Capítulo

Fenotipagem de plantas em larga escala: um novo campo de aplicação para a visão computacional na agricultura

Thiago Teixeira Santos Juliana Erika de Carvalho Teixeira Yassitepe

1 Introdução

Tecnologias visando aumentar a acurácia e rapidez das mensurações fenotípicas para melhor caracterização e entendimento das funções biológicas dos organismos em resposta a diferentes condições ambientais vêm sendo alvo de intensas pesquisas nos últimos anos. Este esforço recente busca diminuir o "gargalo de fenotipagem" (*phenotyping bottleneck*), como vem sendo chamada pela comunidade científica a lacuna entre a quantidade e qualidade de dados genômicos e fenotípicos disponíveis. Técnicas correntes de sequenciamento tornaram a caracterização de genomas um processo eficiente e barato, gerando uma enorme massa de dados para pesquisa. Porém, um avanço similar ainda não ocorreu na caracterização em larga escala de fenótipos, e isso retarda o avanço no entendimento das associações genótipo versus fenótipo.

Para alcançar a mesma velocidade observada atualmente na caracterização genômica, é necessário incorporar à fenotipagem avanços nas áreas de computação, robótica, visão computacional e análise de imagens (COBB et al., 2013; FIORANI; SCHURR, 2013; FURBANK; TESTER, 2011). Com o foco neste objetivo, uma nova área do conhecimento científico está emergindo e vem sendo chamada de "fenômica", em alusão às ciências "ômicas" que estudam os genes, transcritos, proteínas e metabolitos de um organismo. Esta nova ciência, fenômica, se concentra na aquisição de dados fenótipos em larga escala e dimensão, em um curto espaço de tempo, oferecendo com isso uma oportunidade única de visualizar, em vários níveis hierárquicos, o fenótipo de um organismo.

Visão computacional e análise de imagens são hoje um dos principais componentes em qualquer plataforma moderna de fenotipagem (FIORANI; SCHURR, 2013; FURBANK; TESTER, 2011). Técnicas baseadas em imagem são capazes de capturar grandes volumes de dados quantitativos sobre o fenótipo, através de metodologias que não são invasivas ou destrutivas. A fenotipagem de plantas é uma aplicação desafiadora à visão computacional, por apresentar problemas nas áreas de modelagem tridimensional (3D), segmentação e classificação, metrologia por imagem e processamento de nuvens de pontos. Um exemplo da aproximação entre as áreas pôde ser visto em 2014, quando a tradicional *Conferência Europeia em Visão Computacional* - European Conference on Computer Vision (ECCV) incluiu um workshop dedicado a problemas em fenotipagem de plantas (Computer Vision Problems in Plant Phenotyping) (CVPPP).

O presente capítulo apresenta uma visão geral dos avanços recentes na fenotipagem em larga escala (Seção 2) e como a visão computacional surge como ferramenta para a caracterização fenotípica não-destrutiva da parte aérea de plantas (Seção 3). O capítulo se encerra (Seção 4) apresentando cenários futuros de pesquisa nessa área.

2 Tecnologias e plataformas de fenotipagem de plantas em larga escala

As tecnologias que estão sendo utilizadas nesta nova era de fenotipagem de plantas empregam técnicas de espectroscopia, termografia, tomografia, fluorescência, discriminação por isótopos e imagens digitais. Como muitas dessas técnicas de aquisição de dados são não-destrutivas, é possível coletar dados em diversos momentos ao longo do crescimento e desenvolvimento da planta. Como resultado, características que nunca foram mensuradas antes ou somente em situações específicas estão começando a ser medidas com maior frequência, como fluorescência da clorofila, atividade de estômatos, temperatura foliar e arquitetura de raízes e folhas. Além disso, processos dinâmicos tais como crescimento, desenvolvimento e resposta a estresse, os quais na maioria das vezes vinham sendo caracterizados em um único e determinado momento, podem agora ser descritos ao longo do tempo e espaço (FIORANI; SCHURR, 2013).

Tecnologias baseadas em espectroscopia de absorção estão entre as novas tecnologias de fenotipagem em larga escala mais utilizadas nos laboratórios. Dentre elas se destaca a espectroscopia de infravermelho próximo (NIRS na sigla em inglês), comumente empregada para identificar a composição química de uma amostra. A identificação de um composto por esta técnica é possível devido ao fato de as ligações químicas das substâncias possuírem frequências de vibração específicas, as quais correspondem a níveis de energia da molécula. Amostras de referência são usadas para construção de curvas de calibração validadas, que serão utilizadas na inferência sobre a composição química de amostras desconhecidas baseadas em seus espectros NIRS. Curvas de calibração acuradas são essenciais para o sucesso da aplicação de NIRS e a obtenção dessas curvas requer um trabalho prévio envolvendo a análise de uma ampla diversidade fenotípica para as características que se deseja medir. Exemplos nos quais NIRS vem permitindo um rápido screening de germoplasmas incluem a caracterização da composição química de grãos (JIANG et al., 2007; OSBORNE, 2006; TALLADA et al., 2009), detecção de infecção por fungos e toxinas derivadas de fungos em grãos (BERARDO et al., 2005; PEARSON; WICKLOW, 2006) e a determinação da composição química de raízes, caules e tubérculos (LEBOT et al., 2009; MURRAY et al., 2008a, 2008b; WALSH et al., 2000).

Outra tecnologia que está contribuindo extensivamente para fenômica em ambientes controlados é a captura e análise de imagens. Imagens podem ser adquiridas usando técnicas de refletância clássicas tais como fotografia de luz e microscopia ou por técnicas mais modernas como termografia, fluorescência, tomografia, ressonância magnética e ressonância nuclear (BERGER et al., 2010; HOULE et al., 2010; MONTES et al., 2007b). Tecnologias baseadas em imagens podem ser usadas para medir características bioquímicas, fisiológicas e morfológicas tais como atividade fotossintética, atividade estomática, composição química foliar e arquitetura de folhas e raízes (CLARK et al., 2011; GENTY; MEYER, 1995; LENK et al., 2007; MERLOT et al., 2002; ROMANO et al., 2011). Além de serem aplicadas isoladamente, as técnicas baseadas em espectroscopia e imagens podem ser combinadas para permitir uma análise mais compreensível das características mensuradas (CHAERLE et al., 2007; GOETZ et al., 1985). Neste contexto, uma das tecnologias mais promissoras, imagens hiperespectrais, reúne análises de imagens e espectros ao longo de uma ampla extensão de comprimentos de ondas em duas ou três dimensões do espaço (GOWEN et al., 2007). Imagens hiperespectrais vêm sendo utilizadas para detectar contaminação biológica em grãos (DEL FIORE et al., 2010, WILLIAMS et al., 2009) e na análise de crescimento e desenvolvimento de plantas (WALTER; SCHURR, 2005). Similarmente, imagens com fluorescência da clorofila em um contexto espacial também vêm sendo usadas para investigar resposta a estresses abióticos (KONISHI et al., 2009) e bióticos (ROLFE; SCHOLES, 2010).

