

Machine learning for leaf segmentation in NIR images based on wavelet transform.

Aprendizaje automatizado basado en transformadas wavelet para la segmentación de hojas en imágenes infrarrojas.

F. Pérez-Sanz^{1*}, P.J. Navarro², M. Egea-Cortines¹, J.Weiss¹

¹Genética. Instituto de Biología Vegetal. Universidad Politécnica de Cartagena. Cartagena (30202) Spain.

²División de Sistemas e Ingeniería Electrónica. Universidad Politécnica de Cartagena. Cartagena (30202) Spain.

*fernando.perez8@um.es

Abstract

In this work we present an algorithm to segment leaves in NIR images captured inside a growth chamber. The proposed method uses a features vector composed by four elements extracted from different levels of wavelets transform. We have tested three classifiers: k-nearest neighbour (kNN), Naive Bayes classifier (NBC) and Support Vector Machine to determine the optimal machine learning algorithm to carry out the leaf segmentation. Method developed has been validated by means of the Receiver Operating Characteristic (ROC) curve and it has obtained a maximum performance of 98.33% in the leaf segmentation using SVM classifier.

Keywords: Image processing; leaf detection; plant phenotyping.

Resumen

En este trabajo se presenta un algoritmo de segmentación basado en máquinas de aprendizaje para la segmentación de hojas sobre imágenes NIR (Near-Infra-Red). El método de segmentación utiliza un vector de características extraído de diferentes niveles de la transformada wavelet. Para el desarrollo del algoritmo se han probado tres clasificadores: el vecino más cercano (KNN), un clasificador Bayesiano (NBC) y las máquinas de soporte compacto (SVM). Los métodos de aprendizaje han sido validados mediante el análisis de las curvas ROC y el máximo rendimiento fue obtenido por la SVM con un 98.33%.

Palabras clave: Procesamiento de imagen; detección de hoja; fenotipado de plantas.

1. INTRODUCCIÓN

La segmentación de hojas de plantas es un punto clave en el fenotipado de plantas basado en visión artificial. La mayor parte de trabajos en este campo se centran en la detección de la masa vegetal completa más que de la hoja a nivel individual. Sin embargo, aplicar un algoritmo de visión en este campo no es algo trivial debido a dificultades como: (1) fondos de imagen no uniformes, (2) solapamiento de órganos, (3) similitud entre órgano y fondo y (4) cambios en la posición de los órganos respecto a la cámara. Rousseau et al [1] utilizaron el análisis multiescala de Fourier 2D sin ningún requisito para segmentar y detectar y contar hojas una a una. Aplicaron un algoritmo de clasificación supervisada capaz de contar las hojas desde 2 hasta 6 en las primeras etapas de crecimiento de la plántula desde una posición cenital. Cai et al [2] propusieron una novedosa técnica de segmentación de hojas basada en aprendizaje automatizado. Para obtener la

segmentación de los objetos, el algoritmo propuesto utiliza la diferencia entre imágenes para hacer una estimación inicial del fondo. Posteriormente mediante aprendizaje automatizado y técnicas de reconocimiento de patrones se refina la estimación. Los resultados experimentales han mostrado que este algoritmo, puede alcanzar un desempeño prometedor en términos de precisión y velocidad. Finalmente, Noble et al [3] presentaron un trabajo dirigido a la segmentación de las plantas de pepino mediante imágenes multiespectrales. Los resultados concluyeron que la calidad de la luz tiene un impacto determinante en la calidad de la segmentación y que la banda de absorción de agua (970 nm) era generalmente la más efectiva para segmentar el fruto de la planta.

