

**PONTIFICIA UNIVERSIDAD CATOLICA DEL PERU
ESCUELA DE POSGRADO**



**PONTIFICIA
UNIVERSIDAD
CATÓLICA
DEL PERÚ**

**CARACTERIZACIÓN DE TEXTURA EN IMÁGENES DIGITALES DE HOJAS
DE PLANTAS MEDIANTE DIMENSIÓN FRACTAL MULTIESCALA**

Tesis para optar el grado de Magíster en Informática con mención en Ciencias
de la Computación que presenta:

SOFÍA KHLEBNIKOV NÚÑEZ

Asesores:

DR. CÉSAR ARMANDO BELTRÁN CASTAÑÓN

DR. ODEMIR MARTINEZ BRUNO

Jurados:

DR. HECTOR ANDRÉS MELGAR SASIETA

DR. HUGO ALATRISTA SALAS

LIMA – PERÚ

2018

Resumen

Actualmente aún existen áreas de la Amazonía donde se puede encontrar especies de plantas que necesitan ser identificadas y estudiadas para poder conocer sus propiedades médicas, nutricionales, industriales, etc. En muchos casos, los especialistas realizan un análisis manual, confiando en sus habilidades sensoriales y experiencia, pero eso demanda tiempo y dinero. Por eso, es importante tener una herramienta efectiva que permita hacer un rápido y eficiente reconocimiento de las plantas.

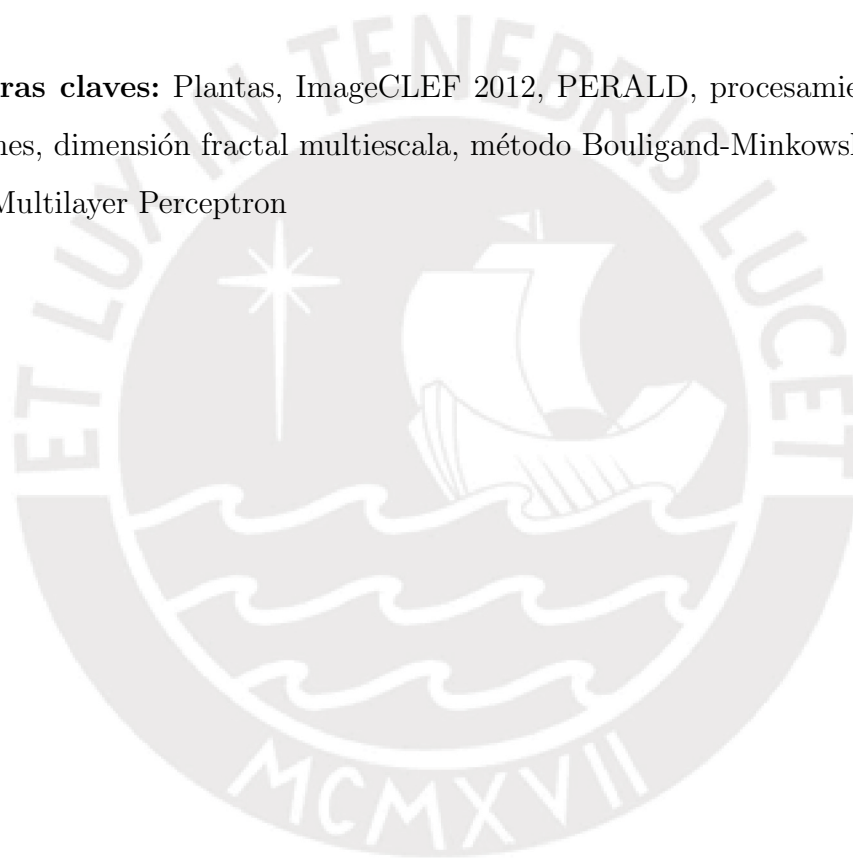
Con este trabajo queremos dar un aporte al área de la investigación de reconocimiento y clasificación de plantas, presentando los resultados de la caracterización de plantas a través de la textura de la hoja.

El objetivo es evaluar el método Bouligand-Minkowski basado en dimensión fractal multiescala, usando imágenes digitales para la caracterización de la textura de hojas de la Amazonía del Perú, con el fin de ayudar a mejorar su identificación y catalogación.

Para lograr el objetivo de la investigación se trabajó con dos bases de datos: ImageCLEF 2012, con 101 especies de plantas y PERALD de 27 especies. La primera es la base de datos de validación y la segunda es objeto de la investigación. El paso inicial de este trabajo fue la aplicación de un preprocesamiento de las imágenes de las plantas. Luego, las imágenes fueron divididas en cuadrados de 128 x 128 píxeles, seleccionando los 5 mejores por

cada imagen. Este paso era necesario para facilitar la caracterización de la textura. Después se aplicó el método Bouligand-Minkowski a cada muestra para obtener los descriptores de la textura de la planta. Estos descriptores fueron la entrada al clasificador *Multilayer Perceptron* generando así un modelo de clasificación de plantas de base de datos PERALD.

Palabras claves: Plantas, ImageCLEF 2012, PERALD, procesamiento de imágenes, dimensión fractal multiescala, método Bouligand-Minkowski, textura, Multilayer Perceptron



Abstract

Nowdays, there are areas of Amazon jungle where exist plant species that need to be identified and studied to know their properties, such as medicinal, nutritional, or industrial. In many cases, specialists perform a manual analysis, relying on their sensory skills and experience, but this demands time and money. For that reason, it is important to have an effective tool that allows to make a quick and efficient recognition of plants.

With this work we want to give a contribution to the research area of recognition and classification of plants, presenting the results of the characterization of plants through the texture of the leaf.

The objective is to evaluate the Bouligand-Minkowski method based on multiscale fractal dimension, using digital images for the characterization of the texture of the leaves of the Peruvian Amazon jungle, in order to help improve their identification and cataloging.

To achieve the objective of the research, we worked with two databases: ImageCLEF 2012, with 101 plant species and PERALD of 27 species. The first one is the validation database and the second database is the subject of the investigation. The initial step of this work was pre-processing of the plant images. Then, the images were divided into squares of 128 x 128 pixels, selecting the best 5 for each image. This step was necessary to facilitate texture characterization. Then the Bouligand-Minkowski method was applied to

each sample to obtain the plant's texture descriptors. These descriptors were the input to the Multilayer Perceptron classifier, thus generating a PERALD database plant classification model.

Keywords: Plants, ImageCLEF 2012, PERALD, image processing, multiscale fractal dimension, Bouligand-Minkowski method, texture, Multilayer Perceptron



Agradecimientos

Gracias a mis asesores Dr.César Beltrán y al Dr.Odemir Martinez. A los miembros del jurado Dr.Andrés Melgar y Dr.Hugo Alatrística.

Quiero agradecer a todos mis familiares y amigos que me ayudaron y apoyaron en el proceso de preparación de este trabajo, desde la etapa de escoger el tema, durante la investigación y recolección de la información, hasta el proceso de desarrollo y redacción de la tesis. Y también un enorme agradecimiento a las personas que tuvieron el tiempo y la paciencia para revisarla.

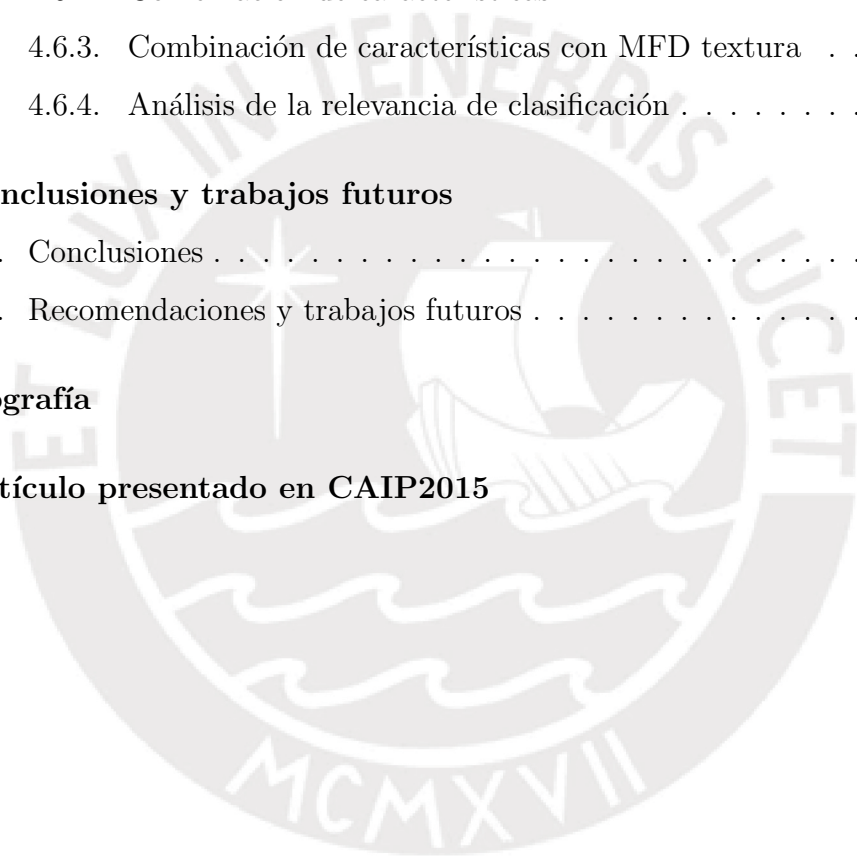
Muchas gracias a todos por su tiempo y dedicación.

Índice general

Resumen	I
Abstract	III
Agradecimientos	V
1. Generalidades	1
1.1. Introducción	1
1.2. Definición del problema	4
1.3. Objetivo general	6
1.4. Objetivos específicos	6
1.5. Resultados esperados	6
1.6. Fuentes de datos	7
1.7. Algoritmos y herramientas	8
1.8. Justificación	9
1.9. Limitaciones del proyecto	10
1.10. Organización del documento	11
2. Marco Conceptual y Metodológico	12
2.1. Conceptos generales	12
2.1.1. Imagen	13

2.2. Proceso de caracterización de textura mediante Dimensión Fractal Multiescala	13
2.3. Adquisición de imágenes y base de datos	14
2.4. Segmentación de imágenes	14
2.4.1. Método de Otsu	15
2.5. Caracterización de hojas de plantas	16
2.6. Textura de la hoja	16
2.7. Dilatación exacta	18
2.8. Fractal y dimensión fractal	19
2.8.1. Box-counting	22
2.8.2. Método Bouligand-Minkowski	23
2.9. Clasificación o reconocimiento del objeto	28
2.9.1. Clasificador Perceptrón Multicapa (MLP)	28
3. Estado del Arte	30
3.1. Introducción	30
3.2. Resumen de características de plantas, métodos para extraerlas y clasificadores	31
4. Desarrollo y Resultados	36
4.1. Base de datos	36
4.1.1. ImageCLEF 2012	36
4.1.2. PERALD	37
4.2. Pre-procesamiento y segmentación	40
4.3. Generación de muestras	41
4.4. Generación del vector de características por DFM	42
4.4.1. Transformación volumétrica de la textura	42

