

TAXONOMÍA DE HOJAS DE IMÁGENES FOLIARES, USANDO UNA RED NEURONAL MLP

Miguel Ángel Torres, Juan Carlos Briceño,
Miguel A. Ferrer Ballester

Departamento de Señales y Comunicaciones
Universidad de Las Palmas de Gran Canaria
mferrer@dsc.ulpgc.es

Itziar Alonso González

Departamento de Ingeniería Telemática
Universidad de Las Palmas de Gran Canaria
ialonso@dit.ulpgc.es

RESUMEN

This paper presents a taxonomy paradigm for canary tree leaves images with a general multilayer perceptron neural network architecture. Some biological parameters that seems to work well and topics of image processing, for the acquisition of such parameters, are exposed. This parameters are used by MLP in classification task.

1. INTRODUCCIÓN

Los biólogos suelen identificar los árboles a partir de unas claves que recogen descripciones de: las hojas, las ramitas, la corteza, la madera, las flores, frutos, semillas y plantas jóvenes.

En este artículo presentamos las primeras pruebas de la identificación de árboles a partir de sus hojas. El problema de la taxonomía de imágenes de hojas simples se ha restringido a la Laurisilva canaria y Fayal-Brezal, específicamente a 16 de los 26 árboles o arbustos endémicos: *acebiño*, *barbusano*, *delfino*, *faya*, *follado*, *hija*, *laurel*, *mocán*, *naranja salvaje*, *olivillo*, *palo blanco*, *sacatero*, *sanguino*, *sauce canario*, *tilo* y *viñático*.

La clasificación automática de especies vegetales por medio exclusivo de sus hojas, presenta el problema añadido del procesamiento de la información con la finalidad de extraer los parámetros más relevantes de la hoja. Una vez obtenidos los parámetros se pasan al clasificador.

Este artículo lo presentamos de la siguiente manera: en la primera sección presentamos la fase de pre-procesado, en la segunda sección presentamos las primeras pruebas utilizando redes neuronales MLP al problema de la taxonomía de imágenes foliares. Continuamos comentando la base de datos y resultados y finalizaremos con las conclusiones y las líneas de trabajo futuras.

2. ADQUISICIÓN DE IMÁGENES

Las imágenes fueron obtenidas por escáner de hojas previamente secadas y prensadas, en tonalidades de grises (300 dpi). Consideraciones de tonalidad (oscuro/claro) o de contraste en la determinación de la presencia de glándulas o nervaduras se efectuaron mediante filtrado adaptativo en intensidad usando histograma. Todas las medidas se consideraron en píxeles, escaladas en [0,1]. El suavizado de la imagen se obtuvo por

filtrado adaptativo de Wiener y eliminación de ruido por filtrado paso alto.

3. PARAMETRIZACIÓN

La hoja se divide en zonas atendiendo a su morfología: peciolo, cuerpo y ápice [1] y [2]. A partir de estas zonas se extraen distintos parámetros.




Figura 1. Partes de una hoja.

Los parámetros extraídos son:

1. Zona cuerpo: lóbulos, largo, ancho, color (claro/oscuro), número de nervios, color de nervadura (claro/oscuro), presencia glandular, escala.
2. Zona ápice: ángulo.
3. Peciolo: Largo, ancho, base (existencia/ausencia) y rugosidad.

La presencia o ausencia de una característica al igual que parámetros calificados de claro/oscuro se codificaron mediante $\{0,1\}$.

El número de veces que se presenta una característica se obtiene por conteo de su localización y determinación. La medida de los ángulos se consideró en grados.

El parámetro de rugosidad se obtiene por un proceso esquematizado: la proyección de contorno de un borde a otro, obteniéndose una línea con variaciones perpendiculares a la trayectoria de propagación y proporcional a la variación del borde seguido; realizándose un estudio estadístico de su evolución. El número de lóbulos se obtuvo por conteo de máximos y mínimos

sobre el borde luego de hacer una transformación de Radon [6] sobre el eje de 90°.

Finalmente se obtuvieron 13 parámetros biológicos de caracterización de especies.

