

## Designing and developing of computer-based techniques for helping agronomical research and precision farming

## Diseño y desarrollo de técnicas basadas en ordenador para ayudar en la investigación agronómica y en la agricultura de precisión

M. Forcen<sup>1\*</sup>, N. Pavon<sup>2</sup>, J.A López<sup>2</sup>, A. Pérez<sup>1</sup>

<sup>1</sup>Departamento de Ingeniería Agronómica, ETSIA, Universidad Politécnica de Cartagena (UPCT), Paseo Alfonso XIII, 48, 30203 Cartagena. Spain.

<sup>2</sup>Departamento de Automática, Ingeniería Eléctrica y Tecnología Electrónica, ETSII, UPCT, Campus Muralla del Mar, C/ Doctor Fleming s/n, 30203 Cartagena. Spain.

\*manuel.forcen@edu.upct.es

### **Abstract**

**This document shows a detailed explanation about a new machine learning-based technique which allows a computer to detect automatically the phenological stage of a citrus crop tree from a picture taken using a standard camera. This will help autonomous systems to determine when deficit irrigation could be applied.**

**Keywords:** artificial intelligence; computer vision; wireless sensor networks; irrigation decision support systems.

### **Resumen**

**Este documento muestra una explicación detallada acerca de una nueva técnica, basada en *machine learning*, que permite a un ordenador detectar de forma automática la fase fenológica de un árbol de un cultivo de cítricos usando una cámara estándar. Esta técnica ayudará en la aplicación automática de técnicas de riego deficitario.**

**Palabras clave:** inteligencia artificial; visión por computador; redes inalámbricas de sensores; sistema de soporte de decisión de riego.

## **1. INTRODUCCIÓN**

La agricultura consume una gran cantidad de agua. Concretamente se utiliza un 70 % en tareas relacionadas con el riego de los cultivos. También se considera una fuente clave de contaminación difusa por la aplicación de nutrientes de forma ineficiente.

Con los nuevos retos que presenta el cambio climático relativos a la disminución de los recursos hídricos (1), es importante que se desarrollen técnicas y dispositivos que permitan realizar aplicaciones eficientes de dichos recursos para asegurar la disponibilidad del alimento.

En la actualidad existen diversas técnicas que permiten reducir el volumen de agua aplicada a los cultivos. En concreto, algunos de esos métodos consisten en controlar la humedad del suelo para evitar lixiviados, mientras que otros están enfocados en el aprovechamiento del conocimiento sobre el cultivo para restringir la aplicación de agua cuando ésta es menos productiva (2).

Según lo anterior, se ha desarrollado una técnica de bajo coste que facilita la detección automática de la fase fenológica del cultivo, usando una cámara estándar de uso común. Esto

permitiría la automatización del proceso de extracción de información relevante a partir de la cual es posible determinar el estado de dicho cultivo, para, posteriormente, utilizarla como entrada en sistemas automáticos de riego.

Por último, se también se destacan algunos avances en materia de dispositivos que facilitarían el proceso de instalación de sensores con un coste muy inferior a las alternativas tradicionales.

## 2. MATERIALES Y MÉTODOS

El proceso seguido para desarrollar la técnica propuesta se detalla en las secciones siguientes. Cada una de ellas se refiere a un paso concreto de dicho proceso.

### 2.1 Conjunto de datos

Se han tomado diversas imágenes a lo largo del ciclo de cultivo de un campo de mandarinos. Un ejemplo de estas imágenes se muestra en la Fig. 1.

Los datos de la etapa fenológica para el entrenamiento de la red neuronal en la que se basa el sistema se han extraído de forma manual, atendiendo a los criterios de la escala BBCH adaptada a cítricos (3).

### 2.2 Preprocesado de datos

Para evitar la inclusión de zonas de la imagen poco relevantes para el algoritmo, las imágenes se han dividido en 24 partes rectangulares y se ha despreciado el borde exterior, de forma que sólo los centros de las imágenes han formado parte del conjunto de datos de entrenamiento. Posteriormente, estas imágenes se han escalado a un tamaño de 256 píxeles de ancho por 256 píxeles de alto.

### 2.3 Métodos

Para llevar a cabo el diseño de la arquitectura y los procesos de entrenamiento y validación de la red neuronal, se ha utilizado la biblioteca *Tensorflow* (4), que permite simplificar el desarrollo matemático y computacional. En concreto, se ha desarrollado una red neuronal convolucional que admite una imagen de 256 por 256 píxeles como entrada. La estructura de la red de la que se parte para hacer los experimentos se muestra en la Fig. 2. A partir de la imagen de entrada, la red infiere un valor en el intervalo  $[0,1] \in \mathbb{R}$ , correspondiente al estado fenológico del fruto, donde 1 se corresponde con que el fruto está listo para su recolección. Por tanto, se trata de un problema de regresión.