4.4.2. Diagrama de flujo del proceso y la explicación de la parte principal del proceso	45
4.5. Clasificación de especies de plantas con DFM	49
4.6. Dimensión Fractal Multiescala como componente de vector de características	51
4.6.1. Conjunto de datos y características	52
4.6.2. Combinación de características	53
4.6.3. Combinación de características con MFD textura	54
4.6.4. Análisis de la relevancia de clasificación	57
5. Conclusiones y trabajos futuros	58
5.1. Conclusiones	58
5.2. Recomendaciones y trabajos futuros	60
Bibliografía	61
A. Artículo presentado en CAIP2015	69



Índice de figuras

2.1. Metodología de caracterización de textura mediante dimensión fractal multiescala para la clasificación de hojas de plantas . . .	14
2.2. Hoja original y hoja segmentada por el método Otsu	16
2.3. Hoja con muestras de textura seleccionadas y ampliación de una muestra	17
2.4. Ejemplo de dilatación de un contorno S de la imagen de hoja en blanco y negro	19
2.5. Ejemplo de un diseño fractal y la textura de una hoja que se asemeja a una estructura fractal	20
2.6. Curva de Koch	21
2.7. Secuencia de dilataciones de píxeles del contorno de la hoja en una imagen	24
2.8. Matriz de distancias de una región de imagen de la hoja . . .	24
2.9. Curva <i>log-log</i> obtenida con el método Bouligand-Minkowski . .	27
2.10. Ejemplo de curvas de dimensión fractal multiescala	27
4.1. Ejemplos de hojas de 115 especies de ImageCLEF 2012	37
4.2. Ejemplos de 14 especies de ImageCLEF 2012 que fueron descartadas debido a la dificultad de extracción de muestras	38
4.3. Ejemplos de hojas (envés y haz) de 27 especies de UNIA . . .	39

4.4. Pre-procesamiento de la imagen 40

4.5. Proceso de generación de muestras 41

4.6. Muestra de imágenes de textura de una hoja de PERALD (haz
y envés) 42

4.7. Región extraída de la hoja que muestra la textura y su repre-
sentación en volumen, generada por la dilatación de la textura 44

4.8. Curva $\log(V(r))$ vs. $\log(r)$, representa la relación entre volu-
men y distancia de dilatación 45

4.9. Pasos del proceso de análisis de textura de hojas 46



Índice de cuadros

4.1. Resultados de la clasificación de textura de ImageCLEF 2012 y PERALD	51
4.2. Características extraídas	52
4.3. Resultados de clasificación de 115 especies	53
4.4. Resultados de clasificación ImageCLEF 2012 sin textura	54
4.5. Resultados de clasificación ImageCLEF 2012 con textura	54
4.6. Resultados de clasificación PERALD sin textura (hoja haz)	55
4.7. Resultados de clasificación PERALD con textura (hoja haz)	55
4.8. Resultados de clasificación PERALD sin textura (hoja envés)	56
4.9. Resultados de clasificación PERALD con textura (hoja envés)	56

Capítulo 1

Generalidades

1.1. Introducción

Según los datos del Ministerio del Ambiente del Perú: “60 % del territorio nacional está cubierto por bosques (73,3 millones de hectáreas), ubicados en la costa, sierra y selva; lo que nos convierte en el segundo país de América Latina con mayor extensión de bosques tropicales, después de Brasil”^{1,2}.

De acuerdo al Ministerio de Agricultura y Riego del Perú: “Se calcula que existen unas 25 000 especies de flora (10 % del total mundial), de las cuales un 30 % son especies endémicas. Es el país con mayor número de especies de plantas cuyas propiedades son utilizadas por la población y primero en especies domesticadas nativas”³. Todas estas especies están concentradas en su mayoría en la Amazonía, convirtiendo a esta región en la más importante del país en cuanto a variedad de plantas. Sin embargo, aún existen áreas poco exploradas donde se puede encontrar especies desconocidas, las

¹<http://www.minam.gob.pe/bosques/los-bosques-en-cifras/>

²<http://www.minam.gob.pe/programa-bosques/el-peru-cuarto-pais-con-mas-bosques-tropicales/>

³<http://www.minagri.gob.pe/portal/47-sector-agrario/recurso-biodiversidad/345-diversidad-de-especies>

cuales necesitan ser identificadas y estudiadas para conocer sus propiedades médicas, comestibles o como materia prima (Pinedo *et al.*, 1997). Por tal motivo, es importante tener una herramienta efectiva que permita hacer un rápido y eficiente reconocimiento de plantas, antes de que se pierda la valiosa información debido a los factores industriales, ambientales y deforestación.

Usualmente, los expertos en botánica, para realizar el reconocimiento y la caracterización de las especies de plantas, hacen un análisis visual de la morfología de las hojas, las flores y los frutos; así mismo realizan un análisis sensorial del látex del árbol para una mejor precisión. Una de las formas más comunes de identificar a una planta es a través de las hojas, midiendo y analizando el tamaño y la forma, por ser un análisis sensorial simple. Otra forma de identificación de plantas es a través de la nervadura y la textura; este análisis es un buen discriminador, pero es más complejo. En la actualidad, la colaboración entre el conocimiento de los especialistas botánicos y las herramientas de la visión computacional, permite mejorar y simplificar el análisis de plantas a través de la nervadura, la textura y la forma, y en consecuencia, aumenta la eficiencia del proceso de reconocimiento y clasificación de las plantas.

Con este trabajo queremos dar un aporte al área de la investigación de reconocimiento y clasificación de plantas, presentando los resultados de la caracterización de plantas a través de la textura de la hoja. ¿Por qué usar la textura? La textura es una característica importante para el análisis de objetos en las imágenes digitales (Laine y Fan, 1993; Haralick, 1979), debido a que representa la consistencia estructural interna del objeto, este punto ayuda en proceso de reconocimiento en botánica (de las hojas vivas y de las imágenes digitales de hojas), porque mediante la textura podemos diferenciar una especie de la otra, cuando las plantas tienen formas o tamaños similares.

Esta característica varía entre especies, haciendo que también varíen sus propiedades biológicas (Sack y Scoffoni, 2013). Además, combinando la textura con otras características, tales como la nervadura, el color y la morfología, mejoramos el análisis de determinación y clasificación de plantas (Manjunath *et al.*, 2001; da Fontoura Costa y Cesar Jr., 2009).

A pesar de ser una propiedad importante, no hay una definición única para la textura en el área de visión computacional, muchas veces es definida según el problema que se intenta resolver (Haralick, 1979; Tuceryan y Jain, 1993a; Nixon y Aguado, 2002). Por ejemplo, en Tuceryan y Jain (1993a) la textura de una imagen es definida como función de variación espacial de nivel de intensidad de píxel en escala de grises que genera una combinación de patrones de repetición regular. Por ende, cada trabajo y estudio de análisis de textura aporta algo a la definición de esta.

En el ámbito científico se han propuesto diferentes métodos para el análisis de la textura, en la literatura Kerut *et al.* (2003) los dividen en dos categorías: cualitativos y cuantitativos; en artículo de Xie (2008) separan los métodos según el enfoque: estadístico, estructural, basado en filtro, basado en fractal y en color-textura. En este trabajo usamos método basado en análisis fractal para obtener las características de textura de las imágenes de hojas. La caracterización de textura será el enfoque principal del presente trabajo.

La caracterización de textura con el método basado en análisis fractal ha ganado interés en la comunidad científica. La principal atracción de este método es la habilidad de describir formas complejas e irregulares de los objetos de la naturaleza. Las hojas de las plantas tienen formas geométricas irregulares y complejas, la textura de ellas no es homogénea y las nervaduras no son líneas rectas. Estas tres características (forma, textura y nervadura) se asemejan a la estructura fractal. Por lo cual, el modelo de fractal es más

apropiado para el análisis de textura de las hojas que el modelo usado para objetos geométricos simples. El fractal, como la propiedad del objeto, es aprovechado en el análisis de identificación y clasificación de distintos tipos de objetos (Lopes y Betrouni, 2009). En la literatura encontramos algunas investigaciones previas (Martinez *et al.*, 2008; Oncevay-Marcos *et al.*, 2015; Backes y Bruno, 2009, 2010; Backes *et al.*, 2009; Plotze *et al.*, 2005; Du *et al.*, 2013) que se enfocaron en aplicar los métodos de caracterización de plantas basados en dimensión fractal.

1.2. Definición del problema

La Amazonía es una región muy importante del Perú, por las diferentes riquezas naturales que se encuentran y que pueden ser explotadas. Como se conoce, en la Amazonía existen diversas especies de plantas que son utilizadas para fines médicos (Pinedo *et al.*, 1997), existen especies que aún no tienen el registro formal de sus características médicas y alimenticias, además existen áreas del bosque tropical que aún no han sido exploradas y por ende hay plantas sin descubrir. La explotación actual de recursos naturales pone en peligro la flora y la fauna del nuestro país. Para no perder la valiosa información de estos recursos es importante rescatar, conservar y analizar el valor de los recursos forestales, para esto debemos identificar y analizar las diversas especies de plantas y establecer un registro de las mismas. El empleo de herramientas computacionales para la identificación y caracterización de plantas ayudaría mucho en la conservación de la flora peruana.

La identificación de las especies de la Amazonía peruana, frecuentemente se realiza de manera tradicional, por los especialistas botánicos que, confiados en su experiencia, analizan manualmente las muestras de hojas de plantas,

comparándolas visualmente con las que ya tienen registradas, generalmente en sus herbarios físicos.

El presente trabajo se encuentra enmarcado dentro del proyecto de generación de un catálogo digital para plantas endémicas de la Amazonía⁴ en el cual se desarrolló un *framework* para la elaboración de un catálogo digital de especies de plantas de la Amazonía Peruana, así como se generó un sistema de recuperación de imágenes por contenido para el reconocimiento automático de especies de plantas basado en el análisis de la morfología de las hojas de plantas. Para ello se constituyó un conjunto de imágenes de hojas de plantas que contiene aproximadamente 45 especies (27 especies fueron usadas en el trabajo presente debido a la buena calidad de las imágenes y las características visuales de las hojas), lo cual representa una primera base de datos digital de especies nativas peruanas.

Dentro del proyecto en mención, se propusieron desarrollar diferentes técnicas de caracterización; por tratarse de una nueva base de datos (PERALD) esta se presta para poder experimentar con diversos métodos que fueron aplicados en otras bases de datos. La pregunta a nuestro problema a resolver es cómo incrementar el nivel de diferenciación entre especies de plantas mediante el análisis de la estructura morfológica de las especies de plantas. Nuestra hipótesis es saber si el método de caracterización mediante estructuras fractales ayuda en esta diferenciación de especies.

⁴Proyecto financiado por INNOVATE Perú mediante contrato 183-FINCYT-IB-2013, adjudicado al Grupo de Reconocimiento de Patrones e Inteligencia Artificial, Sección Ing. Informática, PUCP.

1.3. Objetivo general

Evaluar el método Bouligand-Minkowski basado en dimensión fractal multiescala, para la caracterización de la textura de las imágenes digitales de las hojas de la Amazonia del Perú, con el fin de ayudar a mejorar su identificación y catalogación.

1.4. Objetivos específicos

- Pre-procesar y segmentar dos conjuntos de imágenes digitales de plantas, ImageCLEF 2012 y PERALD, usando los métodos estándar en la literatura para estos dos procesos.
- Implementar el algoritmo de caracterización de textura basado en Dimensión Fractal Multiescala.
- Aplicar el algoritmo implementado para extraer las características de las muestras de imágenes de la base de datos generada en el primer ítem.
- Generar un modelo de clasificación de hojas usando un algoritmo entrenado con los descriptores extraídos de textura y evaluar los resultados del modelo de clasificación.