2. MATERIALES Y MÉTODOS

Para llevar a cabo el este trabajo, se ha capturado un conjunto de imágenes en el interior de una cámara de crecimiento configurable basada en visión artificial. La cámara se ha desarrollado pensando en análisis fenotípico relacionado con el ritmo circadiano [4-5] y está compuesta por tres subsistemas principales: (1) subsistema de iluminación, (2) subsistema de captura y (3) subsistema de procesamiento de imágenes. La modularidad del sistema permite múltiples configuraciones orientado a obtener grandes cantidades de imágenes para el análisis fenotípico. El sistema permite entre otras cosas: capturar imágenes con diferentes intervalos de disparo, tomar imágenes durante el día y durante la noche sin tener que iluminar en la fase nocturna, definir la duración del día y de la noche, y emplear diferentes tipos de cámaras.

El estudio presentado en este trabajo ha consistido en la medida de parámetros de crecimiento durante el periodo nocturno de dos tipos de especímenes de *Antirrhinum* (*A. majus* y *A. majus ssp. Linkianum*). Las imágenes se obtuvieron con una cámara multiespectral JAI AD-080GE. Las imágenes han sido capturadas en el periodo nocturno con el sensor CCD NIR de la cámara, aplicando una iluminación LED en el infrarrojo cercano (NIR) a 890 nm por un periodo de 3 sg. durante la captura de la imagen. Esto es así porque largas exposiciones a la luz infrarroja puede afectar al desarrollo de la planta.

Para el experimento, la cámara se ha configurado en ciclos de 12/12h (día/noche) con imágenes capturadas cada 10 min. Durante 13 días. El número de imágenes NIR obtenidas ha sido por tanto de 6 imágenes/hora*12 horas/día*13 días = 936 imágenes de tamaño 1296x964 píxeles en escala de grises. La figura 1 (a) y (b) muestran dos imágenes capturadas durante el experimento.

La enorme cantidad de datos hace imposible la segmentación manual de las imágenes, por ello hemos diseñado un algoritmo basado en técnicas de aprendizaje automatizado para clasificar los objetos en dos clases: hoja y fondo. El algoritmo se ha dividido en 3 etapas:

(1) *Extraer regiones* de imágenes representativas de las diferentes clases y obtener un vector de características. Para ello se han seleccionado 150 regiones de 32x32 píxeles de cada clase. Esas 300 imágenes se han utilizado como conjunto de entrenamiento. Después se ha obtenido un vector de características basado en transformadas de wavelet con base de Haar. El vector de características está formado por 4 parámetros: máximo, mínimo, media y entropía de Shannon de los coeficientes de wavelet calculados para las subbandas horizontal, vertical y diagonal a dos niveles de descomposición.

(2) El *proceso de entrenamiento* se ha realizado con tres clasificadores: k vecinos más cercanos (kNN), un clasificador bayesiano (Nbc) y una máquina de soporte de vectores (SVM).

(3) *Proceso de segmentación*. En esta etapa el algoritmo se van extrayendo regiones de 32x32 píxeles de la imagen a segmentar, las regiones se van desplazando a lo largo de la imagen con solapamiento de píxeles (ventaneo). Para cada desplazamiento, se calculan los parámetros

wavelet tal como se hizo con las regiones de entrenamiento. A continuación los diferentes clasificadores deciden a qué clase asignan esa subregión de la imágenes (hoja o fondo). Finalmente se aplica un filtro de área para eliminar objetos demasiado pequeños (eliminar ruido). Las figuras 1 (c) y (d) muestran los resultados de la segmentación con el clasificador SVM.

3. RESULTADOS Y DISCUSIÓN

Hemos evaluado los resultados de implementar 3 clasificadores kNN, Nbc y SVM con el método de validación cruzada Leave-one-out cross-validation (LOOCV). El desempeño de los algoritmos de aprendizaje automatizado son normalmente evaluados mediante curvas ROC. Estas curvas son una representación gráfica de ratio de verdaderos positivos (sensibilidad) frente al ratio de falsos positivos (1 – especificidad) para diferentes puntos de corte. El área bajo la curva (AUC) suele utilizarse como medida de la calidad del clasificador y puede interpretarse como la probabilidad de que habiendo detectado un positivo, realmente sea un verdadero positivo. Los resultados de la evaluación de los 3 clasificadores puede verse resumida en la tabla 1, donde se puede observar que SVM y Naive Bayes han producido los mejores resultados con una precisión (AUC) del 98,33% y el 98,00% respectivamente.