En la fase de entrenamiento, se ha utilizado el algoritmo de optimización *Adam* (5). En concreto, el valor que se usa para optimizar la salida de la red neuronal es el error cuadrático medio. El conjunto de imágenes adquiridas se ha dividido en un conjunto de entrenamiento, disponible durante la fase del entrenamiento de la red, y un conjunto no presentado a dicha red durante dicha etapa, denominado conjunto de validación.

## 3. RESULTADOS Y DISCUSIÓN

Para seleccionar el algoritmo definitivo, se ha realizado dos experimentos. En el primero se analiza la importancia del número de neuronas en una única capa, mientras que en el segundo se comparan redes con distintas estructuras, añadiendo una segunda capa y modificando los tamaños de la primera.

En el primer experimento se ha variado el número de neuronas en las capas ocultas para ver cuál es el requerimiento mínimo para obtener una precisión adecuada. Tal y como se puede

ver en la Fig. 3, hay un valor mínimo de neuronas requeridas para obtener un valor aceptable de precisión, pero se puede ver que hay un punto en el que no mejora la precisión.

El segundo experimento consiste en analizar la importancia del número de las capas convolucionales y sus parámetros. Para ello se varía la estructura de la red neuronal para obtener los distintos resultados. Estos datos se muestran en la Tabla 1.

Finalmente, se puede observar que los mejores resultados se obtienen con la configuración de dos capas. Esto conlleva una mayor cantidad de cálculos, pero los errores obtenidos son muy pequeños, con lo que la precisión de la predicción es alta.

#### 4. CONCLUSIONES

Este trabajo demuestra la fiabilidad de usar técnicas basadas en *Machine learning* y *Deep learning* para extraer características de las plantas a partir de imágenes. Las arquitecturas desarrolladas en este trabajo serán un punto de partida útil para otros proyectos que se basen en estas técnicas.

Finalmente, se han analizado y comparado distintas arquitecturas de redes neuronales para definir cuáles son los requerimientos estructurales mínimos para obtener resultados precisos.

#### 5. TRABAJOS FUTUROS

Además del algoritmo detallado en este trabajo, se están desarrollando dispositivos que permitan realizar la sensorización de suelos, de forma que se pueda optimizar el riego obteniendo información del estado del suelo y del ambiente.

Para ello, se está desarrollando una plataforma que consiste en un registrador de datos de bajo coste al que se le conecten diversos sensores. Los datos se guardan internamente de manera local y posteriormente se descargan en un ordenador. Además, se está dotando de conectividad inalámbrica de largo alcance para poder conectar directamente con servidores de Internet.

#### 6. 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 recibido de la Fundación Séneca (20767/FPI/18).


#### 7. REFERENCIAS

1. Misra AK. Climate change and challenges of water and food security. *Int J Sustain Built Environ*. 2014;3(1):153-65.
2. Conesa MR, Rosa JM de la, Artés-Hernández F, Dodd IC, Domingo R, Pérez-Pastor A. Long-term impact of deficit irrigation on the physical quality of berries in 'Crimson Seedless' table grapes. *J Sci Food Agric*. 2015;95(12):2510-20.
3. Agustí M, Zaragoza S, Bleiholder H, Buhr L, Hack H, Klose R, et al. The BBCH scale for describing phenological stages in citrus development. En: *International congress of citriculture*. 2002;445-6.
4. Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems [Internet]. 2015. Disponible en: <https://www.tensorflow.org/>


5. Kingma DP, Ba J. Adam: A Method for Stochastic Optimization. Int Conf Learn Represent. 22 de diciembre de 2014.



**Figura 1.** Ejemplo de imagen capturada incluida en los conjuntos de entrenamiento o validación.



**Figura 2.** Estructura de la red neuronal diseñada para resolver el problema de regresión planteado.



**Figura 3.** Error final obtenido en función del número de neuronas ocultas seleccionado.

**Tabla 1.** Comparativa entre estructuras de la red neuronal.

<b>Capas convolucionales</b>	1	1	2
<b>Filtros convolucionales</b>	10	10	10→15
<b>Tamaño de filtros</b>	4	8	4→5
<b>Media del error</b>	0,1111	0,0396	0,0137
<b>Varianza del error</b>	0,0054	0,0025	0,0000