1.5. Resultados esperados

- Dos conjuntos de imágenes de hojas de plantas pre-procesadas y segmentadas.

- Un algoritmo basado en Dimensión Fractal Multiescala para la caracterización de textura.
- Un espacio de características, constituido por los vectores extraídos de cada muestra de imágenes que representa la textura.
- Modelo de clasificación y la matriz de confusión que indica la efectividad de clasificación del método propuesto.

1.6. Fuentes de datos

Para el presente trabajo se utilizaron dos bases de datos, una para el proceso de validación del modelo y la segunda como objetivo del trabajo por tratarse de una base de datos inédita que se constituye en un aporte. A continuación se detalla cada una de ellas:

- ImageCLEF 2012⁵: se trata de un conjunto de imágenes de 101 especies de hojas de plantas de la región mediterránea francesa, que fueron escaneadas, organizadas y compartidas a la comunidad científica. Esta base de datos se constituye en un *gold standard* para todo trabajo que implique el reconocimiento automático de especies de plantas, mediante el análisis estructural de las hojas (Oncevay-Marcos *et al.*, 2015; Yanikoglu *et al.*, 2014; Brilhador *et al.*, 2013; Yanikoglu *et al.*, 2012).
- PERALD (*Peruvian Amazon Leaves Dataset*): este conjunto de imágenes digitales es un aporte de los botánicos de la Universidad Nacional Intercultural de la Amazonía, el mismo que a su vez es parte del proyecto de generación de un catálogo digital para plantas endémicas de

⁵<http://www.imageclef.org/2012>

la Amazonía⁶. PERALD está constituido por 27 especies de plantas endémicas de la Amazonía, siendo que se poseen 40 muestras de cada especie (20 del envés y 20 del haz). Las muestras de hojas fueron recolectadas en la región de Yarinacocha, Ucayali, por especialistas botánicos de la Universidad Nacional Intercultural de la Amazonía (UNIA), entidad asociada al proyecto referido.

1.7. Algoritmos y herramientas

Para el cumplimiento del objetivo general del presente trabajo se implementaron y se aplicaron diversos algoritmos y técnicas que se encuentran descritos en la literatura. Las implementaciones fueron realizadas en lenguajes *Python* y *Mathematica*. Dentro de estos algoritmos, podemos mencionar los siguientes:

- Algoritmo de segmentación usando las funciones propias del lenguaje *Python*, una de las cuales es basada en el método Otsu, el cual nos permitió aislar la región de interés.
- Algoritmo para la extracción y selección de muestreo de una imagen digital, basado en un modelo matemático descrito en el trabajo de Backes *et al.* (2009). Este algoritmo nos permitió generar un conjunto de muestras de textura (parches) de diferentes regiones de la imagen de una hoja de planta.
- Algoritmo basado en Dimensión Fractal Multiescala para la extracción de características de las muestras de textura.

⁶Proyecto financiado por INNOVATE Perú mediante contrato 183-FINCYT-IB-2013, adjudicado al Grupo de Reconocimiento de Patrones e Inteligencia Artificial, Sección Ing. Informática, PUCP.

Para la experimentación con modelo de clasificación, como *Multilayer Perceptron* (MLP) utilizamos plataforma WEKA; Esta herramienta fue utilizada en el artículo Oncevay-Marcos *et al.* (2015) que fue publicado como parte del proyecto de generación de un catálogo digital para plantas endémicas de la Amazonía⁷.

1.8. Justificación

La autora del presente trabajo fue parte del equipo científico del proyecto de investigación denominado “Aplicación de visión computacional en la generación de un catálogo para la conservación de la diversidad de plantas endémicas” que se desarrolló en la PUCP, y que tuvo como tarea la investigación sobre técnicas de extracción de características para la diferenciación de especies de plantas. Al constituir una nuevo conjunto de imágenes digitales del proyecto (PERALD), se propone analizar la textura de la hoja mediante técnicas basada en fractales, esto debido a que la constitución de la estructura de la textura y nervadura de las hojas guardan una geometría de formación fractal. Con ello se busca incorporar otro algoritmo y extender los métodos de obtención de características para el proyecto de identificación y clasificación de plantas endémicas de la Amazonía del Perú, con el fin de ayudar a mejorar el modelo de clasificación.

Como hemos mencionado anteriormente trabajamos con dos bases de datos: ImageCLEF 2012 y PERALD. La primera fue usada como *gold standard* para efectos de validación del modelo propuesto, siendo característica de esta base de datos la de presentar imágenes digitales de buena calidad, además

⁷Proyecto financiado por INNOVATE Perú mediante contrato 183-FINCYT-IB-2013, adjudicado al Grupo de Reconocimiento de Patrones e Inteligencia Artificial, Sección Ing. Informática, PUCP

de estar organizada por especies, lo que facilita el trabajo de clasificación. PERALD es una base de datos de las imágenes digitales de las plantas que fue proporcionada por los especialistas botánicos de la Universidad Nacional Intercultural de la Amazonía (UNIA), para su constitución se puso especial cuidado en que las imágenes tuviesen una buena calidad además de contar con un buen número de especies recolectadas.

Para la caracterización de la textura se escogió trabajar con el método basado en dimensión fractal multiescala debido a que previamente se trabajó con dimensión fractal para el contorno de la hoja y se obtuvo buenos resultados en Oncevay-Marcos *et al.* (2015), además, como se mencionó previamente, en la literatura se encontraron diversos trabajos basados en dimensión fractal para la textura (Backes *et al.*, 2009; Plotze *et al.*, 2005; Martinez *et al.*, 2008). Otro factor para escoger este método fue el hecho de que estas investigaciones fueron realizadas con las plantas de la Amazonía Brasileña.

Por último, el modelo desarrollado en este trabajo podría servir como base para otros proyectos con mayor alcance, por ejemplo, la identificación de enfermedades en las plantas, o combinarse con aspectos genéticos.

1.9. Limitaciones del proyecto

En el proyecto se realizará la investigación e implementación de la técnica, para la caracterización de la textura de las plantas amazónicas, mediante método Bouligand-Minkowski basado en Dimensión Fractal Multiescala (DFM). Para obtener las características de textura de una imagen, esta debe pasar por un proceso previo de segmentación. Dado que el objetivo del presente trabajo es caracterizar la textura, se usarán las técnicas estándar encontradas en la literatura para el pre-procesamiento y la segmentación. En

caso de ser necesario la segmentación se hará manualmente usando editores gráficos.

Para evaluar la efectividad de la caracterización de textura mediante fractal, se usan los descriptores en el proceso de clasificación e identificación de plantas con *Multilayer Perceptron* (MLP). Como mencionamos anteriormente el objetivo es caracterizar la textura, por lo tanto, se usa un método estándar de la clasificación encontrado en la literatura, sin dar mayor enfoque a esta etapa del proceso general.

1.10. Organización del documento

El presente documento está dividido en capítulos. El Capítulo 1 abarca la motivación, la definición del problema, el objetivo general, objetivos específicos, limitaciones del proyecto y la organización del documento. La base teórica del proyecto se desarrollará en el Capítulo 2. La revisión de estado de arte se verá en el Capítulo 3. La metodología del trabajo y los resultados se presentan en el Capítulo 4. El Capítulo 5 mostrará las conclusiones y los trabajos futuros.

Capítulo 2

Marco Conceptual y Metodológico

2.1. Conceptos generales

El área de procesamiento de imágenes y reconocimiento de patrones es muy importante en la actualidad. Algunos de los propósitos de procesamiento de imágenes es mejorar la calidad visual de imagen para el ojo humano, mejorarla para medir y analizar las características de los objetos contenidos en ella. Las técnicas, herramientas aplicadas para estos propósitos, no siempre son iguales, dependen de varios factores. Uno de los factores es origen de la imagen (Fu y Rosenfeld, 1976; Russ, 2016). Por ejemplo, las imágenes en medicina nuclear y en astronomía son de origen rayos gamma; las imágenes para diagnósticos médicos son de rayos x; geología, investigación submarina, medicina son solo algunas de las áreas que trabajan con las imágenes de ultrasonido (Gonzalez y Woods, 2006). En este proyecto trabajamos con imágenes escaneadas que son de tipo visual.

2.1.1. Imagen

¿Qué es una imagen? Según Gonzalez y Woods (2006), la imagen se define como una función bidimensional $f(x, y)$, donde x e y son coordenadas espaciales (en el plano). La amplitud de f en cualquier par de coordenadas (x, y) es llamada la intensidad o nivel de gris de la imagen en este punto. Cuando las coordenadas (x, y) y los valores de intensidad de función f son valores finitos, a la imagen la llaman: imagen digital. Esta imagen digital está compuesta por un número finito de elementos, cada uno de ellos tiene localización y valor. El nombre de cada uno de estos elementos es píxel.

Para analizar y estudiar los objetos en las imágenes es necesario aplicar pasos de procesamiento de imagen:

- Adquisición de imagen
- Segmentación de imagen
- Extracción de características de imagen
- Reconocimiento de objeto

2.2. Proceso de caracterización de textura mediante Dimensión Fractal Multiescala

El procedimiento seguido se puede apreciar en la Figura 2.1. En ella podemos distinguir las bases de datos a estudiar y los procesos propuestos para este trabajo: pre-procesamiento, generación de muestras, extracción de características y clasificación.

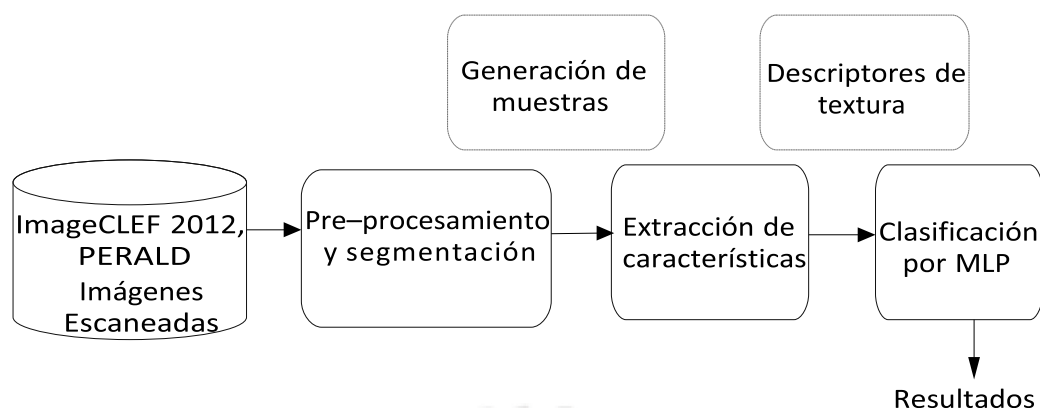


Figura 2.1: Metodología de caracterización de textura mediante dimensión fractal multiescala para la clasificación de hojas de plantas (elaboración propia).