4. CONCLUSIONES

En este trabajo hemos desarrollado un método para la segmentación de hojas basado en algoritmos de aprendizaje automatizado. Los métodos propuestos utilizan vectores de características calculados sobre transformadas wavelet. Hemos evaluado 3 algoritmos de aprendizaje diferentes: los k vecinos más próximos (kNN), el clasificador Naive Bayes (Nbc) y la máquina de soporte de vectores (SVM). La mejor clasificación la hemos obtenido con SVM con una eficacia superior al 98%. En un futuro, continuaremos trabajando en aspectos como la búsqueda de nuevos vectores de características que produzcan mejores resultados, reducción del tiempo de cálculo en el ventaneo y la implementación de los algoritmos en C o C++.

5. AGRADECIMIENTOS

Este trabajo ha sido parcialmente soportado por el Ministerio de Economía y Competitividad (MINECO) bajo los proyectos ViSelTR (TIN2012-39279) y cDrone (TIN2013-45920-R).

6. REFERENCIAS

- [1] Rousseau, D. 2015. Counting leaves without “finger-counting” by supervised multiscale frequency analysis of depth images from top view. *Proceedings of the Computer Vision Problems in Plant Phenotyping (CVPPP)*. (2015), 1–9. DOI:<https://doi.org/10.5244/C.29.CVPPP.2>.
- [2] Cai, J. 2011. Novel Image Segmentation Based on Machine Learning and Its Application to Plant Analysis. *IJIEE*. (2011). DOI:<https://doi.org/10.7763/IJIEE.2011.V1.12>.
- [3] Noble, S.D. and Li, D. 2012. Segmentation of Greenhouse Cucumber Plants in Multi-Spectral Imagery. *Proceedings of the International Conference of Agricultural Engineering* (Valencia, Spain, 2012).
- [4] Navarro, P.J. et al. 2012. Development of a configurable growth chamber with a computer vision system to study circadian rhythm in plants. *Sensors (Switzerland)*. 12, 11 (2012), 15356–15375. DOI:<https://doi.org/10.3390/s121115356>.
- [5] Navarro, P.J. et al. 2016. Machine Learning and Computer Vision System for Phenotype Data Acquisition and Analysis in Plants. *Sensors (Basel, Switzerland)*. 16, 5 (Jan. 2016), 641. DOI:<https://doi.org/10.3390/s16050641>.

Tabla 1: Eficacia de los clasificadores

| Clasificador | kNN | Naive Bayes | SVM |
|--------------|--------|-------------|--------|
| AUC | 96,67% | 98,00% | 98,33% |




Figura 1: (a),(b) Imágenes NIR capturadas en la cámara de crecimiento; (c),(d) resultados.

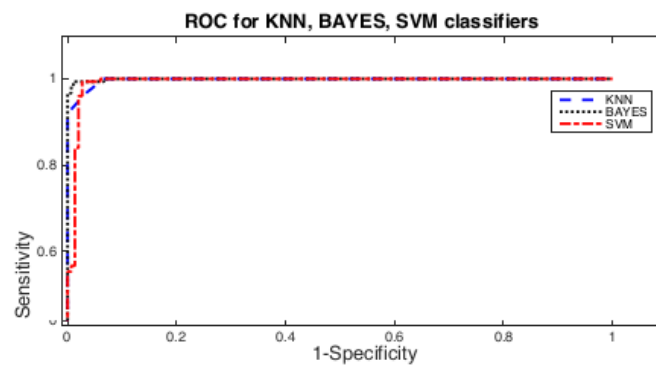


Figura 2: Curvas ROC para kNN, Naive Bayes y SVM.