Apesar das interessantes possibilidades que as tecnologias de fenotipagem utilizadas em laboratório ou ambientes controlados podem oferecer, a maioria das características de importância agronômica precisam ser avaliadas em campo. Felizmente, várias destas recentes tecnologias podem ser adaptadas para caracterização fenotípica no campo (HATFIELD et al., 2008). Vários tipos de sensores vêm sendo desenvolvidos para serem usados no campo. Ao nível do solo, sensores estão disponíveis em equipamentos manuais tais como espectro radiômetros, medidores de clorofila, e termômetros infravermelhos (MONTES et al., 2007a, 2007b; WELLE et al., 2003, 2005) e acoplados em tratores, picadores, colheitadeiras e mesmo em pivôs de irrigação, o que permite o ganho de escala e possibilita a análise de milhares de amostras em um curto espaco de tempo. Sensores manuais portáteis estão disponíveis para detectar deficiência de nutrientes e predizer conteúdo total de nitrogênio, biomassa, produtividade de grãos e variações em status fisiológicos (BABAR et al., 2006a, 2006b; OSBORNE et al., 2002a, 2002b; POSS et al., 2006). A aplicação de NIRS acoplados a tratores e picadores foi demonstrada por Montes et al. (2006, 2007b) e Welle et al. (2003, 2005) durante avaliação da qualidade, teor de matéria seca e produtividade de silagem de milho. Algumas destas características puderam ser medidas com precisão superior às dos procedimentos clássicos de NIRS em laboratório. Características de crescimento também têm sido mensuradas utilizando tecnologia de sensoriamento remoto no campo (PETERS; EVETT, 2007; WINTERHALTER et al., 2011a, 2011b). Sensores e câmeras podem também ser acoplados em torres, dirigíveis ou drones, para nomear alguns, o que permite a aquisição de dados de uma área extensa e favorece a análise de características fenotípicas dinâmicas em milhares de plantas (FURBANK; TESTER, 2011; JONES et al., 2009).

Mesmo utilizando estas novas tecnologias, muitos dos equipamentos disponíveis para fenotipagem em larga escala ainda requerem o manuseio do operador. Este processo é muitas vezes exaustivo, tedioso e custoso. Para minimizar o viés individual obtido pelas mensurações manuais e garantir escala, acurácia e precisão nas medições, a mecanização e a automação de alguns processos surgem como alternativas, principalmente envolvendo o cultivo das plantas e o processamento de imagens e dados gerados (COBB et al., 2013; FURBANK; TESTER, 2011).

Empregando os últimos avanços tecnológicos em fenotipagem bem como tecnologias robóticas e analíticas, sofisticadas plataformas de fenotipagem em configurações automatizadas e semiautomáticas vem sendo desenvolvidas, tais como: Phenopsis (GRANIER et al., 2006), Growscreen (BISKUP et al., 2009; NAGEL et al., 2012; RASCHER et al., 2011) e TraitMill[™] (REUZEAU et al., 2006), além de soluções comerciais de empresas como LemnaTec, GmbH¹

¹ Disponível em: <http://www.lemnatec.com>.

e Qubit Systems². Desenhadas para câmaras de ambiente controlado, essas plataformas ajudam a automatizar várias etapas do processo de cultivo e fenotipagem, como preparo do substrato, enchimento de potes, plantio, fertilização, irrigação, aquisição e análise de dados fenotípicos (HENTEN, 2006). Sistemas de códigos de barra e identificação por radiofrequência podem também ser incluídos na plataforma, permitindo com isso identificação e rastreamento automático de amostras. Computadores de alta capacidade, bancos de dados e software também estão sendo desenvolvidos e utilizados na aquisição, armazenamento e análise de quantidades massivas de dados que tais plataformas são capazes de gerar (HARTMANN et al., 2011; LI et al., 2011; VANKADAVATH et al., 2009).

Centros de fenômica utilizando essas plataformas surgiram nos últimos anos, principalmente na Austrália e Europa. Exemplos incluem a Australian Plant Phenomics Facility (Adelaide e Canberra, Austrália), o Jülich Phenomics Centre (Jülich, Alemanha), o Leibniz Institute of Plant Genetics and Crop Plant Research (Gatersleben, Alemanha), a PhenoArch (Montpellier, França) e a Crop Design (Zwijnaarde, Bélgica). No entanto, muitas destas plataformas foram desenvolvidas para aplicações com plantas modelo ou culturas de grande importância econômica. Plataformas genéricas e soluções modulares e flexíveis que permitam a avaliação simultânea do fenótipo de múltiplas espécies e capazes de acomodar necessidades experimentais diferentes não estão ainda disponíveis (COBB et al., 2013; FIORANI; SCHURR, 2013). Buscando unir esforços no sentido de padronizar as metodologias de fenotipagem empregadas, desenvolver novos sensores, instrumentos e estruturas para acessar, gerenciar e analisar a informação tecnológica gerada, muitos destes centros se organizam em redes, como a Rede Europeia para Fenotipagem de Plantas (European Plant Phenotyping Network - EPPN)³.

2.1 Representação de fenótipo

Enquanto o genoma de um organismo pode ser caracterizado através de suas sequências de bases, é virtualmente impossível caracterizar totalmente seu *fenoma*. Como expresso por Cobb et al. (2013): "o fenoma de um organismo é dinâmico e condicional, o que representa um conjunto complexo de respostas a um conjunto multi-dimensional de sinais endógenos e exógenos que são integradas ao longo do desenvolvimento de um indivíduo".

Contudo, se nos restringirmos aos aspectos macroscópicos da parte aérea da planta, um modelo 3D pode atuar como uma representação temporal concisa e versátil do estado do indivíduo, permitindo que diferentes medidas quantitativas sejam computadas, como área e angulação foliar, porcentagem de área afetada (em patologias), curvatura e enrolamento foliar ou altura. Outras medições podem ser computadas *a posteriori*, destinadas a responder outros questionamentos, formulados posteriormente dentro do mesmo experimento ou de um novo. Dado o caráter não--invasivo e não-destrutivo dos procedimentos de aquisição de imagens, o comportamento do espécime ao longo do tempo pode ser avaliado comparando os vários modelos tridimensionais construídos ao longo do tempo.

O procedimento de criação desses modelos tridimensionais é frequentemente chamado na literatura em fisiologia vegetal de digitalização de plantas (*plant digitizing*) e diversas metodologias para tal fim foram propostas ao longo dos anos.

3 Visão computacional e digitalização 3D de plantas

Os primeiros esforços na digitalização 3D de plantas empregavam dispositivos mecânicos (LANG, 1973), digitalizadores sônicos (SINOQUET et al., 1991) ou rastreadores magnéticos (RAKOCEVIC et al., 2000). Tais métodos de contato foram importantes na criação de modelos funcionais e estruturais do desenvolvimento de plantas (GODIN et al., 1999; RAKOCEVIC et al., 2000) mas são incapazes de atingir o desempenho necessário à fenotipagem em alta escala. As iniciativas atuais em fenotipagem com reconstrução tridimensional se baseiam em métodos sem contato como varredura laser, câmeras ToF (*time-of-flight*) e visão estéreo.

3.1 Digitalização de plantas por métodos sem contato

Provavelmente o primeiro trabalho a utilizar varredura por laser na caracterização da estrutura tridimensional de plantas em fenotipagem de larga escala foi apresentado por Kaminuma et al. (2004) em seus experimentos com *Arabidopsis thaliana*. Folhas e pecíolos foram representados em 3D por malhas poligonais. Essas malhas foram utilizadas na determinação quantitativa de dois atributos de interesse: a direção da lâmina e a epinastia da folha, visando a caracterização de dois ecótipos diferentes de Arabidopsis. A configuração da montagem foi capaz de produzir uma boa amostragem das superfícies: a distância de aquisição e a amostragem permitiram uma resolução de 0,045 milímetros por pixel, produzindo uma nuvem densa de pontos 3D. Contudo, plantas diferentes apresentando dimensões maiores, ou até mesmo espécimes de *Arabdopsis* em um estágio mais avançado de desenvolvimento, produziam conjuntos de pontos mais esparsos.