2.3. Adquisición de imágenes y base de datos

En el presente trabajo hemos utilizado dos bases de datos de imágenes, ImageCLEF 2012 y PERALD (*Peruvian Amazon Leaves Dataset*), las cuales se describen en la Sección 4. Con el fin de validar nuestra propuesta, se tomó para experimentación la conocida base de datos ImageCLEF 2012, lo cual sirvió como referencia comparativa de los resultados que se obtuvieron con nuestro algoritmo. Luego de validado el resultado, se procede a aplicar la misma estrategia sobre la nueva base de datos denominada PERALD, siendo esta de reciente constitución y de interés en el presente trabajo para conseguir la diferenciación entre especies de plantas de la Amazonía.

2.4. Segmentación de imágenes

La segmentación es el paso importante y fundamental del área de procesamiento de imágenes. Para obtener un buen resultado en el proceso de reconocimiento de objeto en una imagen, la segmentación de este objeto de-

be ser muy precisa. Es necesario separar o delimitar dicho objeto del entorno. El objetivo principal de la segmentación es separar la imagen en objetos o regiones para obtener los objetos de relevancia en una imagen. Según Gonzalez y Woods (2006), los métodos de la segmentación se basan en las propiedades básicas de intensidad de valores, de similitud y de discontinuidad. En caso de aplicar la similitud de valores de píxeles, la imagen se divide en regiones con características similares; en caso de discontinuidad, la imagen se particiona en regiones con mayor diferencia de intensidad entre los píxeles. En el presente trabajo, para segmentar el objeto de interés, se aplicó el método de Otsu, uno de los principales métodos de segmentación Otsu (1975).

2.4.1. Método de Otsu

Este algoritmo usa la distribución estadística de la intensidad de colores (un histograma) para obtener un umbral, que permite dividir una imagen en las regiones. Este valor se utiliza para segmentar la imagen en dos partes, el fondo (*background*) y el objeto (*foreground*) (Otsu, 1975). El histograma de colores permite determinar el valor promedio y la varianza de cambio de intensidad para cada grupo de colores, con estos datos se obtiene un mejor resultado de la separación de objetos por colores similares. En la Figura 2.2 observamos imagen original (izquierda) y segmentada (derecha) utilizando el método Otsu. La imagen segmentada (binarizada) la podemos utilizar como máscara para obtener objeto de interés, aplicando un operador lógico entre imagen original y segmentada (binarizada).




Figura 2.2: Hoja original y hoja segmentada (binarizada) por el método Otsu (elaboración propia).

2.5. Caracterización de hojas de plantas

La caracterización de plantas es un proceso que permite obtener las características tales como forma, color, textura, nervadura, morfología, borde de las diferentes partes de la planta: hoja, tallo, flores. Es difícil encontrar un algoritmo o una técnica de caracterización que, utilizando solo una característica (forma, color o textura), clasifica o reconoce las plantas con la precisión al 100 %. Pero con la combinación de varias características se puede aumentar el porcentaje de precisión. Una de las partes más usadas y representativas de la planta en el procesamiento de imágenes es la hoja. Tanto botánicos como los especialistas en visión computacional estudian esta característica para el reconocimiento y clasificación de las plantas. La hoja de la planta ofrece un buen material de estudio; la forma, el borde, la nervadura, el contorno y la textura son unas de las propiedades que identifican e indican a qué familia, género o especie pertenece cada planta.

2.6. Textura de la hoja

La textura es una característica importante para el análisis de muchos tipos de imágenes (Laine y Fan, 1993; Haralick, 1979; Tuceryan y Jain, 1993a),




Figura 2.3: Hoja con muestras de textura seleccionadas y ampliación de una muestra (elaboración propia).

incluyendo las plantas. Según Tuceryan y Jain (1993b); Laws (1980) una imagen de textura ofrece muchas propiedades para describir una textura, tales como uniformidad, densidad, dirección, frecuencia y otras más. En la Figura 2.3 podemos observar un ejemplo de textura de una hoja.

En botánica para describir la textura de una planta generalmente analizan las hojas, pero también pueden analizar otras partes (flor, tallo) (Simpson, 2010).

La textura representa la consistencia estructural interna del objeto. En el área de visión computacional la textura no tiene una definición exacta, cada investigador la define según la visión y objetivo del problema (Haralick, 1979; Tuceryan y Jain, 1993a; Nixon y Aguado, 2002). Coggins (1983) hace una compilación de definiciones de textura. Según Tuceryan y Jain (1993a), la textura en una imagen es una función de variación espacial de intensidad de píxel (de color gris) y es una parte importante de estudio en visión computacional.

¿Por qué analizamos textura de la planta? Cuando existen ciertas similitudes en la forma o color de las hojas de diferentes especies, el análisis de la textura ayuda a mejorar la precisión de clasificación y reconocimiento de las plantas, pues cada especie tiene diferente patrón de textura. Además el análisis de textura ayuda mucho en caso de una planta dañada o fragmentada, cuando no es posible reconocerla por la forma. Existen técnicas y métodos que extraen y procesan la textura del objeto, siendo las más conocidas matriz de co-ocurrencia e histograma de colores (Kebapci *et al.*, 2010), que analizan la frecuencia de los valores del nivel de intensidad de color en una imagen. Otra de las técnicas es el análisis fractal basado en el cálculo de dimensión fractal.

2.7. Dilatación exacta

Dilatación es una operación morfológica matemática que expande o dilata interiormente y exteriormente un objeto o su contorno en una imagen. Se aplica en muchos problemas de área de procesamiento de imagen, especialmente en el análisis de la forma de un objeto (da Fontoura Costa y Cesar Jr., 2009).

Dilatación exacta es un algoritmo que permite implementar esta operación morfológica. Sea S una forma (contorno) binaria bidimensional. La dilatación exacta de S es la secuencia de todas las dilataciones sucesivas, sin repetición, usando círculos con el radio que se incrementa con cada dilatación (da Fontoura Costa y Cesar Jr., 2009). En la Figura 2.4 vemos el ejemplo de dilatación del contorno S de una hoja.




Figura 2.4: Ejemplo de dilatación (imagen derecha) de un contorno S de la imagen de hoja en blanco y negro (imagen izquierda) (elaboración propia).

2.8. Fractal y dimensión fractal

Un fractal es un objeto cuya estructura en parte o total se repite a diferentes escalas (auto similitud). El objeto se caracteriza por tener una estructura geométrica irregular que no se puede definir con la geometría tradicional (Larese *et al.*, 2014; Mandelbrot, 1983).

¿Por qué fractal? Su principal atracción es la habilidad de describir formas irregulares y complejas de los objetos de la naturaleza (Lopes y Betrouni, 2009). No siempre los objetos se forman de líneas rectas. Muchos objetos de la naturaleza no son figuras geométricas exactas, forman las figuras complejas, como líneas costeras, brócoli, copos de nieve, rayos; además son objetos que tienen propiedades fractales. Las plantas tienen una forma y una estructura irregular y compleja, no son un círculo u óvalo perfecto; algunas veces podemos identificar patrones de repetición en las superficies. Muchos de es-




Figura 2.5: Ejemplo de un diseño fractal (izquierda)¹ y la textura de una hoja que se asemeja a una estructura fractal (derecha)².

tos patrones nos recuerdan estructuras fractales. En este trabajo se quiere explorar la propiedad fractal de hoja para obtener conjunto de características de texturas y analizarlo como herramienta para la identificación de plantas. En la Figura 2.5 vemos un ejemplo de fractal.

Generalmente cuando vemos un objeto de formas regulares podemos definir su dimensión topológica; por ejemplo, un punto es de dimensión cero, una recta es dimensión 1, el cuadrado (área) es dimensión 2 y el cubo (volumen) es dimensión 3 (Hausdorff, 1918).

¿Pero qué pasa con un objeto con forma irregular? ¿Qué dimensión tiene? En la Figura 2.6 vemos un ejemplo de figura de forma irregular.

Según Jelinek y Fernandez (1998), dimensión es un número que refleja un aspecto particular de una forma geométrica. No siempre este número es entero. Cuando el espacio o una forma geométrica es expresado con un

¹https://commons.wikimedia.org/wiki/File:Fractal_fern_explained.png

²http://www.allposters.es/-sp/Backlit-Close-Up-of-a-Rose-Leaf-with-Visible-Veins-Posters.i6111570_.htm




Figura 2.6: Curva de Koch (elaboración propia)

número real, este se denomina dimensión Hausdorff (Schroeder, 2009). Esta dimensión fue renombrada como dimensión fractal, porque el valor se puede representar en forma de una fracción (en objetos irregulares) (Plotze *et al.*, 2005). Es llamada “dimensión” porque provee la medida de cómo un objeto llena completamente un espacio. Para medir la dimensión de un objeto irregular, necesitamos una fórmula o una expresión. La dimensión fractal es un valor numérico que indica con cuántas unidades de fractal se puede llenar un objeto.

Como menciona Plotze *et al.* (2005) es común el uso de concepto de dimensión fractal en el área de procesamiento de imágenes, para la cuantificación de la complejidad de la forma y de la textura de los objetos.

Hay varios métodos para determinar la dimensión fractal, el más conocido es *box-counting*, otro método es de Minkowski, que fue adoptado para aplicar a las estructuras no fractales (Plotze *et al.*, 2005) y para el enfoque multiescala (más adelante explicaremos estos dos métodos). Actualmente se han desarrollado algunas técnicas que usan el concepto de dimensión fractal para el reconocimiento de plantas. Analizan el contorno de la hoja aplicando el algoritmo para calcular la dimensión fractal, y luego utilizan características obtenidas para la clasificación de plantas (Jobin *et al.*, 2012). Obtienen el contorno de la imagen en blanco y negro de una planta, luego calculan los valores de dimensión fractal del contorno. La dimensión fractal es mencionada

en el trabajo de Martinez *et al.* (2008) donde comparan dos métodos (*box-counting* y *multiscale Minkowski*) analizando la complejidad de las plantas.

Para entender mejor la definición de dimensión fractal, tomamos la descripción y ejemplos de Theodoridis y Koutroumbas (2009). El autor toma una recta de longitud L y la divide en N partes iguales de longitud l . Cada segmento es parte de la recta, cuya longitud disminuye (escala) por el factor $f = \frac{1}{N} = \frac{l}{L}$. Al aumentar cualquier segmento por el mismo factor, se obtiene la recta original. Es una propiedad de auto-similaridad, algunas partes de objeto son similares al todo (definición de fractal). Luego, usa un cuadrado de longitud L y aplica al lado del cuadrado el factor escala $f = \frac{1}{N^{1/2}}$; esto genera N cuadrados iguales, donde cada uno es igual al cuadrado original (Theodoridis y Koutroumbas, 2009). Ahora, la cantidad de elementos que se forman depende de la dimensión D y el factor f de escala; para la recta con dimensión = 1 sería $f^1 = N$; para el cuadrado con dimensión =2 es $f^2 = N$ y para el cubo sería $f^3 = N$. Podemos observar una relación entre dimensión (D), factor (f) y número de elementos (N), $N = f^D$. Si despejamos D obtenemos $\frac{\log N}{\log f} = D$.

