Design, development and validation of an intelligent system of a decision support system about irrigation water management in agriculture

Diseño, desarrollo y validación de un sistema inteligente de toma de decisiones en el manejo del agua de riego en agricultura

M. Forcén^{1*}, J.A. López², N. Pavón³, A. Pérez¹

- ¹Departamento de Ingeniería Agronómica, Escuela Técnica Superior de Ingeniería Agronómica, Universidad Politécnica de Cartagena. Paseo Alfonso XIII 48, 30203, Cartagena. Murcia. Spain
- ²Departamento de Tecnología Electrónica, Escuela Técnica Superior de Ingeniería Industrial, Universidad Politécnica de Cartagena. Campus Muralla del Mar, Calle Doctor Fleming S/N, 30203, Cartagena. Murcia. Spain
- ³Departamento de Automática, Ingeniería Eléctrica y Tecnología Electrónica, Escuela Técnica Superior de Ingeniería Industrial, Universidad Politécnica de Cartagena. Campus Muralla del Mar, Calle Doctor Fleming S/N, 30203, Cartagena. Murcia. Spain

Abstract

This document gives an overview of the state of the art of artificial intelligence applied to precision agriculture. In addition, it describes the proposed work schedule in order to achieve the one of the objectives related to the efficient water management in agriculture that are aimed within this PhD and shows some of the advances that are fulfilled until now.

Keywords: artificial intelligence; precision farming; computer vision.

Resumen

Este documento muestra una visión general del estado del arte de la inteligencia artificial aplicada a la agricultura de precisión. Además, describe el plan de trabajo propuesto para conseguir uno de los objetivos relacionados con el manejo eficiente del agua en la agricultura que pretenden ser abordados en la tesis doctoral y muestra algunos de los avances conseguidos hasta ahora.

Palabras clave: inteligencia artificial; agricultura de precisión; visión artificial.

1. INTRODUCCIÓN

La agricultura es el mayor consumidor de agua, con alrededor del 70% del agua utilizada para el riego. También es considerada una fuente clave de contaminación difusa por la aplicación de nutrientes de forma ineficiente.

Para ser más eficientes, se ha intentado llevar técnicas como el análisis de datos y la inteligencia artificial al campo de la agricultura de precisión.

A lo largo de los años, diversos estudios han intentado aplicar distintas técnicas para mejorar algunos aspectos de los cultivos. Algunos de los trabajos más destacados son los

^{*}manuel.forcen@edu.upct.es

destinados a predecir [1], [2], a detectar [3], [4] y a ayudar en la toma de decisiones ofreciendo información que de otra manera sería costosa [5] y menos sostenible.

Cabe destacar que en los últimos años se ha visto un incremento en la cantidad de artículos y trabajos que han sido desarrollados utilizando un enfoque basado en la inteligencia artificial aplicada a agricultura de precisión, especialmente en redes neuronales artificiales, tal y como se muestra en el estudio de Kamilaris y Prenafeta-Boldú [6]. Esto es un indicativo de que se utilizan cada vez de manera más generalizada técnicas de macrodatos, análisis automático e inteligencia artificial.

Sin embargo, el aspecto sobre el que más hincapié se va a hacer a lo largo de esta tesis doctoral será cómo se usan los sistemas aéreos autónomos (drones) para extraer información útil para su análisis y su posterior uso a la hora de realizar predicciones de productividad o requerimientos hídricos y de abono, tal y como se muestra en el trabajo de Martín Abadi [7].

Algunas de las técnicas empleadas consisten en el uso de cámaras hiperespectrales y multiespectrales, con las que se consiguen obtener la cantidad de luz reflejada por las plantas en longitudes de onda distintas a la de la luz visible, con lo que se puede extraer información útil. También se utilizan cámaras térmicas para obtener valores como la temperatura de la canopia, o cámaras de luz visible para realizar inspección visual.

Por último, cabe destacar que la aplicación de técnicas de inteligencia artificial es capaz de dar un segundo significado a las clásicas imágenes de luz visible, con lo que es interesante revisar qué información es capaz de extraer un sistema de aprendizaje automático a partir de sistemas de obtención de datos tradicionales.