4. CLASIFICADOR MLP

Como primeras pruebas de clasificación se ha utilizado una red neuronal Multilayer Perceptron (MLP), entrenada con el algoritmo de *backpropagation*. Se realizaron varios experimentos:

1. Red neuronal de 2 capas, ver figura 1.
2. Red neuronal de 3 capas, ver figura 1.
3. Conjunto de varias redes neuronales con selección de la clase más votada, ver figura 2.




Figura 1. Experimento con una única red neuronal.




Figura 2. Modelo del más votado (voting model).

Para el experimento 1 se trabajó con una estructura de red de 2 capas: la capa de entrada con los 13 parámetros de entrada, una capa oculta con 26 nodos y la capa de salida con 16 nodos, (un nodo por clase).

El experimento 2 se realizó con una red neuronal de 3 capas: la capa de entrada con 13 nodos, 2 capas ocultas de 10 y 30 nodos y la capa oculta con 16 nodos (una por clase).

La estructura de las redes neuronales de los experimentos fueron obtenidas a base de prueba y error.

El experimento 3, se trabajó con redes entrenadas obtenidas de los experimentos 1 y 2.

4. BASE DE DATOS Y RESULTADOS

La base de datos está formada por la laurisilva canaria y Fayal-Brezal, específicamente se ha trabajado con 16 de los 26 árboles o arbustos endémicos: *acebiño, barbusano, delfino, faya, follado, hija, laurel, mocán, naranjo salvaje, olivillo, palo blanco, sacatero, sanguino, sauce canario, tilo y viñático*.

De cada árbol se han recogido 75 hojas, en épocas distintas del año, lo que hace un total de 1200 hojas a digitalizar.

Los resultados se presentan en la tabla 2, y corresponden a los resultados promedios de entrenar 10 redes neuronales para cada experimento.

	Media	Varianza
MLP 2 capas	85.72	1.30
MLP 3 capas	84.70	1.27

Tabla 2. Resultados de los experimentos 1 y 2.

Se observa que se obtienen mejores resultados con la MLP de 2 capas. Para el experimento 3 se trabajó con las 10 redes procedentes de los experimentos anteriores por separado y mezclando las redes del experimento 1 y 2.

	Media
Modelo más votado MLP 2 capas	88.3
Modelo más votado MLP 3 capas	88.2
Modelo más votado MLP 2 y 3 capas	88.7

Tabla 3. Resultados de los experimentos 3.

La combinación de varias redes ayuda en la fase de decisión, errores que comete una red puede ser corregido por otras redes. Se observa en la tabla 3 que ha aumentado la tasa de reconocimiento en casi 3 puntos. Lo interesante de esta estructura es que las redes que participen en el modelo estén lo más incorreladas posible, ya que así los errores lo estarán.

4. CONCLUSIONES

Aquí se presenta los primeros resultados sobre la taxonomía de hojas de imágenes foliares procedentes de árboles autóctonos de las Islas Canarias, aplicando redes neuronales. Los mejores resultados obtenidos son los del modelo más votado, ya que participan varias redes en el proceso de clasificación. Todavía queda mucho trabajo que realizar sobre el preprocesado, extracción de parámetros, aplicaciones de otros modelos de clasificación y combinación entre ellos.

5. REFERENCIAS

- [1] William T. Stearn, *Botanical Latin, History, Grammar, Syntax, Terminology and Vocabulary*. David&Charles. Network Abbot.
- [2] Pedro L. Pérez de Paz y Lourdes Negrin Sosa. *Phanerogamarum Monographiae Tomus XX*. Revisión Taxonómica de Sideriris L.
- [3] U. Grenander, Y. Chow, and D.M. Keenan, *Hands: A pattern Theoretic Study of biological Shapes*. New York: Springer-Verlag, 1991.
- [4] S.Y. Kung *Digital Neural Networks* Prentice Hall, New Jersey 1993.
- [5] Amanda J.C. Sharkey, *Combining Artificial Neural Nets: Ensemble and Modular Multi-Net Systems*, Springer-Verlag London, 1999.
- [6] Stanley R. Deans, *The Randon Transform and some of its applications*. John Wiley & Sons. South of Florida, 1983.