Equipamentos de varredura laser, como o LiDAR, são caros e difíceis de serem movimentados. Uma alternativa mais barata e flexível é o uso de visão estéreo com câmeras simples. Diversos métodos na literatura utilizam visão estéreo para digitalização sem contato de plantas, a partir do conceito de triangularização em geometria projetiva. Considere duas imagens tomadas por uma câmera em duas posições diferentes (ou, alternativamente, duas câmeras posicionadas em locais diferentes). Para cada imagem, um pixel define um raio no espaço 3D - todo ponto 3D nesse raio será projetado no mesmo pixel. Se as posições e os parâmetros internos da câmera forem conhecidos previamente, um par de pontos correspondentes em diferentes imagens irá definir um par de raios e a localização do ponto em 3D estará na intersecção dos raios (o leitor interessado em um tratamento aprofundado do problema da triangularização pode recorrer a Hartley e Zisserman, 2004).

O trabalho de Ivanov et al. (1995) é possivelmente o primeiro trabalho na literatura a utilizar visão estéreo na reconstrução 3D da superfície de um cultivar para medição e análise. Os autores estimaram a posição e a orientação de folhas de milho (*Zea mays* L.) e a distribuição da área foliar. Seu sistema utilizava um par de câmeras instalado a 8,5 metros do solo em um campo de milho apresentando altura de 2,5 metros. Infelizmente, as dificuldades impostas pelo equipamento disponível na época (a fotografia digital ainda não era largamente disseminada) comprometeram os experimentos. A segmentação das folhas e a determinação das correspondências entre imagens foram realizadas manualmente, utilizando-se ampliações fotográficas. Apesar das limitações, este trabalho foi o antecessor de sistemas mais recentes, capazes de empregar avanços em computação, imageamento digital e visão computacional. Biskup et al. (2007) desenvolveram um sistema de visão estéreo baseado em duas câmeras digitais para criar modelos tridimensionais para folhas de soja, com o objetivo de analisar o ângulo de inclinação e o movimento das folhas

² Disponível em: <http://qubitsystems.com>.

³ Disponível em: <http://www.plant-phenotyping-network.eu>.

ao longo do dia. Dada a importância do movimento para o experimento, o sistema era capaz de processar até três imagens por segundo, recuperando assim a informação 3D necessária para o cômputo da inclinação.

Dados de profundidade oriundos de câmeras ToF podem ser combinados a dados RGB de câmeras convencionais para produzir reconstruções 3D de folhas apesar da baixa resolução dos dispositivos ToF atuais. Song et al. (2011) combinaram dados de um par de câmeras RGB (480 x 1280 pixeis) e de uma câmera ToF (64 x 48 pixeis) utilizando a técnica de minimização por cortes em grafos (BOYKOV et al., 2001). O par de câmeras provê uma resolução mais alta enquanto a informação ToF auxilia na resolução de falhas no cômputo da profundidade em regiões sem textura, nas quais a determinação de correspondência entre imagens é mais propensa a falhas. Alenyà et al. (2011) empregaram uma abordagem mais simples: os pontos 3D produzidos por uma câmera ToF foram transformados para as coordenadas de referência de uma câmera RGB e, em seguida, projetados para o plano de imagem da câmera - pontos nesse plano que não apresentassem uma contraparte 3D da câmera ToF foram descartados. Apesar do método simples, os autores foram capazes de produzir bons resultados pois: a) a câmera ToF empregada apresentava uma resolução maior (200 x 200 pixeis) e b) um braço robô foi utilizado na movimentação das câmeras, permitindo a aquisição de mais dados, uma abordagem de sensoriamento ativo (*sensing-for-action*) proposta pelos autores.

No arcabouço de triangularização, uma câmera do par estéreo pode ser substituída por um projetor. O mesmo princípio de intersecção de raios pode ser aplicado se a posição do projetor e seus parâmetros internos forem conhecidos. Bellasio et al. (2012) utilizaram um par câmera-projetor e um método de luz codificada (*coded-light*) para determinar a correspondência entre pixels, recuperando a superfície 3D das folhas de pimenteiros. Chéné et al. (2012) empregaram uma câmera RGB-D (um Microsoft Kinect®) para segmentar folhas e estimar sua orientação e inclinação. Tais câmeras RGB-D consistem em um par câmera-projetor e um sistema de triangularização embarcados em um único dispositivo, também utilizando luz codificada para estabelecer correspondências entre pixels (FREEDMAN et al., 2013).

Recentemente, visão estéreo múltipla *multiple-view stereo* (MVS) passou a ser empregada em digitalização de plantas como uma tentativa de solucionar problemas de oclusão encontrados na reconstrução 3D. Paproki et al. (2012) empregaram o software 3D SOM. (BAUMBERG et al., 2005) para criar modelos tridimensionais de espécimes de algodão (*Gossypium hirsutum*) e então estimar a altura de suas hastes, a largura e o comprimento das folhas. Os espécimes foram colocados em uma mesa giratória contendo um padrão de calibração utilizado pelo 3D SOM na estimação da posição relativa da câmera em cada quadro.

Santos e Oliveira (2012) empregaram o arcabouço de estruturação por movimento, *structure-from-motion* (SfM) (HARTLEY; ZISSERMAN, 2004), para recuperar o posicionamento da câmera em cada imagem. SfM estende o arcabouço de triangularização incorporando uma etapa que simultaneamente busca pelas melhores estimativas para as posições da câmera e as posições dos pontos 3D na superfície do objeto. Tal processo, *bundle-adjustment*, é um procedimento de maximização da esperança que avalia múltiplos ângulos ao mesmo tempo, minimizando o erro de reprojeção para cada imagem. Ao invés de empregar um padrão de calibração, os autores utilizaram a detecção de características visuais locais nas imagens e suas correspondências intra-imagens, como proposto por Snavely et al. (2008) no contexto de reconstrução 3D de arquitetura

de cidades, para recuperar os parâmetros da câmera (posição, orientação e parâmetros internos). Os dados da câmera e o modelo 3D inicial produzidos foram utilizados como entrada para um algoritmo de MVS, o PMVS proposto por Furukawa e Ponce (2010), o qual foi capaz de produzir nuvens de pontos 3D densas, amostrando a superfície de folhas e entrenós em experimentos com manjericão, *Ixora* (SANTOS; OLIVEIRA, 2012), hortelã (SANTOS; UEDA, 2013) e girassol (Figura 1).



Figura 1. Resultados para girassol produzidos a partir de 302 imagens com 3888 x 2592 pixeis de resolução (a-c) pela metodologia proposta . O modelo 3D é composto por 829.722 pontos 3D (d-f).

Sirault et al. (2013) também reportam resultados em reconstrução 3D a partir do sistema PMVS de Furukawa e Ponce (2010). Os autores utilizam um conjunto de câmeras fixas e calibradas, imageando plantas em vasos posicionados em uma mesa giratória de alta precisão (2,5 milhões de passos por revolução). Sua plataforma de digitalização, PlantScan[™], é uma câmara esquipada com três câmeras RGB CCD, uma câmera NIR e dois varredores laser LiDAR, além de dois sensores térmicos. Seu sistema de reconstrução estéreo emprega os métodos de visão estéreo múltipla (PMVS) e colorização de voxels, *voxel colouring* (LEUNG et al., 2012), que são combinados aos dados LiDAR com o uso de algoritmos de registro RANdom SAmple Consensus (Ransac) e Iterative Closest Point (ICP). Os autores reportam que sua plataforma é capaz de digitalizar plantas de poucos centímetros até dois metros em altura e até um metro de diâmetro, permitindo assim a fenotipagem da parte aérea de diversas espécies diferentes.

