



APRENDIZAGEM PROFUNDA NA IDENTIFICAÇÃO DE PLANTAS E LINHAS DE PLANTIO EM IMAGENS AÉREAS

Ana Paula Marques Ramos, Lucas Prado Osco, José Marcato Junior, Wesley Nunes Gonçalves

PROBLEMÁTICA

O mapeamento preciso de áreas de cultivo, por exemplo, para identificar a localização de plantas e linhas de plantio, é uma estratégia importante para a agricultura de precisão, pois auxilia em distintas tarefas relacionadas à cultura, como no gerenciamento das áreas plantadas, previsão de produtividade e monitoramento da cultura. Os sensores RGB, embarcados em Veículos Aéreos Não Tripulados (VANTs), também, popularmente conhecidos como Drones, são uma opção econômica viável para se capturar imagens dessas áreas agrícolas. Todavia, a análise visual dessas imagens pode ser uma tarefa desafiadora e tendenciosa, especificamente para se detectar plantas e linhas de plantio. Assim, tem-se a necessidade de se desenvolver métodos automáticos e inteligentes para realizar a tarefa de extração de informações de interesse nessas imagens de maneira rápida e precisa.

CONHECIMENTO PRÉVIO

Técnicas baseadas em inteligência artificial se constituem no que há de mais moderno para se processar imagens, como as coletadas por VANTs, visando se mapear ou monitorar campos agrícolas. A aprendizagem profunda (*deep learning*), uma subárea dentro da área de aprendizagem de máquina (*machine learning*), usa de redes neurais artificiais complexas para aprender a extrair padrões em um determinado tipo de dado, como são as imagens aéreas. Essas redes, todavia, requer uma quantidade considerável de exemplos para então aprender a desempenhar a tarefa requerida. Não obstante, uma vez aprendido, podem ser aplicadas em diversos contextos, atingindo excelentes desempenhos. Abordagens que visam auxiliar a agricultura de precisão, especificamente voltadas para a contagem de plantas ou extração de linhas de plantio com redes profundas, estão recebendo atenção da comunidade científica. Diferentes métodos baseados em Redes Neurais Convolucionais (CNN), que é um tipo de rede profunda, estão sendo investigados e foram publicados em periódicos científicos de alto impacto nos últimos anos. Alguns dos quais, são capazes de contar árvores, detectar e contar frutos, estimar biomassa, entre outros. No entanto, para o caso de plantas e linhas de plantio, nenhum desses métodos foi implementado de uma maneira que a aprendizagem ocorra simultaneamente.

DESCRIÇÃO DA PESQUISA

O estudo baseou-se na proposta de um novo método de aprendizado profundo baseado em uma CNN (Figura 1) que detecta e localiza simultaneamente as linhas de



plântio, enquanto conta as plantas presentes nestas linhas, utilizando imagens aéreas RGB coletadas por VANT. O método utiliza um tipo de arquitetura de dois “ramos”, onde as informações obtidas para as linhas de plântio são atualizadas no “ramo” de informação sobre a localização da planta e retroalimentadas no “ramo” da linha; tais ramos que são refinados por um método composto por vários estágios. Isso garante que a rede aprende informações das posições da planta e as incorpore na posição das linhas de plântio e vice-versa; aumentando a sua precisão para ambas as tarefas. Testes foram conduzidos em áreas experimentais com cultivo de milho, em diferentes estágios, e em área comercial de citricultura.

RESULTADOS E DISCUSSÃO

A rede extrai a localização da planta e da linha de plântio de acordo com um mapa de confiança e então usa essa informação para prever o centro da própria planta. Obteve-se nos testes desempenhos satisfatórios, sobretudo, quando comparando com outras redes neurais consideradas estado-da-arte para contagem de plantas e linhas de plântio em imagens aéreas em diferentes tipos de cultivos (Tabela 1). O método de refinamento na detecção da posição (centro) da planta também foi crucial para o alto desempenho da rede, sobretudo nas áreas de árvores citrus (Figura 2). Além disso, observa-se que o desempenho do método na detecção de plantas de milho em seu estágio inicial de crescimento também foi satisfatório visualmente (Figura 3). Essas informações qualitativas descritas permitiram comprovar a eficácia da rede proposta. Outras culturas além das investigadas podem se beneficiar da abordagem apresentada aqui, seja na contagem de plantas, bem como na detecção de linhas de plantação existentes.