2.8.1. Box-counting

Box-counting o *dimension-box* es uno de los métodos que estima la dimensión fractal, y es el más usado (Falconer, 2004; Plotze *et al.*, 2005). La idea de este método es dividir la imagen en cuadrados de tamaño t , se forma una grilla del tamaño de la imagen. Luego se cuenta la cantidad de cuadrados que cubren al menos una parte del objeto de la imagen. $N(t)$ es la cantidad de cuadrados que cubren al objeto. Para mayor precisión del resultado, progresivamente disminuyen el tamaño t del cuadrado, por consecuencia cambia $N(t)$. La relación de $\log N(t)$ vs. $\log(t)$ genera una curva cuya gradiente es

dimensión fractal (Jelinek y Fernandez, 1998; da Fontoura Costa y Cesar Jr., 2009). Según Takayasu (1990); Peitgen *et al.* (1992); Falconer (2004) la reducción de tamaño t en cada paso es un factor que es igual a $\frac{1}{2}$.

2.8.2. Método Bouligand-Minkowski

Otra forma de estimar la dimensión fractal es aplicar el método de Bouligand-Minkowski (Falconer, 2004), que está basado en espacio de Minkowski (Tricot, 1994; Jelinek y Fernandez, 1998). El espacio de Minkowski es el objeto que se genera al aplicar el proceso de dilatación a cada píxel de la figura.

En Plotze *et al.* (2005) se presenta una explicación detallada del método: la estimación de dimensión fractal con este método se basa en la relación entre el interfaz del objeto y el espacio ocupado por él. La dimensión del objeto es dada por la función que representa un proceso iterativo y que expresa la razón entre el área de dilatación y el radio de incremento de dilatación. La secuencia consecutiva de dilatación se conoce como la suma de Minkowski, la suma consiste en expansión secuencial del contorno el cual con cada dilatación incrementa su área. En la Figura 2.7 vemos la secuencia de dilataciones del contorno de una hoja.

Para implementar el proceso de dilatación Plotze *et al.* (2005) usa *Exact Distance Transform* (EDT), la distancia de todos los elementos cercanos de la matriz al elemento de interés, para luego escoger la distancia mínima entre píxel de matriz y el píxel del objeto de interés. En la Figura 2.8 observamos un ejemplo de matriz de distancias de una región de imagen. Los dígitos ceros representan píxeles del objeto de interés (contorno de la hoja), y el resto de los valores representan la distancia entre el píxel del contorno (dígitos ceros) y del punto que da el valor respectivo.




Figura 2.7: Secuencia de dilataciones de píxeles del contorno de la hoja en una imagen. El contorno rojo (dentro del borde blanco) corresponde al borde original de la hoja (elaboración propia).

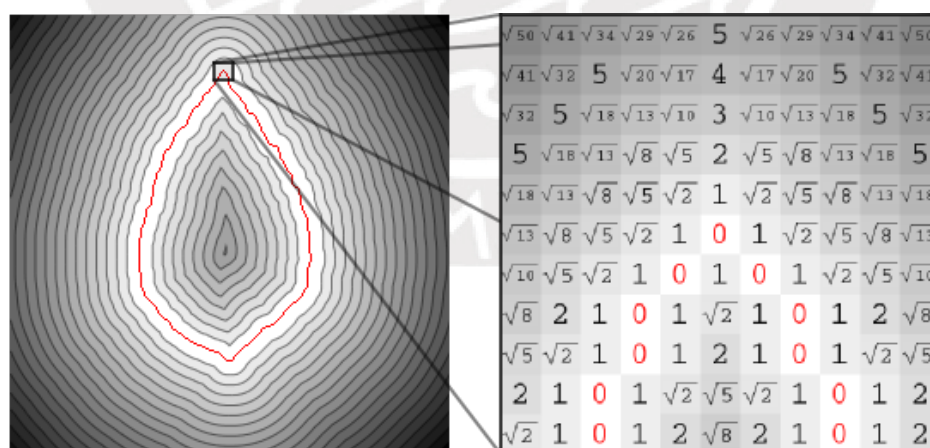


Figura 2.8: Matriz de distancias de una región de imagen de la hoja. Los dígitos ceros corresponden al contorno de la hoja (elaboración propia).

En Plotze *et al.* (2005) se representa EDT mediante un conjunto de distancias euclidianas $E = \{0, 1, \sqrt{2}, \sqrt{3}, 2, \sqrt{5}, 2\sqrt{2}, \dots, t\}$

Cada elemento de E es denominado d , donde $d = (i^2 + j^2)^{1/2}$, $i, j \in N$

- $k = \{0, 1, 2, 3, \dots, n\}$, donde k es el índice que corresponde a una distancia d del conjunto E .

- P es el conjunto de puntos que corresponden a la imagen (objeto) a dilatar.

- $g_k(P)$ es el conjunto de píxeles que están a una distancia, correspondiente al índice k , de puntos que pertenecen a P , donde

$$k = 0, g_0(P) = P$$

$$k \neq 0, g_k(P) = \{(x, y), [(x - Px)^2 + (y - Py)^2]^{1/2} = E(k); x, y \in N\}$$

- $Q(k)$ es la cantidad de píxeles de la dilatación k .
- $A(k)$ es el área de dilatación, donde

$$A(k) = \sum_{i=1}^k Q(i)$$

Relacionando el área total de cada dilatación a una distancia d desde el contorno original de la hoja, el autor obtiene un gráfico *log-log*. El valor de dimensión fractal se calcula usando la pendiente del gráfico $\log(d)$ versus $\log A(d)$ (da Fontoura Costa y Cesar Jr., 2009). La fórmula sería:

$$df = 2 - \frac{\log A(d)}{\log(d)}$$

donde $A(d)$ es el área total que es la suma de todos los puntos que están a una distancia d de la dilatación.

Como dice Plotze *et al.* (2005) a pesar de que dimensión fractal es usada en análisis de imágenes y reconocimiento de patrones, igual tiene sus limitaciones: algunos objetos de naturaleza geométrica distinta pueden tener el valor equivalente o similar de dimensión fractal, además, no todos los objetos son fractales y el tamaño de los objetos no es infinito, lo que implica que la complejidad tiende al valor cero al incrementar la escala del objeto de interés. Además, un solo valor numérico de dimensión fractal no es suficiente para describir el comportamiento fractal (como ocurre con la dilatación en diferentes puntos de la figura) del objeto que muestra la curva obtenida con el método Bouligand-Minkowski (Backes y Bruno, 2012). Por tal motivo, Plotze *et al.* (2005); Backes y Bruno (2012) proponen la función Dimensión Fractal Multiescala (DFM), es obtenida de la derivación de curva *log-log* y proporciona un conjunto de valores para describir el comportamiento fractal del objeto. La función DFM es definida como:

$$DFM = 2 - \frac{du(t)}{dt}$$

donde $\frac{du(t)}{dt}$ es la derivada de la curva *log-log* de $u(t)$ calculada con el método Bouligand-Minkowski.

En la Figura 2.9 observamos un ejemplo de curva de *log-log* obtenida con el método Bouligand-Minkowski, es la relación entre la distancia de dilatación (d) y el área que se genera ($A(d)$) por la dilatación correspondiente. La pendiente de esta curva representa la dimensión fractal (df). Luego, al derivarla se genera una nueva curva mostrada en la Figura 2.10, ahí observamos unos ejemplos de curvas Dimensión Fractal Multiescala. Son dos tipos que corresponden a dos especies diferentes, las curvas de color rojo representan DFM de hojas de una especie y las de color azul son DFM de otra especie, cada curva pertenece a una imagen de hoja. Luego, por cada curva se ge-




Figura 2.9: Curva *log-log* obtenida con el método Bouligand-Minkowski (elaboración propia).




Figura 2.10: Ejemplo de curvas de dimensión fractal multiescala (elaboración propia).

nera un conjunto de puntos característicos (descriptores) para el proceso de clasificación.

El enfoque de multiescala muestra el comportamiento fractal a diferentes escalas (en dilataciones a distancias distintas) y lo expresa a través de un conjunto de valores en vez de un único valor, lo que mejora la caracterización de la figura dándole una información más robusta, esto hace que sea uno de los métodos más precisos y que produce un resultado consistente (Tricot, 1994; Schroeder, 2009; da Fontoura Costa y Cesar Jr., 2009).

2.9. Clasificación o reconocimiento del objeto

El reconocimiento del objeto es la parte final del procesamiento de imágenes. Los métodos y técnicas de clasificación se dividen en dos grupos: de decisión teórica y estructural. Los del primer grupo trabajan con los descriptores cuantitativos, tales como longitud, textura, área. El segundo grupo usan los descriptores cualitativos (Gonzalez y Woods, 2006). En este trabajo utilizaremos los clasificadores del primer grupo.

2.9.1. Clasificador Perceptrón Multicapa (MLP)

El Perceptrón Multicapa o MLP (*Multilayer Perceptron*) es un algoritmo de aprendizaje de red neuronal, propuesto por Rumelhart (Rumelhart *et al.*, 1988). Como indica su nombre tiene múltiples capas, donde cada capa es un conjunto de neuronas interconectadas entre sí. La conexión entre neuronas es a través de los pesos. Las capas se dividen en tres partes: una capa de entrada, n capas ocultas y una capa de salida, donde n es una o más capas. La salida de cada neurona i es la entrada a la neurona $i + 1$. Además, la capa de entrada debe tener la misma cantidad de neuronas que la de salida. En

este trabajo se utilizó MLP utilizando la plataforma WEKA³.

La razón de utilizar este clasificador es porque han trabajado con él en varios estudios de procesamiento de imágenes y de reconocimiento y clasificación de plantas, tales como, Vianna y Cruz (2014); Brilhador *et al.* (2013), además fue utilizado en Oncevay-Marcos *et al.* (2015), donde la autora del trabajo presente hizo estudio con los descriptores DFM del contorno de las hojas de la base de datos ImageCLEF 2012, y el resultado (porcentaje de acierto de clasificación) de este estudio fue bueno.



³<http://www.cs.waikato.ac.nz/ml/weka/>

Capítulo 3

Estado del Arte

3.1. Introducción

En este capítulo se presenta el estado de arte de procesamiento de imágenes, una revisión bibliográfica de los métodos y técnicas de fractal aplicadas a textura de las plantas, desarrollados y aplicados en la actualidad.

Durante el proceso de revisión bibliográfica se analizaron los artículos, libros obtenidos de las bases de datos como *SCOPUS*, *IEEEExplore*, *Science Direct* y *Scholar Google*. Se buscaron los trabajos relacionados con el tema del trabajo presente. Para tal propósito se formularon preguntas específicas para que el resultado de la búsqueda fuera más detallado y enfocado en el tema estudiado. Además se incluyeron los criterios de inclusión y exclusión para disminuir la cantidad de la bibliografía.

3.2. Resumen de características de plantas, métodos para extraerlas y clasificadores

Revisando los trabajos de procesamiento de imágenes de plantas, se observó que las características más usadas en el proceso de caracterización son forma (*shape*), color (*colour*), textura (*texture*), debido a la facilidad para procesar y analizarlas (Du *et al.*, 2007). Otras características que encontramos en estado de arte y que son usadas como descriptores, fueron la nervadura (*vein*) (Harish *et al.*, 2013; Martinez *et al.*, 2008) y el borde (*margin*) de las hojas. Hay investigaciones que usan sólo un descriptor para la caracterización de las plantas. Rashad *et al.* (2011) trabaja con el contorno, Pydipati *et al.* (2006); Beghin *et al.* (2010) sólo con el color. Pero esto tiene cierta desventaja en las plantas que tienen fuerte similitud entre especies; extraer y analizar solo la forma de la hoja no va a dar resultado satisfactorio en la clasificación. Pero combinando las dos características, color y forma, se mejora el resultado en la clasificación de plantas (Cope *et al.*, 2012). Beghin *et al.* (2010) analiza la forma y la textura de las hojas y obtiene descriptores para la clasificación a partir de estas dos propiedades. Kadir *et al.* (2012) proponen extraer características de color, forma, nervadura y de textura de las hojas para el proceso de identificación de las plantas. En el mismo trabajo en la etapa de clasificación usaron Red Neuronal *Probabilistic Neural Network* (PNN) como clasificador, obteniendo el resultado de 93,75 % de precisión.