Santos et al. (2014) estenderam sua metodologia inicial (SANTOS; OLIVEIRA, 2012) incorporando uma aplicação que seleciona automaticamente quadros de uma sequência de vídeo em

tempo real. O aplicativo computa características visuais locais e suas correspondências entre quadros utilizando uma unidade de processamento gráfico (GPU), selecionando um conjunto de quadros capaz de produzir boas reconstruções tridimensionais (o algoritmo garante um número mínimo de correspondências entre quadros que possibilite ao método de SfM recuperar a posição da câmera). O usuário pode mover livremente a câmera ao redor da planta, o que possibilita a resolução de oclusões.

Metodologias que empregam uma única câmera móvel apresentam duas vantagens. A flexibilidade na definição do caminho percorrido pela câmera permite um melhor tratamento de oclusão e variações no tamanho e na morfologia das plantas. O trabalho de Alenyà et al. (2011) ilustra tal característica, mostrando como o planejamento apropriado de movimentação para um braço robô é capaz de posicionar a câmera em locais onde oclusões podem ser facilmente resolvidas. A outra vantagem diz respeito ao baixo custo de tais soluções. Um experimento que requer fenotipagem de alto-desempenho pode exigir a digitalização de centenas de indivíduos por dia. Metodologias baratas de reconstrução permitem que diversos módulos de digitalização sejam montados para o experimento e empregados na paralelização do trabalho.

3.2 Digitalização de plantas no campo

Os métodos apresentados na seção anterior são dedicados a ambientes controlados como casas de vegetação e câmaras de crescimento. Esses ambientes permitem o controle de características ambientais e um alto nível de automação. Porém, pesquisas agrícolas geralmente requerem experimentos em campo, na tentativa de compreender como certos germoplasmas irão se comportar em condições reais de produção. Tais ambientes são mais complexos para a fenotipagem em alta escala e à reconstrução 3D de plantas devido à dificuldade de automação, à variabilidade nas condições de luz e aos problemas com movimentação devida ao vento.

Contudo, há avanços na reconstrução 3D de plantas em campo. Rovira-Más et al. (2005) acoplaram uma câmera estéreo a um helicóptero controlado por rádio. As imagens foram combinadas na produção de um mapa 3D de um campo de milho. Jay et al. (2014) acoplaram uma câmera a um eixo de translação móvel, produzindo um conjunto de imagens para linhas de plantio de beterraba em campo. Essas imagens foram utilizadas na reconstrução 3D do dossel das plantas de beterraba via SfM.

Kazmi et al. (2014) analisaram o uso de câmeras ToF na estimação de profundidade de folhas (distância entre o sensor e a superfície da folha) em ambientes de campo. Os autores mostram que tais câmeras são capazes de estimar de maneira acurada a profundidade em diversas condições de iluminação (ambiente ensolarado ou nublado). Folhas com superfícies homogêneas (sem textura), que são um problema para sistemas baseados em visão estéreo devido às dificuldades em estabelecer correspondências entre pares de imagens, não apresentam dificuldades para câmeras ToF, que usam iluminação ativa e não dependem do cômputo de correspondências intra-imagens.

3.3 Análise de nuvens de pontos

Os métodos apresentados anteriormente envolvendo LiDAR, câmeras ToF ou métodos de visão estéreo produzem dados 3D na forma de nuvens de pontos que amostram a superfície do objeto. Dependendo do processo de aquisição, do posicionamento dos sensores e dos algoritmos utilizados, tal amostragem pode variar em um mesmo modelo, sendo mais densa em certas partes e

mais esparsa em outras. Outros problemas podem ocorrer, como buracos causados por oclusões não resolvidas ou reflexão especular da luz. Considerando-se todos esses problemas, a nuvem de pontos precisa ser analisada conforme os seguintes passos:

- 1) A superfície da planta deve ser inferida a partir dos pontos para que medidas quantitativas como área foliar possam ser devidamente computadas (Figura 2);
- O modelo deve ser segmentado em partes significativas para caracterização da estrutura da planta;
- Cada segmento deve ser classificado em categorias significativas (folhas, entrenós, pecíolos, frutos, flores etc.) para que medições quantitativas sejam devidamente realizadas em cada estrutura diferente do organismo.



Figura 2. Inferindo superfícies a partir de nuvens de pontos. Nuvem de pontos produzida por SfM e MVS (a). Malha triangular produzida pelo algoritmo *ball pivoting* (b). Visualização da superfície suavizada (c).

Xu et al.(2007) produziram nuvens de pontos para árvores utilizando um dispositivo LiDAR. Pontos próximos foram conectados, estruturando a nuvem na forma de um grafo no qual cada ponto 3D corresponde a um vértice. Os grafos foram segmentados e simplificados na forma de esqueletos que representam a estrutura de troncos e galhos. Os esqueletos e as nuvens de pontos foram então empregados na estimação de parâmetros de modelos alométricos, responsáveis por definir a superfície das árvores na forma de uma malha 3D.

Santos e Ueda (2013) empregaram *clustering* de pontos para segmentar folhas em espécimes de hortelã (SANTOS; UEDA, 2013), girassol e soja (SANTOS et al. 2014), como ilustrado na Figura 3. Os segmentos obtidos são subconjuntos disjuntos da nuvem original e foram caracterizados através de medidas como comprimento e largura. Essas medidas permitiram a construção de classificadores capazes de identificar quais segmentos correspondiam às folhas da planta. Uma vez identificadas, as folhas tiveram suas superfícies caracterizadas através de *splines*, cujos parâmetros foram estimados a partir dos pontos 3D atribuídos a cada folha. Alenyà et al.(2011) procederam de forma similar: pontos foram agrupados através de algoritmos de *clustering* e um modelo quadrático foi empregado para representar superfícies curvas (folhas), sendo seus parâmetros estimados a partir dos pontos 3D através de um procedimento de otimização.

A ideia por trás dessas metodologias é que, uma vez identificada corretamente a estrutura em questão, um modelo apropriado pode ser selecionado para representá-la. Por exemplo, *splines* podem ser utilizadas para representar a superfície das folhas enquanto que cilindros generalizados são mais adequados para caracterizar estruturas como entrenós e pecíolos. Medidas de interesse, como área foliar, inclinação foliar, comprimento e largura, podem ser então estimadas a partir do modelo paramétrico (SANTOS; UEDA, 2013).







(d)

Figura 3. Segmentação do modelo. (a) Nuvem de pontos produzida pelo método. (b) Segmentação através de spectral clustering - cores diferentes indicam segmentos diferentes. (c) Vista superior do mesmo modelo. (d) Vista superior da segmentação.

4 Considerações finais

Novos equipamentos para imageamento 3D têm surgido nos últimos anos. Câmeras baseadas em métodos como ToF (KAZMI et al., 2014) ou luz estruturada (FREEDMAN et al., 2013) são hoje disponibilizadas como produtos comerciais com valores inferiores a 500 dólares. Esses equipamentos apresentam resoluções crescentes ano a ano e devem disseminar a produção de dados 3D a baixo custo. Paralelamente, avanços em visão estéreo múltipla e estruturação por movimento (NEWCOMBE et al., 2011a, 2011b; PIZZOLI et al., 2014;) irão permitir a construção de modelos 3D em tempo real, permitindo que o modelador (seja ele um operador humano ou um sistema automatizado) identifique, durante a aquisição das imagens, quais regiões da planta necessitam de mais detalhes e quais ângulos precisam ser fornecidos para completar o modelo e resolver oclusões.