APLICAÇÃO PRÁTICA

Este tipo de abordagem pesquisada pode auxiliar em novas pesquisas e aplicações que se baseiam na integração das áreas de sensoriamento remoto e agricultura de precisão. O método apresentado é viável e provou resultados altamente precisos, superiores aos resultados de outras redes profundas (HRNet, Faster R-CNN e RetinaNet) avaliadas para a mesma tarefa e no mesmo conjunto de dados. O método proposto também é uma alternativa viável do ponto de vista do custo, pois utiliza uma câmara RGB para capturar as imagens. Outra contribuição de nossa abordagem em CNN é que, ao aplicar uma arquitetura de duas ramificações e permitir a troca de informações entre elas, nossa abordagem pode se beneficiar dos resultados de uma detecção para a outra, caracterizando uma espécie de aprendizagem cíclica. A principal contribuição de nosso estudo é demonstrar uma alternativa rápida, segura e economicamente viável para prever corretamente o número real de plantas ao mesmo tempo em que se detecta linhas de plantação em imagens aéreas RGB.

AGRADECIMENTOS

CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico.

TABELAS E FIGURAS

TABELA 1. Resultados do método proposto e dos métodos de detecção de objetos HRNet, Faster R-CNN e RetinaNet para os conjuntos de dados de plantio de milho (V3 e adultos).

Métodos	Planta					Linha		
	Mean absolute error	Mean square error	Precision	Recall	F1-score	Precision	Recall	F1-score
HRNet	14,879	319,258	0,761	0,955	0,840	-	-	-
Faster R-CNN	17,245	392,754	0,736	0,952	0,825	-	-	-
RetinaNet	20,250	558,025	0,693	0,940	0,786	-	-	-
Abordagem Proposta	6,224	66,706	0,856	0,905	0,876	0,913	0,941	0,925