Según Haralick *et al.* (1973) la textura es la distribución espacial del tono gris de los píxeles en una imagen. Para analizar la textura de la hoja de la planta en una imagen analizan los valores de cada píxel. Como mencionamos antes, la imagen de textura ofrece diferentes características. El Haralick *et al.* (1973) propone obtener una matriz de niveles de grises de los píxeles y

analizar la frecuencia de repetición del nivel de gris en un área respecto a sus vecinos.

En Zhang *et al.* (2012); Kadir *et al.* (2012), a partir de esta matriz, obtienen y analizan 9 características de textura para el reconocimiento de las plantas. Además de textura Zhang *et al.* (2012) analizan la forma de la hoja, combinando los descriptores de las dos características y clasifica las 1900 hojas de 32 especies obteniendo 93.8% de exactitud. Otros métodos de análisis de textura que encontramos en revisión son el filtro de Gabor (Zhang *et al.*, 2012; Cope *et al.*, 2012) y el análisis fractal.

El análisis fractal permite analizar propiedades de textura y color del objeto y determinar la complejidad del objeto estimando la dimensión fractal. Actualmente se han desarrollado algunas técnicas que usan el fractal para el reconocimiento de plantas.

Jobin *et al.* (2012); Martinez *et al.* (2008) aplican la técnica de dimensión fractal para analizar contorno y nervadura de las plantas. Al contorno de hoja de la imagen en blanco y negro aplican el algoritmo basado en dimensión fractal, obteniendo las características. Luego aplican media y varianza para homologar los valores antes de aplicar un clasificador. El mismo proceso se aplica a la nervadura. El resultado final de clasificación mostró 84% de coincidencia.

En Oncevay-Marcos *et al.* (2015) trabajaron con ImageCLEF2012 la misma base de datos que fue propuesta en este trabajo. Se trabajó con textura, color y forma. Para la caracterización de textura y color aplicaron el método de Haralick (Haralick *et al.*, 1973) y momentos de color, para el contorno de hojas la dimensión fractal y redes complejas. El porcentaje de precisión fue 64,78% usando el descriptor obtenido del contorno con dimensión fractal, pero las 3 características juntas dieron un 90,41% de precisión. El clasifica-

dor que se usó fue Perceptrón Multicapa. Otro autor que utilizó el *dataset* ImageCLEF 2012 fue Brillhador *et al.* (2013). Su enfoque fue comparar el comportamiento de diferentes descriptores, tales como textura, color y contorno obtenidos con los métodos de Haralick, Fourier y *Quantized Compound Change Histogram* (QCCH) para clasificación usaron *K-nearest neighbor* (K-NN), *Naive Bayes* (NB), *Multilayer Perceptron* (MLP), *Random Forest* (RF), J4.8 y *Support Vector Machines* (SVM). Compararon los resultados de 3 pruebas: clasificación con todos los descriptores, clasificación con algunos descriptores seleccionados y clasificación con descriptores seleccionados con la técnica *AdaBoost*. El mejor resultado fue 87,5 % con SVM usando todos los descriptores, el segundo fue 87,1 % con RF usando todos los descriptores seleccionados por *AdaBoost* y el tercer resultado fue 83,9 % con MLP y algunos descriptores seleccionados.

En el trabajo presente se decidió usar la textura debido a su importancia. En Tuceryan y Jain (1993a) la textura de una imagen es definida como función de variación espacial de nivel de intensidad de píxel en escala gris. Cuando existen ciertas similitudes en la forma o en color, analizar la textura de las hojas ayuda a clasificar las plantas porque las especies tienen diferentes patrones de textura. También es útil si la planta está dañada o solo existe un fragmento de hoja.

Actualmente hay bastante investigaciones que trabajan con fractales para obtener características y descriptores. En el trabajo de Martinez *et al.* (2008) se compara dos métodos (*box-counting* y *multiscale Minkowski*) analizando la complejidad de las plantas estimando la dimensión fractal. Para tal caso analizan el contorno y la nervadura. En el estudio usaron 50 hojas de 10 especies diferentes para el experimento uno. Para el experimento dos fueron utilizados 4 especies con 20 hojas por cada una. El método multiscale Min-

kowski mostró mejores resultados, solo 2,225 % de error en la clasificación. En general, los resultados muestran un buen desempeño al aplicar el método, basado en la dimensión fractal, para generar descriptores. Backes y Bruno (2012); Backes *et al.* (2012) trabajan con contorno, color y textura usando el método fractal de Bouligand-Minkowski, Haralick, Gabor. Los resultados obtenidos muestran cierta ventaja de Bouligand-Minkowski respecto a otros métodos.

Los métodos principales o los más usados de clasificación son: *Probabilistic Neural Network* (PNN), *Support Virtual Machine* (SVM), *k-Nearest Neighbours* (k-NN). Kadir *et al.* (2012) utilizan el clasificador PNN para el reconocimiento de las especies usando color, textura y propiedades morfológicas de hojas como características de las plantas. Como resultado obtiene 93,75 % de exactitud. En cambio, Wu *et al.* (2007), usando el mismo clasificador y la forma de hoja como característica obtuvieron 90,312 % de acierto. Para Wu *et al.* (2007) el clasificador PNN se demoró menos tiempo en procesar los datos que otros clasificadores que fueron aplicados a los mismos datos. Arun Priya *et al.* (2012) procesaron las doce características morfológicas digitales, y aplicaron los clasificadores SVM y k-NN; en este caso el clasificador SVM dio mayor tasa de exactitud y también fue más rápido. En dos investigaciones (Du *et al.*, 2007; Zhang *et al.*, 2004) propusieron el clasificador *Moving Median Centers Hypersphere* (MMC) para las características morfológicas que fueron extraídas de la hoja. En el primer estudio (Du *et al.*, 2007) el resultado de MMC fue comparado con los resultados obtenidos de clasificadores 1-NN y k-NN y la conclusión fue que MMC tuvo un tiempo menor y además necesitó un espacio menor de almacenamiento. El porcentaje de respuestas correctas para MMC fue 91 %, y para 1-NN y 4-NN fue 93 % y 92 % respectivamente. En el segundo estudio (Zhang *et al.*, 2004) también hicieron las

comparaciones entre MMC, 1-NN y 4-NN, haciendo dos experimentos, para 9 y 17 tipos de plantas. En los dos casos el MMC mostró menor tiempo de ejecución y menor tamaño de almacenamiento. En cuanto al porcentaje de precisión, MMC, con 9 especies, ocupó el tercer lugar, MMC con 19 especies ocupó el segundo lugar entre 1-NN,4-NN y MMC. También se observó que menor cantidad de plantas daba mayor tasa de exactitud.

De los trabajos recientes mencionaremos algunos, en Aakif y Khan (2015) usaron 817 hojas de 14 árboles distintos, extrajeron descriptores morfológicos, de Fourier y del contorno propuestos por ellos mismos. Estas características fueron procesadas con el clasificador ANN (*Artificial Neural Network*) dando como resultado más de 95 % de acierto. En Naresh y Nagendraswamy (2016) usaron las características de textura extraídas con MLBP (*Modified Local Binary Patterns*), que fueron procesadas con el clasificador *Nearest Neighbor*. Ahmed *et al.* (2016), trabajaron con las características de contorno, nervadura y descriptores de Fourier sobre el data set Flavia con 32 especies de plantas. El resultado de precisión fue 87,40 % usando SVM como clasificador.

En resumen, podemos señalar que hay bastantes trabajos con fractales y texturas. Se analizaron las investigaciones de 2007 hasta 2017. En los trabajos usaron la textura y el color para caracterizar al objeto en la imagen. En los 10 artículos se vio el uso de contorno, nervadura y características morfológicas para el análisis de reconocimiento. En los 7 trabajos hicieron análisis de dimensión fractal para caracterizar al objeto de reconocimiento. Haralick fue aplicado en 5, Gabor (Backes *et al.*, 2012) en 5, Fourier (Backes y Bruno, 2012) en 3 y 2 de Momentos de Zernike (Khotanzad y Hong, 1990).

Capítulo 4

Desarrollo y Resultados

4.1. Base de datos

4.1.1. ImageCLEF 2012

ImageCLEF 2012 es una base de datos de imágenes digitales de plantas, que fue presentada en el *workshop* ImageCLEF en el año 2012 (por eso el nombre) y es parte de una base de datos más grande ImageCLEF que se renueva cada año. Esta base de datos contiene 126 especies de plantas obtenidas de la región mediterránea de Francia, consiste de 11 572 imágenes de 3 tipos: 6 630 escaneadas, 2 726 fotografías pseudo-escaneadas (foto sobre fondo blanco) y 2 216 fotografías en ambiente natural (Goëau *et al.*, 2013).

En la Figura 4.1, podemos apreciar muestras de la base de datos, donde se coloca una imagen por cada una de las 115 especies que fueron utilizados para un trabajo anterior y cuyo resultado se menciona en este documento.

Para este trabajo se utilizaron imágenes escaneadas de 101 especies de las 115 que fueron utilizados por Oncevay-Marcos *et al.* (2015). El resto de las imágenes escaneadas, 14 especies, fue descartado debido a la imposibilidad



Figura 4.1: Ejemplos de hojas de 115 especies de ImageCLEF 2012 (elaboración propia).

de procesarlas. En la Figura 4.2 podemos apreciar que la forma y el tamaño de las hojas no permite generar muestras de textura de 128 x 128 píxeles.

Como hemos mencionado antes, ImageCLEF 2012 es la base de datos de validación del modelo del presente trabajo; fue escogida por la buena calidad de imágenes escaneadas y tener buena organización por especies, lo que facilita el proceso de clasificación.

4.1.2. PERALD

Base de datos de hojas de Amazonía peruana (PERALD) es una base de datos nueva de imágenes digitales de plantas nativas. Estas plantas fueron recolectadas en Yarinacocha, región amazónica peruana. Es proporcionada para el proyecto de investigación “Aplicación de visión computacional en la



Figura 4.2: Ejemplos de 14 especies de ImageCLEF 2012 que fueron descartas debido a la dificultad de extracción de muestras (elaboración propia).

generación de un catálogo para la conservación de la diversidad de plantas endémicas”. El proyecto coincidía con el enfoque del presente trabajo, por tal motivo decidimos trabajar con PERALD. Contiene 45 especies de las plantas, 40 imágenes por especie (20 imágenes de haz y 20 de envés por especie), en total hay 1 800 hojas. Las hojas frescas fueron escaneadas con la resolución de 300 DPI, colores de 24 bits y con fondo blanco.