Considerando que tais tecnologias irão produzir uma quantidade cada vez maior de dados tridimensionais, tornam-se cada vez mais necessárias metodologias capazes de analisar esses dados, identificando automaticamente as estruturas de interesse, realizando as medições necessárias para a caracterização do fenótipo e detalhando o comportamento dessas estruturas ao longo do tempo. A principal vantagem de métodos não-destrutivos é permitir que os indivíduos continuem se desenvolvendo ao longo do experimento e registrar esse desenvolvimento. Novos métodos em visão computacional e aprendizado de máquina são necessários para permitir o reconhecimento automático das mesmas estruturas ao longo do tempo, por exemplo, para registrar o desenvolvimento de uma folha ao longo de um experimento.

Outro problema de interesse diz respeito à fusão de dados de múltiplos sensores. Na tentativa de obter uma caracterização mais completa do *fenoma* de um indivíduo em um dado instante, informação oriunda de outros sensores, como termógrafos, espectrômetros e fluorímetros, poderia ser incorporada ao modelo tridimensional da planta, permitindo o registro da variação de leituras ao longo da superfície do indivíduo ou, no pior dos casos, um registro preciso da localização da leitura. A ideia é obter o *snapshot* mais completo possível do estado da planta no momento da medição.

As inovações em visão computacional, automação, robótica e imageamento multiespectral irão melhorar a qualidade, quantidade e dimensionalidade dos dados fenotípicos, permitindo uma melhor caracterização do organismo. Hoje, os custos associados com muitas destas tecnologias de fenotipagem em larga escala limitam seu uso a indústrias de biotecnologia e sementes, e a poucos projetos públicos. Entretanto, pressupondo que o fenótipo ganhará tanta notoriedade como os genótipos alcançaram na era da genômica, progressos contínuos no desenvolvimento de sensores, câmeras, metodologias de imageamento, automação, entre outros, possibilitarão a redução de custos e a expansão da sua aplicação. Se estas perspectivas se concretizarem, avanços consideráveis são esperados tanto na ciência básica envolvendo elucidação de mecanismos biológicos fundamentais como na aplicação desse conhecimento e geração de valor através de novas variedades de plantas.

5 Referências

ALENYÀ, G.; DELLEN, B.; TORRAS, C. 3D modelling of leaves from color and ToF data for robotized plant measuring. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION, 2011, Shanghai. **Proceedings**... Piscataway: IEEE, 2011. p. 3408-3414.

BABAR, M. A.; GINKEL, M. van; PRASAD, B., REYNOLDS, M. P. The potential of using spectral reflectance indices to estimate yield in wheat grown under reduced irrigation. **Euphytica**, Wageningen, v. 150, n. 1-2, p. 155-172, Aug. 2006a.

BABAR, M. A.; REYNOLDS, M. P.; GINKEL, M. van; KLATT, A. R.; RAUN, W. R.; STONE, M. L. Spectral reflectance to estimate genetic variation for in-season biomass, leaf chlorophyll, and canopy temperature in wheat. **Crop Science**, Madison, v. 46, n. 3, p.1046-1057, 2006b. DOI: 10.2135/cropsci2005.0211.

BAUMBERG, A.; LYONS, A.; TAYLOR, R. 3D S.O.M.—A commercial software solution to 3D scanning. **Graphical Models**, San Diego, v. 67, n. 6, p. 476-495, Nov. 2005. DOI: 10.1016/j.gmod.2004.10.002.

BELLASIO, C.; OLEJNÍCKOVÁ, J.; BELLASIO, C.; SEBELA, D.; NEDBAL, L. Computer reconstruction of plant growth and chlorophyll fluorescence emission in three spatial dimensions. **Sensors**, Basel, v. 12, n. 1, p. 1052-71, Jan. 2012. DOI:10.3390/s120101052.

BERARDO, N.; PISACANE, V.; BATTILANI, P.; SCANDOLARA, A.; PIETRI, A.; MAROCCO, A. Rapid detection of kernel rots and mycotoxins in maize by near-infrared reflectance spectroscopy. Journal of Agricultural and Food Chemistry, Easton, v. 53, n. 21, p. 8128-34, Oct. 2005.

BERGER, B.; PARENT, B.; TESTER, M. High-throughput shoot imaging to study drought responses. Journal of **Experimental Botany**, Oxford, v. 61, n. 13, p. 3519-3528, July, 2010. DOI:10.1093/jxb/erq201.

94

BISKUP, B.; SCHARR, H.; SCHURR, U.; RASCHER, U. A stereo imaging system for measuring structural parameters of plant canopies. **Plant, Cell & environment**, Nottinghan, v. 30, n. 10, p. 1299-308, Oct. 2007.

BOYKOV, Y.; VEKSLER, O.; ZABIH, R. Fast approximate energy minimization via graph cuts. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York , v. 23, n. 11, p. 1222-1239, Nov. 2001. DOI: 10.1109/34.969114.

CHAERLE, L.; LEINONEN, I.; JONES, H. G.; STRAETEN, D. van der. Monitoring and screening plant populations with combined thermal and chlorophyll fluorescence imaging. **Journal of Experimental Botany**, Oxford, v. 58, n. 4, p. 773-84, 2007. DOI:10.1093/jxb/erl257.

CHÉNÉ, Y.; ROUSSEAU, D.; LUCIDARME, P.; BERTHELOOT, J.; CAFFIER, V.; MOREL, P.; BELIN, E.; CHAPEAU-BLONDEAU, F. On the use of depth camera for 3D phenotyping of entire plants. **Computers and Electronics in Agriculture**, New York, v. 82, p. 122-127, Mar. 2012. DOI: 10.1016/j.compag.2011.12.007

CLARK, R. T.; MACCURDY, R. B.; JUNG, J. K.; SHAFF, J. E.; MCCOUCH, S. R.; ANESHANSLEY, D. J.; KOCHIAN, L. V. Three-dimensional root phenotyping with a novel imaging and software platform. **Plant Physiology**, Bethesda, v. 156, n. 2, p. 455-465, Jun. 2011. DOI: http://dx.doi.org/10.1104pp.110.169102.

COBB, J. N.; DECLERCK, G.; GREENBERG, A.; CLARK, R.; MCCOUCH, S. Next-generation phenotyping: requirements and strategies for enhancing our understanding of genotype-phenotype relationships and its relevance to crop improvement. **Theoretical and Applied Genetics**, Berlin, v. 126, n. 4, p. 867-87, May, 2013. DOI 10.1007/ s00122-013-2066-0.

DEL FIORE, A.; REVERBERI, M.; RICELLI, A.; PINZARI, F.; SERRANTI, S.; FABBRI, A. A.; BONIFAZI, G.; FANELLI, C. Early detection of toxigenic fungi on maize by hyperspectral imaging analysis. **International Journal of Food Microbiology**, Amsterdam, v. 144, n.1, p. 64-71, Nov. 2010. DOI: 10.1016/j.ijfoodmicro.2010.08.001. Epub 2010 Aug 13.

FIORANI, F.; SCHURR, U. Future scenarios for plant phenotyping. Annual Review of Plant Biology, Palo Alto, v. 64, p. 267-91, Feb. 2013. DOI.10.1146/annurev-arplant-050312-120137.

FREEDMAN, B.; SHPUNT, A.; MACHLINE, M.; ARIELI, Y. Depth mapping using projected patterns. Int US8493496 B2, 2013.