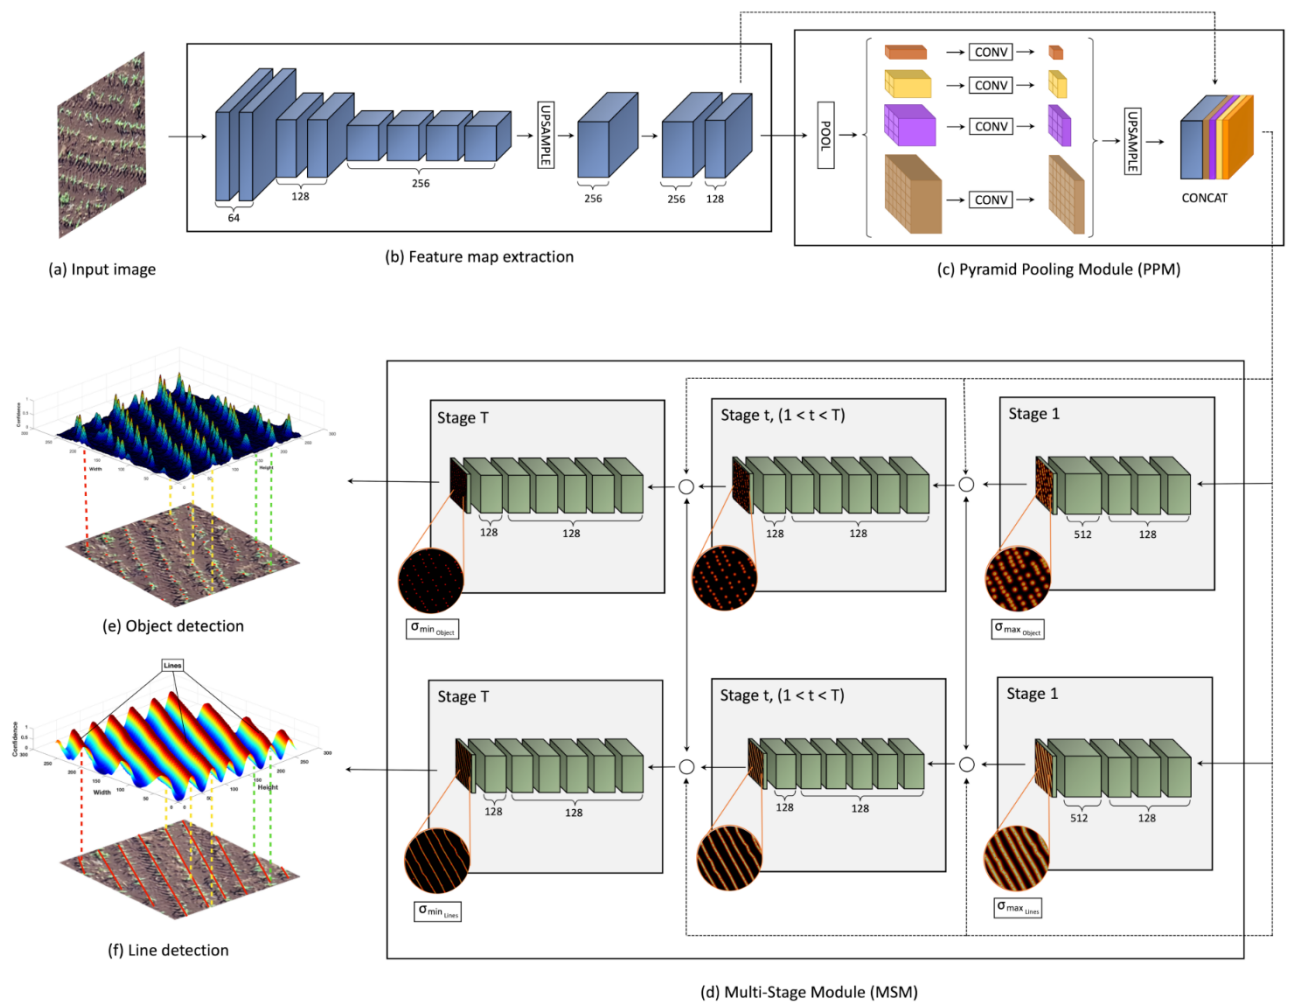


FIGURA 1. Arquitetura do método, onde: (a) corresponde à imagem RGB de entrada; (b) é o método de extração do mapa de recursos por uma CNN; (c) usa um módulo de aprimoramento PPM com o mapa de recursos como entrada; (d) é composto pelos dois ramos de detecção do MSM; e (e) realiza detecção de objetos (plantas) e (f) detecção de linha (linhas de plantação).

Dense citrus orchard plantation pattern

Object detection based on confidence map

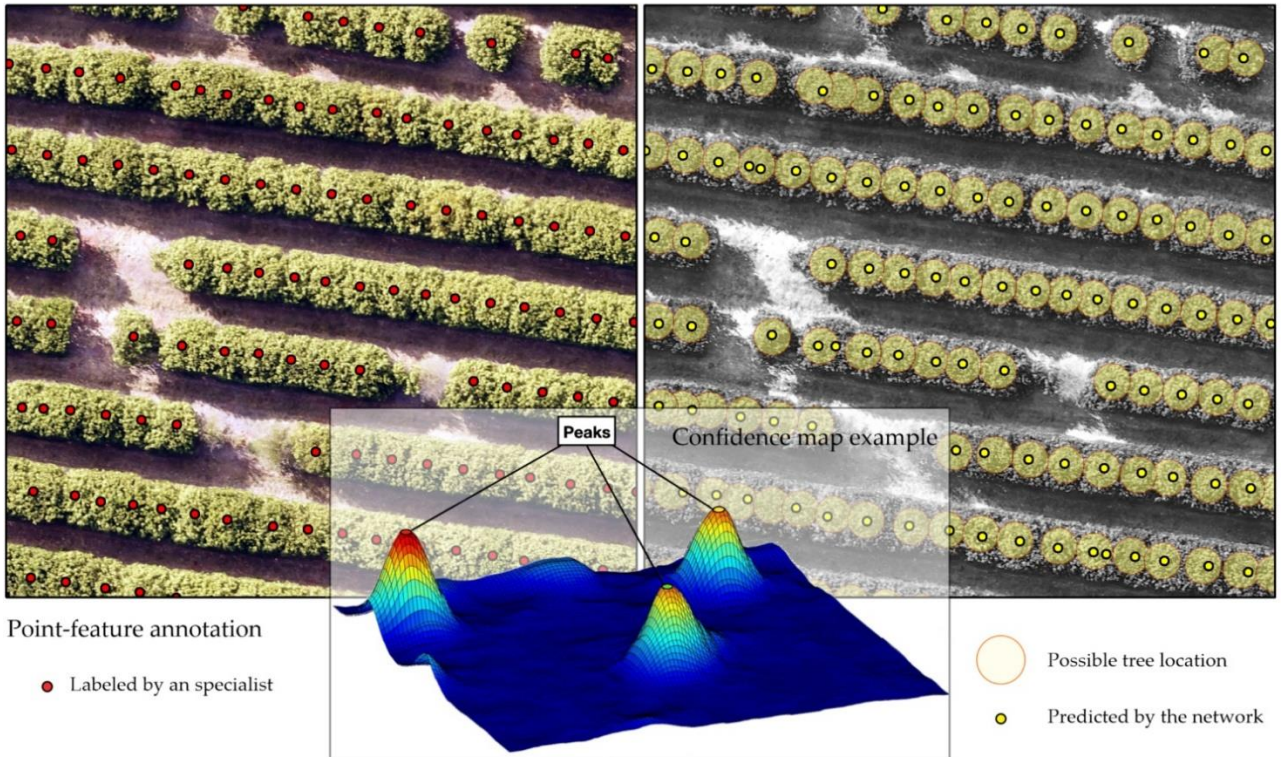


FIGURA 2. Exemplo dos resultados do método ao detectar árvores cítricas em uma plantação altamente adensada, isto é, com pequenos espaços entre as plantas. Há, também, um exemplo do mapa de confiança extraído com nossa rede para um conjunto de plantações. A rede profunda entende que os picos no mapa de confiança devem ser considerados possíveis localizações de plantas na imagem.



FIGURA 3. Exemplos de áreas nas imagens RGB exibindo as linhas de plantações e plantas de milho.