Para nuestro trabajo se utilizaron 27 especies de las 45; estas 27 fueron escogidas por la calidad de imagen y el tamaño de las hojas. Las hojas demasiado angostas no permitían obtener muestras de textura de buena calidad.

En la Figura 4.3, se muestra un ejemplo de imágenes que constituyen la base de datos, cada imagen es representativa de las 27 clases con las cuales se trabajó.



Figura 4.3: Ejemplos de hojas (envés y haz) de 27 especies de UNIA (elaboración propia).




Figura 4.4: Pre-procesamiento de la imagen (elaboración propia).

4.2. Pre-procesamiento y segmentación

Para el proceso de la segmentación primero convertimos las imágenes a escala de grises con un algoritmo estándar encontrado en literatura y luego son binarizadas. Para generar una imagen binaria es necesario aplicar el umbral (*threshold*) con el método de Otsu (Otsu, 1975), esto separa el fondo del objeto del interés, como se muestra en la Figura 4.4, la segunda imagen. El último paso es cambiar el objeto de interés a escala de grises, usando algoritmo de conversión de color.

Anteriormente ya se trabajó con el método Otsu en el artículo “Plant identification based on leaf shape, texture and color using complex networks, multi-scale fractal dimension and statistical descriptors” (Oncevay-Marcos *et al.*, 2015) segmentando las imágenes digitales de hojas y se obtuvo buenos resultados, por tal motivo, decidimos trabajar con el mismo método en esta propuesta. Aplicamos el proceso de segmentación a las dos bases de datos. En la Figura 4.4 podemos observar imágenes generadas durante el proceso de segmentación: original, imagen obtenida al combinar original con la obtenida por método Otsu y segmentada en escala de grises.




Figura 4.5: Proceso de generación de muestras (elaboración propia).

4.3. Generación de muestras

El proceso de generación de las muestras de textura de las imágenes de hojas es el siguiente: a cada imagen se aplica el algoritmo que divide la imagen en cuadrados no solapados de 128 x 128 píxeles, luego se aplica un filtro que selecciona muestras que tengan 50 o menos píxeles negros de fondo para un buen análisis de textura. De las muestras generadas, seleccionamos las 5 mejores por cada imagen de hoja de ImageCLEF 2012 y de PERALD (5 envés y 5 haz) para la extracción de las características. Estas 5 fueron escogidas por un algoritmo implementado, que se basó en un trabajo de Backes *et al.* (2009). En la Figura 4.5 observamos el proceso completo de generación de muestras.

La razón de escoger el tamaño de muestra 128 x 128 píxeles es debido a que en la bibliografía de procesamiento de imágenes encontramos varios estudios que utilizan el mismo tamaño de muestras de textura de hojas (Backes *et al.*, 2009; Backes y Bruno, 2010; Rashad *et al.*, 2011; Backes *et al.*, 2012). Otra razón es que con este tamaño obtenemos la cantidad suficiente de muestras para la generación de características.

La elección de la cantidad de muestras por imagen se basó en los trabajos de Backes *et al.* (2009); Backes y Bruno (2010) porque su enfoque es similar al trabajo presente, caracterización de textura de hojas usando fractal.




Figura 4.6: Muestra de imágenes de textura de una hoja de PERALD (haz y envés) (elaboración propia).

En la Figura 4.6, se muestra un ejemplo de muestras de textura (imágenes segmentadas). En la primera fila son 5 imágenes de haz de la hoja y en la segunda son de envés.

4.4. Generación del vector de características por DFM

4.4.1. Transformación volumétrica de la textura

Para la extracción de características de hoja escogimos las 5 muestras de textura en escala gris por cada imagen de hoja, luego procesamos a cada muestra con el algoritmo que extrae las características de textura usando el método de Bouligand-Minkowski.

Como hemos explicado en Capítulo 2, la dimensión fractal (DF) es definida como $DF = 2 - \frac{\log A(d)}{\log(d)}$, donde $A(d)$ es el área del objeto dilatado a una distancia d , representa la correlación entre el objeto y el espacio que este ocupa. Este trabajo está enfocado en caracterizar la textura de una hoja, como dice Backes *et al.* (2009) diferentes texturas tienen diferentes estructuras de

píxeles, esto muestra que cada textura tiene un patrón característico, a cada patrón le corresponde un volumen característico. Esto permite trabajar con $V(r)$ como característica que describe la organización de píxeles de textura y por lo tanto también la complejidad de la misma. Por tal motivo trabajamos con el volumen en vez de área, el proceso de trabajo es similar al explicado en Capítulo 2, solo que en vez de aplicar el método Bouligand-Minkowski al contorno, lo aplicaremos a la superficie generada en R^3 .

Aplicamos los mismos pasos que Backes *et al.* (2009); Backes y Bruno (2009). Primero se genera una superficie de puntos $p(x, y, z)$, $p \in S$, donde x, y son coordenadas de píxel en la imagen M de la textura original y $z = M(x, y)$ es la intensidad de este píxel. Realizando la dilatación de la superficie S la dimensión fractal de Bouligand-Minkowski se define como $FD = 3 - \frac{\log V(r)}{\log(r)}$, donde $V(r)$ es el volumen del objeto dilatado y r la distancia de dilatación. El volumen es la suma de todos los puntos a una dilatación de distancia r del objeto original. El proceso de dilatación con diferentes r permite estudiar la complejidad de textura en diferentes escalas. Este proceso se implementa con EDT para tres dimensiones.

En la Figura 4.7 podemos observar una muestra de textura y la dilatación de esta muestra.

Como se mencionó en el Capítulo 2 la curva logarítmica obtenida con el método Bouligand-Minkowski presenta más detalles de lo que se podría expresar con un solo valor numérico, y no es suficiente para representar toda la complejidad del objeto. Por eso utilizan Dimensión Fractal Multiescala (DFM) en Backes y Bruno (2009). Se hace la derivación de la curva logarítmica obtenida con el método Bouligand-Minkowski:

$$DFM = 3 - \frac{d \log V(r)}{d(r)}$$



Figura 4.7: Región extraída de la hoja que muestra la textura (izquierda) y su representación en volumen, generada por la dilatación de la textura (derecha) (elaboración propia).

En la Figura 4.8 podemos observar una curva, donde cada punto representa la relación entre la distancia de dilatación y el volumen generado por esa dilatación, esta curva es importante porque la pendiente de ella es la Dimensión Fractal.

Para calcular la dimensión fractal multiescala necesitamos obtener la derivada de la curva *log-log*. El valor inicial de la derivación no da buenos resultados, porque la curva *log-log* presenta mucho ruido. Para optimizar los resultados, la suavizamos aplicando el filtro de Gauss para eliminar los ruidos. Los descriptores a evaluar son los puntos (x, y) obtenidos de la derivación de la curva *log-log*; además, la cantidad de características depende de la distancia máxima de dilatación.




Figura 4.8: Curva $\log(V(r))$ vs. $\log(r)$, representa la relación entre volumen y distancia de dilatación. El valor de la pendiente de la curva es la Dimensión Fractal (elaboración propia).

4.4.2. Diagrama de flujo del proceso y la explicación de la parte principal del proceso

El proceso total de identificación y clasificación de plantas, desde la etapa **Leer una imagen** hasta **Clasificación de planta**, lo podemos observar en la Figura 4.9.

Siguiendo el objetivo del trabajo, nos enfocamos solo en las siguientes etapas:

- Selección de mejores muestras de textura de hojas
- Generación de curva de distancias acumuladas
- Generación de la curva DFM para obtener puntos característicos

Más adelante describiremos las tres etapas principales, que mencionamos líneas arriba. Las etapas el pre-procesamiento, la segmentación y la clasi-

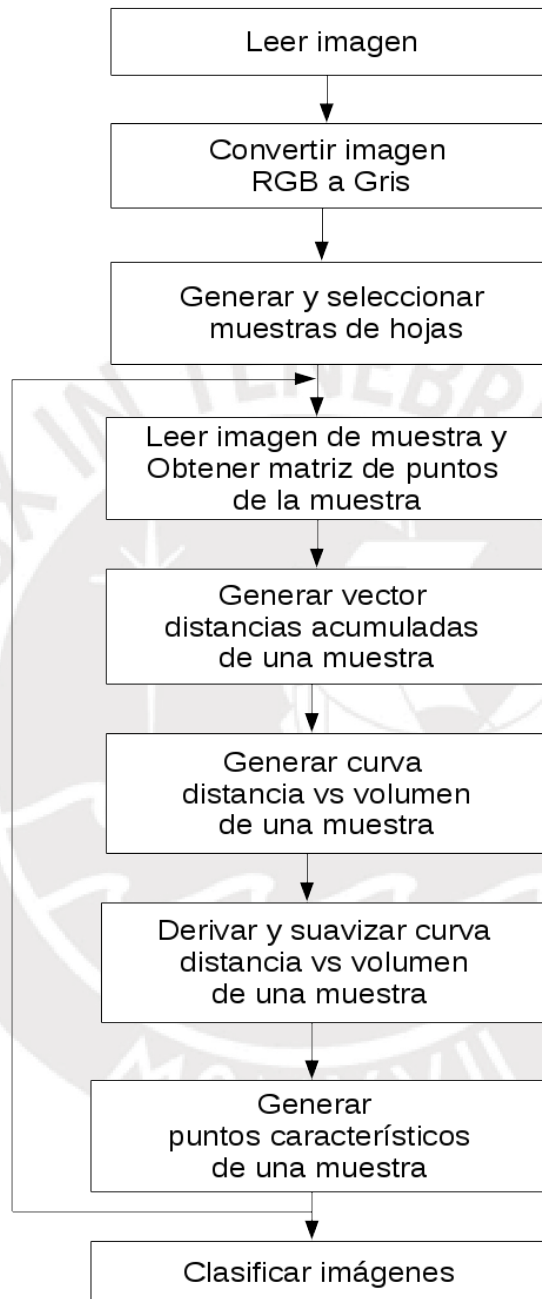


Figura 4.9: Pasos del proceso de análisis de textura de hojas (elaboración propia).

cación también son parte del proceso general pero no fueron puntos principales del trabajo presente. Para estas etapas aplicamos métodos y técnicas estándar encontrados en la literatura, los mencionaremos en los Capítulos 2 y 4 a rasgos generales. Como hemos mencionado en Capítulo 1, el desarrollo del proceso de la Figura 4.9 se realizó con los lenguajes *Mathematica(R)*, *Python* y la plataforma WEKA para la clasificación.

Selección de mejores muestras de textura de hojas

Para seleccionar las mejores muestras implementamos y aplicamos la técnica mencionada en Backes *et al.* (2009). Cada muestra es dividida en cuadrantes y de cada cuadrante obtienen media y varianza del valor de píxel para generar un vector x de características para cada muestra. Usando la distancia como métrica se descartan las muestras cuyas características de vector presentan mayor diferencia al comparar con los valores de las medias y varianzas de la misma clase.

Se definen $q_{ik}(x, y)$, $i=1,2,3,4$ como 4 cuadrantes de la muestra $f_i(x, y)$.