FURBANK, R. T.; TESTER, M. Phenomics - technologies to relieve the phenotyping bottleneck. Trends in Plant Science, Oxford, v. 16, n. 12, p. 635-644, Dec. 2011.

FURUKAWA, Y.; PONCE, J. Accurate, dense, and robust multiview stereopsis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, v. 32, n. 8, p. 1362-1376, Aug. 2010. DOI: 10.1109/TPAMI.2009.161.

GENTY, B.; MEYER, S. Quantitative mapping of leaf photosynthesis using chlorophyll fluorescence imaging. Australian Journal of Plant Physiology, Melbourne, v. 22, n. 2, p. 277-284, 1995.

GODIN, C.; COSTES, E.; SINOQUET, H. A method for describing plant architecture which integrates topology and geometry. **Annals of Botany**, London, v. 84, n. 3, p. 343-357, May, 1999.

GOETZ, A. F. H.; VANE, G.; SOLOMON, J. E.; ROCK, B. N. Imaging spectrometry for earth remote sensing. **Science**, Washington, DC, v. 228, n. 4704, p. 1147-1153, June, 1985. DOI: 10.1126/science.228.4704.1147.

GOWEN, A. A.; O'DONNELL, C. P.; CULLEN, P. J.; DOWNEY, G.; FRIAS, J. M. Hyperspectral imaging - an emerging process analytical tool for food quality and safety control. **Trends in Food Science & Technology**, Cambridge, v. 18, n.12, p. 590-598, Dec. 2007. DOI: 10.1016/j.tifs.2007.06.001.

GRANIER, C.; AGUIRREZABAL, L.; CHENU, K.; COOKSON, S. J.; DAUZAT, M.; HAMARD, P.; TARDIE, F. Phenopsis, an automated platform for reproducible phenotyping of plant responses to soil water deficit in Arabidopsis thaliana permitted the identification of an accession with low sensitivity to soil water deficit. **New Phytologist**, Cambridge, v. 169, n. 3, p. 623-635, Jan. 2006. DOI: 10.1111/j.1469-8137.2005.01609.x.

HARTLEY, R.; ZISSERMAN, A. Multiple view geometry in computer vision. 2nd ed. Cambridge University Press, 2004. 670 p.

HARTMANN, A.; CZAUDERNA, T.; HOFFMANN, R.; STEIN, N.; F. SCHREIBER. HTPheno: an image analysis pipeline for high-throughput plant phenotyping. **BMC Bioinformatics**, Cambridge, v. 12, n. 1, p. 148, May, 2011. DOI:10.1186/1471-2105-12-148.

HATFIELD, J. L.; GITELSON, A. A.; SCHEPERS, J. S.; WALTHALL, C. L. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, Madison, v.100, n.3, p. S-117-S-131, 2008. Suplemento. DOI: 10.2134/ agronj2006.0370c.

HENTEN, E. J. van. Greenhouse mechanization: state of the art and future perspective. Acta Horticulturae, The Hague, v. 710, p. 55-70, 2006. International Symposium on Greenhouses, Environmental Controls and In-house Mechanization for Crop Production in the Tropics and Sub-Tropics, June 2006.

HOULE, D.; GOVINDARAJU, D. R.; OMHOLT, S. Phenomics: the next challenge. Nature Reviews. Genetics, London, v. 11, p. 855-66, Dec. 2010.

IVANOV, N.; BOISSARD, P.; CHAPRON, M.; ANDRIEU, B. Computer stereo plotting for 3-D reconstruction of a maize canopy. Agricultural and Forest Meteorology, Amsterdam, v. 75, n.1-3, p. 85-102, June, 1995.

JAY, S.; RABATEL, G.; GORRETTA, N. In-field crop row stereo-reconstruction for plant phenotyping. In: INTERNATIONAL CONFERENCE ON ROBOTICS, AND ASSOCIATED HIGH-TECHNOLOGIES AND EQUIPMENT FOR AGRICULTURE AND FORESTRY, 2., 2014, Madrid. New trends in mobile robotics, perception and actuation for agriculture and forestry: proceedings... Madrid: Polytechnic University of Madrid, 2014. p. 339-348. Edyted by Pablo Gonzalez-de-Santos and Angela Ribeiro.

JIANG, H. Y.; ZHU, Y. J.; WEI, L. M.; DAI, J. R.; SONG, T. M.; YAN, Y. L.; CHEN, S. J. Analysis of protein, starch and oil content of single intact kernels by near infrared reflectance spectroscopy (NIRS) in maize (*Zea mays* L.). **Plant Breeding**, Berlin, v. 126, n. 5, p. 492-497, Oct. 2007. DOI. 10.1111/j.1439-0523.2007.01338.x.

JONES, H. G.; SERRAJ, R.; LOVEYS, B. R.; XIONG, L.; WHEATON, A.; PRICE, A. H. Thermal infrared imaging of crop canopies for the remote diagnosis and quantification of plant responses to water stress in the field. **Functional Plant Biology**, v. 36, n. 11, p. 978-989, Nov. 2009.

KAMINUMA, E.; HEIDA N.; TSUMOTO, Y.; YAMAMOTO, N.; GOTO, N.; OKAMOTO N.; KONAGAYA, A.; MATSUI, M.; TOYODA, T. Automatic quantification of morphological traits via three-dimensional measurement of Arabidopsis. **The Plant Journall**: for Cell and Molecular Biology, Oxford, v. 38, n. 2, p. 358-365, Apr. 2004.

KAZMI, W.; FOIX, S.; ALENYÀ, G.; ANDERSEN, H. J. Indoor and outdoor depth imaging of leaves with time-offlight and stereo vision sensors: Analysis and comparison. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 88, p. 128-146, Fev. 2014. DOI: 10.1016/j.isprsjprs.2013.11.012.

KONISHI, A.; EGUCHI, A.; HOSOI, F.; OMASA, K.3D monitoring spatio-temporal effects of herbicide on a whole plant using combined range and chlorophyll a fluorescence imaging. **Functional Plant Biology**, Victoria, v. 36, n. 11, p. 874-879, Nov. 2009. DOI: http://dx.doi.org/10.1071/FP09108.

LANG, A. R. G. Leaf orientation of a cotton plant. Agricultural Meteorology, Amsterdam, v. 11, p. 37-51, 1973.

LEBOT, V.; CHAMPAGNE, A.; MALAPA, R.; SHILEY, D. NIR determination of major constituents in tropical root and tuber crop flours. Journal of Agricultural and Food Chemistry, Easton, v. 57, n. 22, p.10539-47, Oct. 2009. DOI: 10.1021/jf902675n.

LENK, S., CHAERLE, L.; PFÜNDEL, E. E.; LANGSDORF, G.; HAGENBEEK, D.; LICHTENTHALER, H. K.; STRAETEN, D. van der; BUSCHMANN, C. Multispectral fluorescence and reflectance imaging at the leaf level and its possible applications. Journal of Experimental Botany, Oxford, v. 58, n. 4, p. 807-814, Nov. 2007.

LEUNG, C.; APPLETON, B.; BUCKLEY, M.; SUN, C. Embedded voxel colouring with adaptive threshold selection using globally minimal surfaces. **International Journal of Computer Vision**, Dordrecht, v. 99, n. 2, p. 215-231, Sept.. 2012.

LI, Y.-F.; KENNEDY, G.; NGORAN, F.; WU, P.; HUNTER, J. An ontology-centric architecture for extensible scientific data management systems. **Future Generation Computer Systems**, Amsterdam, v. 29, n. 2, p. 641-653, Feb. 2013.