Como parte de este trabajo, se ha desarrollado una técnica que permite utilizar una cámara clásica para realizar una estimación de la carga productiva en un cultivo de cítricos en condiciones de campo.

2. MATERIALES Y MÉTODOS

El proceso seguido para el desarrollo de la técnica se detalla a continuación, indicando todos los pasos

2.1 Conjunto de datos

Es la base de las redes neuronales. Permite que la misma arquitectura matemática se especialice en las tareas que se requiere. Para la particularización de esta red neuronal se utilizaron fotografías de limoneros de la Vía Verde del Noroeste (38°02'22.0"N 1°28'04.6"O).

2.2 Preprocesado, clasificación y aumentado de datos

Para la clasificación, se dividen las imágenes tomadas en teselas, que se clasifican manualmente. El tratamiento de imágenes se realiza usando el lenguaje de programación *Python*. Una vez clasificadas estas, se le aplican operaciones de tratamiento de imágenes, como rotaciones, simetrías entre otros.

2.3 Métodos

Se utiliza la librería *TensorFlow* [8], que facilita la implementación matemática de la red neuronal. Tanto para el entrenamiento como para la predicción, se utiliza la aceleración de cálculos mediante el uso de GPU ofrecido por *TensorFlow* sobre *CUDA*, para tarjetas gráficas *Nvidia*. En la Figura 1 se puede observar un esquema de la estructura utilizada.

3. RESULTADOS Y DISCUSIÓN

En la figura 2 se puede observar cómo evoluciona la precisión de la red neuronal para predecir la existencia de fruto en las imágenes. En el eje de abscisas se muestra el número de procesos de entrenamiento que se han realizado, mientras que en el eje de ordenadas se representa la precisión que se obtuvo al ejecutar la predicción con un conjunto de datos de prueba. Se puede ver que al final ronda el 90%, con lo que se puede deducir que, aunque tiene un cierto margen de mejora, se ha conseguido utilizar dicho modelo de manera exitosa para estimar la carga frutal del árbol con dispositivos de bajo coste.

En la figura 3 se puede observar un ejemplo de detección de fruto. Las teselas que se detectan como parte de un fruto se pueden observar como tintadas en rojo.

4. CONCLUSIONES

Existen una gran cantidad distinta de técnicas utilizadas para reconocer objetos de manera automática en una imagen, pero con este trabajo se demuestra que se pueden aplicar técnicas de aprendizaje automático a algunos aspectos de la investigación agronómica.

5. AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Investigación e Innovación del Gobierno de España (PCIN-2017-091, WaterWorks2015 ERA-NET) y Manuel Forcen agradece la financiación del contrato predoctoral recibida de la Fundación Séneca (20767/FPI/18).

6. REFERENCIAS

- [1] Kuwata, K., Shibasaki, R. 2015.. 2015 IEEE Geosci. Remote S. 858-861.
- [2] Sharpley, A. N., Smith, S. J., Aruja L.R. 1988. Prediction of Soluble Phosphorus Transport in Agricultural Runoff. Agr. Water. Manage. 15: 37-46.
- [3] Zhao, Y., Ma, J., Li, X., Zhang, J., 2018. Saliency Detection and Deep Learning-Based Wildfire Identification in UAV Imagery. Ah. S. Sens. 18: 3.
- [4] Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., Stefanovic, D., 2016. Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. Comput. Intel. Neurosc. 2016: ID-3289801.
- [5] Rahnemoonfar, M., Sheppard, C., 2017. Deep Count: Fruit Counting Based on Deep Simulated Learning. Ah. S. Sens. 17: 905.
- [6] Kamilaris, A., Prenafeta-Boldú, F. X. 2018. Deep learning in agriculture: A survey, Comput. Electron. Agric. 147: 70-90
- [7] Ezenne, G. I., Jupp, L., Mantel, S. K., Tanner, J. L. 2019. Agric. Water Manag. 218: 158-164.
- [8] Abadi, M., 2015. TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems.




Figura 1. Estructura de la red neuronal convolucional.




Figura 2. Gráfica de la precisión de la red neuronal durante el proceso de entrenamiento.



Figura 3. Predicción de la presencia de fruto en una fotografía. Lo clasificado como fruto está tintado en rojo