIRA, R. P. de; VILELA, M. de F. Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 58-73.

SMTIS, F. M. Measurement of sheet resistivities with the four-point probe. **The Bell System Technical Journal**, v. 37, n. 3, p. 711-718, May 1958. DOI: [10.1002/j.1538-7305.1958.tb03883.x](https://doi.org/10.1002/j.1538-7305.1958.tb03883.x).

SPERANZA, E. A.; GREGO, C. R.; JORGE, L. A. C.; RODRIGUES, C. A. G.; LUCHIARI JUNIOR, A.; RONQUIM, C. C.; SANCHES, G. M. Delineamento de zonas de manejo em cana-de-açúcar a partir de atributos do solo e da cultura e imagens georreferenciadas. In: SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA, 4., 2019, São Carlos, SP. **Ciência, inovação e mercado: anais**. São Carlos, SP: Embrapa Instrumentação, 2019a. p. 175-179.

SPERANZA, E. A.; GREGO, C. R.; RODRIGUES, G. C.; LUCHIARI, A. Influência das diferentes faces de exposição ao sol nos índices vegetativos e relativo de clorofila em cafés especiais. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 12., 2019, Indaiatuba. **Anais**. Indaiatuba: FATEC; Campinas: Embrapa Informática Agropecuária; Ponta Grossa: UEPG, 2019b.

SUDDUTH, K. A.; DRUMMOND, S. T. Yield editor: software for removing errors from crop yield maps. **Agronomy Journal**, v. 99, n. 6, p. 1471-1482, 2007. DOI: [10.2134/agronj2006.0326](https://doi.org/10.2134/agronj2006.0326).

TANG, J. L.; WANG, D.; ZHANG, Z. G.; HE, L. J.; XU, Y. Weed identification based on K-means feature learning combined with convolutional neural network. **Computers and Electronics in Agriculture**, v. 135, p. 63-70, 2017. DOI: [10.1016/j.compag.2017.01.001](https://doi.org/10.1016/j.compag.2017.01.001).

VEGA, A.; CÓRDOBA, M.; CASTRO-FRANCO, M.; BALZARINI, M. Protocol for automating error removal from yield maps. **Precision Agriculture**, v. 20, n. 5, p. 1030-1044, 2019. DOI: [10.1007/s11119-018-09632-8](https://doi.org/10.1007/s11119-018-09632-8).

VERIS. **Sensor Veris Technologies**. Disponível em: <http://www.veristech.com>. Acesso em: 3 set 2020.

VIEIRA, S. R. Uso de geoestatística em estudos de variabilidade espacial de propriedades do solo. In: NOVAIS, R. F.; ALVAREZ V., V. H.; SCHAEFER, C. E. G. R. (org.). **Tópicos em ciência do solo**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2000. v. 1, p. 1-54.

ZHANG, T-X.; SU, J.-Y.; LIU, C.-J.; CHEN, W. H. Potential bands of Sentinel-2A satellite for classification problems in precision agriculture. **International Journal of Automation and Computing**, v. 16, n. 1, p. 16-26, 2019. DOI: [10.1007/s11633-018-1143-x](https://doi.org/10.1007/s11633-018-1143-x).