MERLOT, S.; MUSTILLI, A. C.; GENTY, B.; NORTH, H.; LEFEBVRE, V.; SOTTA, B.; VAVASSEUR, A.; GIRAUDAT, J. Use of infrared thermal imaging to isolate Arabidopsis mutants defective in stomatal regulation. **Plant Journal**: for Cell and Molecular Biology, Oxford, v. 30, n. 5, p. 601-609, Jun. 2002.

MONTES, J. M.; MELCHINGER, A. E.; REIF, J. C. Novel throughput phenotyping platforms in plant genetic studies. **Trends in Plant Science**, Oxford, v. 12, n.10, p. 433-6. Oct. 2007a. DOI: 10.1016/j.tplants.2007.08.006.

MONTES, J. M.; PAUL, C.; MELCHINGER, A. E. Determination of chemical composition and nutritional attributes of silage corn hybrids by near-infrared spectroscopy on chopper: evaluation of traits, sample presentation systems and calibration transferability. **Plant Breeding**, Berlin, v. 126, n. 5, p. 521-526, Oct. 2007b. DOI: 10.1111/j.1439--0523.2007.01389.x.

MONTES, J. M.; UTZ, H. F.; SCHIPPRACK, W.; KUSTERER, B.; MUMINOVIC, J.; PAUL, C.; MELCHINGER, A. E. Near-infrared spectroscopy on combine harvesters to measure maize grain dry matter content and quality parameters. **Plant Breeding**, Berlin, v. 125, n. 6, p. 591-595, Dec. 2006. DOI:10.1111/j.1439-0523.2006.01298.x.

MURRAY, S. C.; ROONEY, W. L.; MITCHELL, S. E.; SHARMA, A.; KLEIN, P. E.; MULLET, J. E.; KRESOVICH, S. Genetic improvement of sorghum as a biofuel feedstock: II. QTL for stem and leaf structural carbohydrates. **Crop Science**, Madison, v. 48, n. 6, p. 2180-2193. 2008a. DOI:10.2135/cropsci2008.01.0068.

MURRAY, S. C.; SHARMA, A.; ROONEY, W. L.; KLEIN, P. E.; MULLET, J. E.;. MITCHELL, S. E.; KRESOVICH, S. Genetic improvement of sorghum as a biofuel feedstock: I. QTL for stem sugar and grain nonstructural carbohydrates. **Crop Science**, Madison, v. 48, n. 6, p. 2165-2179. Nov. 2008b.

NAGEL, K. A.; PUTZ, A.; GILMER, F.; HEINZ, K.; FISCHBACH, A.; PFEIFER, J.; SCHURR, U.; FAGET, M.; BLOSSFELD, S.; ERNST, M.; DIMAKI, C.; KASTENHOLZ, B.; Ann-KLEINERT, A.-K.; GALINSKI, A.; SCHARR, H.; FIORANI, F.; SCHURR, U. GROWSCREEN-Rhizo is a novel phenotyping robot enabling simultaneous measurements of root and shoot growth for plants grown in soil-filled rhizotrons. **Functional Plant Biology**, Victoria, v. 39, n. 11, p. 891-904. June, 2012

NEWCOMBE, R. A.; IZADI, S.; HILLIGES, O.; MOLYNEAUX, D.; KIM, D.; DAVISON, A. J.; KOHLI, P.; SHOTTON, J.; HODGES, S.; FITZGIBBON, A. KinectFusion: Real-time dense surface mapping and tracking. In: IEEE INTERNATIONAL SYMPOSIUM ON MIXED AND AUGMENTED REALITY, 10., 2011, Basel. **Proceedings**.... Piscataway: IEEE, 2011a. p. 127–136, 2011.

NEWCOMBE, R. A.; LOVEGROVE, S. J.; DAVISON, A. J. DTAM: dense tracking and mapping in real-time. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION, 2011, Barcelona. **Proceedings**... Piscataway,: IEEE, 2011b. p. 2320-2327. DOI:10.1109/ICCV.2011.6126513.

OSBORNE, B. G. Applications of near infrared spectroscopy in quality screening of early-generation material in cereal breeding programmes. **Journal of Near Infrared Spectroscopy**, Sussex, v. 14, n. 2, p. 93-101, 2006. DOI: 10.1255/ jnirs.595.

OSBORNE, S. L.; SCHEPERS, J. S.; FRANCIS, D. D.; SCHLEMMER, M. R. 2002a. Detection of phosphorus and nitrogen deficiencies in corn using spectral radiance measurements. **Agronomy Journal**, v. 94, n. 6, p.1215-1221, 2002a. DOI:10.1186/1471-2229-12-63.

OSBORNE, S. L.; SCHEPERS, J.S.; FRANCIS, D.D.; SCHLEMMER, M.R. Use of spectral radiance to estimate in-season biomass and grain yield in nitrogen- and water-stressed corn. **Crop science**, v. 42, n. 1, p.165-171, 2002b

PAPROKI, A.; SIRAULT, X.; BERRY, S.; FURBANK, R.; FRIPP, J. A novel mesh processing based technique for 3D plant analysis. **BMC Plant Biology**, Cambridge, v. 12, p. 63, May, 2012. DOI:10.1186/1471-2229-12-63.

PEARSON, T. C.; D. T. WICKLOW. Detection of corn kernels infected by fungi. Transactions of the Asabe, St. Joseph, v. 49, n. 4, p. 1235-1246, 2006.

PETERS, R. T.; EVETT, S. R. Spatial and emporal analysis of crop conditions using multiple canopy temperature maps created with center-pivot-mounted infrared thermometers. **Transactions Of The ASABE**, St. Joseph, v. 50, n. 3, p. 919-927, May/June, 2007. <Disponível em: http://naldc.nal.usda.gov/naldc/download.xhtml?id=2345&content=PDF>. Acesso em: 20 out. 2014.

PIZZOLI, M.; FORSTER, C.; SCARAMUZZA, D. Remode: probabilistic, monocular dense reconstruction in real time. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION, 2014, Hong Kong. Robotics and automation: technologies enabling new economic growth: proceedings. Hong Kong: University of Hong Kong, 2014. Não paginado.

POSS, J. A.; RUSSELL, W. B.; GRIEVE, C. M.. Estimating yields of salt- and water-stressed forages with remote sensing in the visible and near infrared. **Journal of Environmental Quality**, Madison, v. 35, n. 4, p. 1060-1071, May, 2006.

RAKOCEVIC, M.; SINOQUET, A.; VARLET-GRANCHER, C. Assessing the geometric structure of a white clover (*Trifolium repens* L.) canopy using3-D digitising. **Annals of Botany**, London, v. 86, n. 3, p. 519-526, July, 2000. DOI:10.1006/anbo.2000.120.

RASCHE, U.; BLOSSFELD, S.; FIORANI, F.; JAHNKE, S.; JANSEN, M.; KUHN, A. J.; KUHN, A. J.; MATSUBARA, S.; MÄRTIN, L. L. A.; MERCHANT, A.; METZNER, R.; MÜLLER-LINOW, M.; NAGEL, K. A.; PIERUSCHKA, R.; PINTO, F.; SCHREIBER, C. M.; TEMPERTON, V. M.; THORPE, M. R.; DUSSCHOTEN, D. van; VOLKENBURG, E. van; WINDT, C. W.; SCHURR, U. Non-invasive approaches for phenotyping of enhanced performance traits in bean. **Functional Plant Biology**, Victoria, v. 38, n. 12, p. 968-983, 2011.

REUZEAU, C.; FRANKARD, V.; HATZFELD, Y.; SANZ, A.; CAMP, W. van; LEJEUNE, P.; BROEKAERT, W.; WILDE, C.D.; LIEVENS, K.; VRANKEN, E.; PEERBOLTE, R.; BROEKAERT, W. TraitmillTM: a functional genomics platform for the phenotypic analysis of cereals. **Plant Genetic Resources**, Cambridge, v. 4, n. 1, p. 20-24, 2006.

ROLFE, S. A.; SCHOLES, J. D. Chlorophyll fluorescence imaging of plant-pathogen interactions. **Protoplasma**, New York, v. 247, n. 3-4, p. 163-75, Dec. 2010. DOI: 10.1007/s00709-010-0203-z.

ROMANO, G.; ZIA, S.; SPREER, W.; SANCHEZ, C.; CAIRNS, J.; ARAUS, J. L.; MÜLLER, J. Use of thermography for high throughput phenotyping of tropical maize adaptation in water stress. **Computers and Electronics in Agriculture**, v. 79, n. 1, p. 67-74, Oct. 2011. DOI: 10.1016/j.compag.2011.08.011.

ROVIRA-MÁS, F.; ZHANG, Q.; REID, J. Creation of Three-dimensional Crop Maps based on Aerial Stereoimages. **Biosystems Engineering**, London, v. 90, n. 3, p. 251-259, Mar. 2005. DOI: DOI:10.1016/j.biosystem-seng.2004.11.013.

SANTOS, T.; UEDA, J. Automatic 3D plant reconstruction from photographies, segmentation and classification of leaves and internodes using clustering 1. In: INTERNATIONAL CONFERENCE ON FUNCTIONAL-STRUCTURAL PLANT MODELS, 7., 2013, Saariselkä. **Proceedings...** Saariselkä: [s.n.], 2013. p. 95–97.

SANTOS, T. T.; OLIVEIRA, A. A. de. Image-based 3D digitizing for plant architecture analysis and phenotyping. In: WORKSHOP ON INDUSTRY APPLICATIONS; CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES, 25., 2012, Ouro Preto. **Proceedings**... Los Alamitos: IEEE Computer Society, 2012. Não paginado. SIBGRAPI 2012.

SANTOS, T. T.; KOENIGKAN, L. V.; BARBEDO, J. G. A.; RODRIGUES, G. C. 3D plant modeling: localization, mapping and segmentation for plant phenotyping using a single hand-held camera. In: EUROPEAN CONFERENCE ON COMPUTER VISION; WORKSHOP ONCOMPUTER VISION PROBLEMS IN PLANT PHENOTYPING, 2014, Zurich, 2014. Zurich. **Proceedings**...: Swiss Federal Institute of Technology, 2014. p. 1-18.

SINOQUET, H.; MOULIA, B.; BONHOMME, R. Estimating the three-dimensional geometry of a maize crop as an input of radiation models: comparison between three-dimensional digitizing and plant profiles. **Agricultural and Forest Meteorology**, Amsterdam, v. 55, n. 3-4, p. 233-249, June, 1991. DOI: 10.1016/0168-1923(91)90064-W.

SIRAULT, X.; FRIPP, J.; PAPROKI, A.; KUFFNER, P. C.; NGUYEN, C. V.; LI, R.; DAILY, H.; GUO, J.; FURBANK, R. PlantScan™: a three-dimensional phenotyping platform for capturing the structural dynamic of plant development and growth. In: INTERNATIONAL CONFERENCE ON FUNCTIONAL-STRUCTURAL PLANT MODELS, 7., 2013, Saariselkä. **Proceedings.**.. Saariselkä: [s.n.], 2013. p. 45-48.

SNAVELY, N.; SEITZ, S.; SZELISKI, R. Modeling the world from internet photo collections. International Journal of Computer Vision, Dordrecht, v. 80, n. 2, p. 189-210, Nov. 2008. DOI 10.1007/s11263-007-0107-3.

SONG, Y.; GLASBEY, C.; HEIJDEN, G. Van der; POLDER, G.; J.; DIELEMAN, A. Combining stereo and Time-of-Flight images with application to automatic plant phenotyping. In: SCANDINAVIAN CONFERENCE ON IMAGE ANALYSIS, 17., 2011, Ystad. **Proceedings**... Ystad Linköping University, 2011. v. 1, p. 467-478.

TALLADA, J. G.; PALACIOS-ROJAS, G. N.; ARMSTRONG, P. R. Prediction of maize seed attributes using a rapid single kernel near infrared instrument. **Journal of Cereal Science**, London, v. 50, n. 3, p. 381-387, Nov. 2009. DOI: 10.1016/j.jcs.2009.08.003.

VANKADAVATH, R. N.; HUSSAIN, A. J.; BODANAPU, R.; KHARSHIING, E.; BASHA, P. O.; GUPTA, S.; SREELAKSHMI, Y.; SHARMA, S. Computer aided data acquisition tool for high-throughput phenotyping of plant populations. **Plant Methods**, London, v. 5, p. 18, Dec. 2009. DOI:10.1186/1746-4811-5-18.

WALSH, K. B.; GUTHRIE, J. A.; BURNEY, J. W. Application of commercially available, low-cost, miniaturised NIR spectrometers to the assessment of the sugar content of intact fruit. **Australian Journal of Plant Physiology**, Melbourne, v. 27, n. 12, p.1175-1186, 2000.

WALTER, A.; SCHURR, U. Dynamics of leaf and root growth: endogenous control versus environmental impact. **Annals of Botany**, London, v. 95, n. 6, p. 891-900, 2005. DOI: 10.1093/aob/mci103.

WELLE, R.; GRETEN, W.; MÜLLER, T.; WEBER, G.; WEHRMANN, H. Application of near infrared spectroscopy on-combine in corn grain breeding. Journal of Near Infrared Spectroscopy, Sussex, v. 13, n.1, p. 69-76, 2005. DOI: 10.1255/jnirs.459.

WELLE, R.; GRETEN, W.; RIETMANN, B.; ALLEY, S.; SINNAEVE, G.; DARDENNE, P. Near-infrared spectroscopy on chopper to measure maize forage quality parameters online. **Crop Science**, Madison, v. 43, n. 4, p. 1407-1413, June, 2003. DOI: 10.2135/cropsci2003.1407.

WILLIAMS, P.; GELADI, P.; FOX, G.; MANLEY, M. Maize kernel hardness classification by near infrared (NIR) hyperspectral imaging and multivariate data analysis. **Analytica Chimica Acta**, Amsterdam, v. 653, n. 2, p.121-30, Oct. 2009.

WINTERHALTER, L.; MISTELE, B.; JAMPATONG, S.; SCHMIDHALTER, U. High-throughput sensing of aerial biomass and above-Ground nitrogen uptake in the vegetative stage of well-watered and drought stressed tropical maize hybrids. **Crop Science**, Madison, v. v. 51, n. 2, p. 479, 2007a. DOI: 10.2135/cropsci2010.07.0397.

WINTERHALTER, L.; MISTELE, B.; JAMPATONG, S.; SCHMIDHALTER, U. High throughput phenotyping of canopy water mass and canopy temperature in well-watered and drought stressed tropical maize hybrids in the vegetative stage. **European Journal of Agronomy**, v. 35, n. 1, p. 22-32, June, 2011b. DOI: 10.1016/j.eja.2011.03.004.

XU, H.; GOSSETT, N.; CHEN, B. Knowledge and heuristic-based modeling of laser-scanned trees. ACM Transactions on Graphics, New York, v. 26, n. 4, Oct. 2007. DOI: 10.1145/1289603.1289610.

100