El vector de características (medias y varianzas) x_i se define de la siguiente manera:

$$x_i = \mu_{q_{i1}}, \sigma_{q_{i1}}, \mu_{q_{i2}}, \sigma_{q_{i2}}, \mu_{q_{i3}}, \sigma_{q_{i3}}, \mu_{q_{i4}}, \sigma_{q_{i4}}$$

donde $\mu_{q_{ik}}$ es la media y $\sigma_{q_{ik}}^2$ es la varianza al cuadrado:

$$\mu_{q_{ik}} = \frac{1}{mn} \sum_{x=1, y=1}^{m, n} q_{ik}(x, y)$$

$$\sigma_{q_{ik}}^2 = \frac{1}{mn} \sum_{x=1, y=1}^N (q_{ik}(x, y) - \mu)^2$$

Luego, calculamos la distancia (Mahalanobis) con la función $R(x; x_0)$ para cada muestra y las ordenamos de menor a mayor valor. Escogemos las 5

primeras muestras con distancias cercanas a cero.

$$R(x; x_0) = \sqrt{(x - x_0)^T \Sigma^{-1} (x - x_0)}$$

donde:

x es el vector de cada muestra,

x_0 es la media de todos,

Σ^{-1} es matriz inversa de covarianzas.

Generación de la curva de distancias acumuladas

El objetivo de este paso es obtener matriz de puntos y generar el vector distancias acumuladas.

- Para cada píxel calculamos su distancia mínima hacia la superficie generada por la textura, luego generamos una matriz de *píxel vs. distancia mínima*.
- Generamos una matriz *distancia vs. cantidad*, donde la distancia es distancia de dilatación desde superficie inicial y la cantidad es el número de píxeles que están a esta distancia de la superficie inicial.
- Se genera una matriz *distancia vs. área*, donde distancia es la distancia de dilatación desde superficie inicial y área corresponde a la cantidad acumulada de píxeles a una distancia de dilatación desde la superficie inicial.
- Computamos la curva *log-log*, que representa el comportamiento de píxeles en el proceso de dilatación. La curva es la relación cómo cambia el volumen del objeto al incrementar la distancia de dilatación.

Generación de la curva DFM filtrada

El objetivo de este paso es generar la curva distancia vs. volumen, derivar y suavizar curva distancia vs. volumen y generar puntos característicos.

- Derivamos la curva *log-log* obtenida con el método Bouligand-Minkowski.
- Eliminamos el ruido de la curva derivada, suavizando con el método de Gauss.
- Eliminamos los puntos iniciales de la curva, debido a que no aportan información adicional como puntos característicos.

4.5. Clasificación de especies de plantas con DFM

Para cumplir con el objetivo del trabajo se sigue dos estrategias:

1. Analizar solamente el conjunto de características de Dimensión Fractal Multiescala (DFM) y cuán discriminante es por sí misma.
2. Combinar DFM con un descriptor basado en Redes Complejas, con Haralick y Momentos de Color y generar otras combinaciones con estos 4 descriptores.

Los descriptores Redes Complejas, Haralick y Momentos de Color son obtenidos por colegas participantes del proyecto en el que se desarrolló el presente trabajo.

En esta sección veremos el desarrollo de la primera estrategia y en la siguiente sección mostraremos la segunda estrategia.

Para el proceso de clasificación se usa el método *Multilayer Perceptron* (MLP). La descripción del clasificador y los valores a usar fueron descritos en el Capítulo 2. Este clasificador fue seleccionado porque se utilizó en Oncevay-Marcos *et al.* (2015), donde se trabajó con los descriptores DFM del contorno de las hojas de la base de datos ImageCLEF 2012 y dio buenos resultados. En otros trabajos relacionados con la clasificación de plantas (Vianna y Cruz, 2014; Brilhador *et al.*, 2013) también encontramos el uso del clasificador MLP. Es un clasificador muy usado en problemas de procesamiento de imágenes de reconocimiento y clasificación de plantas.

Para entrenar este clasificador se utilizó la técnica de validación cruzada (*cross-validation*), consiste en dividir los datos en k segmentos donde $k-1$ son de entrenamiento y el resto es de prueba. Este procedimiento se repite durante k iteraciones, donde $k=10$. En cada iteración el conjunto de prueba es diferente. El resultado final será la media que se genera a partir de los resultados parciales de cada iteración (Devyver y Kittler, 1982).

Los resultados de clasificación se presentan en los cuadros, se muestra la base de datos de evaluación, el nombre de los descriptores, el número de descriptores y el porcentaje de acierto de la clasificación, que es relación entre plantas reconocidas correctamente sobre el total.

En el Cuadro 4.1 se presentan los resultados de clasificación de plantas de las dos bases de datos (ImageCLEF 2012 y PERALD) con los descriptores que fueron extraídos de la textura de la hoja usando el método de DFM. En la tabla se muestra la base de datos que fue procesada, la cantidad de descriptores extraídos y los porcentajes de acierto de la clasificación de cada base de datos.

El enfoque de este trabajo es analizar el comportamiento del descriptor de textura obtenido con el método DFM y ver si puede mejorar los resultados

Cuadro 4.1: Resultados de la clasificación de textura de ImageCLEF 2012 y PERALD

Base de datos	#características	Resultados (%)
PERALD	17	71,04
ImageCLEF	17	61,71

en procesos de clasificación combinándolo con otros descriptores. Como podemos observar, por sí solo el resultado de aciertos no es alto, por tal motivo se decidió hacer un análisis donde combinamos descriptor de textura con los descriptores del trabajo Oncevay-Marcos *et al.* (2015). Los descriptores se describirán brevemente en la siguiente sección; también veremos los resultados de clasificación de plantas y el comportamiento de los descriptores de textura en combinación con otras características.

4.6. Dimensión Fractal Multiescala como componente de vector de características

Al encontrarnos con los resultados mostrados en la sección anterior, los cuales no son altos, se procedió a realizar diferentes combinaciones de características buscando mejorar la tasa de acierto. De ese modo, los descriptores extraídos del presente trabajo se combinaron con otros descriptores implementados por colegas del proyecto en el cual se desarrolla la presente tesis. Estos son: descriptores de Redes Complejas, de Color y Haralick, y de Dimensión Fractal aplicada al borde. La combinación de estos 4 conjuntos de características dio buenos resultados, dando como producto la publicación del artículo de Oncevay-Marcos *et al.* (2015) en la conferencia *Computer*

Analysis on Images and Patterns, 2015¹. La descripción de cada uno de los descriptores se puede observar en el artículo mencionado anteriormente, y será anexado al trabajo presente.

En las siguientes dos subsecciones describimos brevemente los resultados (sin entrar en mayor detalle) del artículo mencionado anteriormente, para entender el contexto de los descriptores y luego combinarlos con los del trabajo presente.

4.6.1. Conjunto de datos y características

Para la experimentación del escenario descrito en Oncevay-Marcos *et al.* (2015), se utilizó 115 especies de plantas de la base de datos ImageCLEF 2012 (Goëau *et al.*, 2013) haciendo un total de 4 870 instancias.

De este modo, a este conjunto de datos se le aplicó algoritmos de extracción de descriptores de redes complejas (DRC), dimensión fractal multiescala (DFM), Haralick (HAR) y momentos de color (COL) en los tres canales de RGB. El procedimiento de extracción puede ser revisado en el *paper* de nuestra co-autoría (Oncevay-Marcos *et al.*, 2015). Para facilitar su uso, llamaremos a estos 4 descriptores con el nombre CAIP.

Cuadro 4.2: Características extraídas

Abv.	Descripción	#características
DRC	Descriptores de Redes Complejas	26
DFM	Dimensión Fractal Multi-Escala con $d = 0,05$	68
HAR	14 descriptores de Haralick en 4 direcciones	56
COL	3 momentos de color en cada canal RGB	9
	TOTAL	159

¹<http://www.springer.com/us/book/9783319231914>

El total de características extraídas fue de 159, y la composición del mismo se detalla en el Cuadro 4.2. Se puede apreciar que los descriptores de dimensión fractal multiescala son los que se presentan en mayor número.

4.6.2. Combinación de características

Para el proceso de clasificación Oncevay-Marcos *et al.* (2015) utilizó una red neuronal Perceptrón multicapa, siendo el proceso de validación de *10-fold cross validation*. Con ello, se procedió a realizar diferentes combinaciones de conjuntos de características. Los resultados se muestran en el Cuadro 4.3, donde vemos las combinaciones de las características, la cantidad de descriptores por cada combinación y la precisión de acierto que está en % (es la relación entre casos correctamente identificados y el total de casos estudiados).

Cuadro 4.3: Resultados de clasificación de 115 especies

Combinación de características	#características	Precisión (%)
HAR + COL	65	79,85
DRC + DFM	94	72,03
DRC + HAR + COL	91	86,61
DFM + HAR + COL	133	88,31
DRC + DFM + HAR + COL	159	90,41

Se puede apreciar que el mejor resultado se obtiene al combinar todos los conjuntos de características, otorgando un precisión de 90,41 %. Estos resultados fueron mejores a los previamente desarrollados por Brilhador *et al.* (2013), (trabajo descrito en el Capítulo 3), con una estrategia muy similar (la diferencia está en la menor cantidad de especies, y en la combinación de descriptores), alcanzaron 87,5 % con un total de 218 características y con un

Cuadro 4.4: Resultados de clasificación ImageCLEF 2012 sin textura

Combinación de características	#características	Precisión (%)
HAR + COL	65	77,26
DRC + DFM	94	73,87
DRC + HAR + COL	91	86,26
DFM + HAR + COL	133	87,19
DRC + DFM + HAR + COL	159	89,20

Cuadro 4.5: Resultados de clasificación ImageCLEF 2012 con textura

Combinación de características	#características	Precisión (%)
HAR + COL + DFMT	82	81,73
DRC + DFM + DFMT	111	82,66
DRC + HAR + COL + DFMT	108	87,90
DFM + HAR + COL + DFMT	150	89,14
DRC + DFM + HAR + COL +DFMT	176	90,26

menor número de especies de plantas (54), ello debido al número de ejemplos no balanceados de cada clase. El trabajo Oncevay-Marcos *et al.* (2015) fue desarrollado en 2014-2015, por eso la comparación es con los estudios del mismo periodo o anteriores.

4.6.3. Combinación de características con MFD textura

En esta sección mostramos los resultados de la clasificación de plantas combinando los descriptores mencionados en la sección anterior con los de textura.

En los Cuadros 4.4 y 4.5 mostramos los resultados de clasificación de plantas de ImageCLEF 2012, sin y con descriptores de textura (DFMT)

Cuadro 4.6: Resultados de clasificación PERALD sin textura (hoja haz)

Combinación de características	#características	Precisión (%)
HAR + COL	55	93,70
DRC + DFM	106	83,02
DRC + HAR + COL	81	95,99
DFM + HAR + COL	135	94,47
DRC + DFM + HAR + COL	161	96,76

Cuadro 4.7: Resultados de clasificación PERALD con textura (hoja haz)

Combinación de características	#características	Precisión (%)
HAR + COL + DFMT	72	94,85
DRC + DFM + DFMT	123	93,32
DRC + HAR + COL + DFMT	98	96,95
DFM + HAR + COL + DFMT	152	96,18
DRC + DFM + HAR + COL + DFMT	178	96,76

respectivamente. DFMT son los descriptores de textura obtenidos en este trabajo con el método Dimensión Fractal Multiescala. Para hacer las pruebas, usamos 101 especies de las 115 de ImageCLEF 2012. No usamos las 115 especies de CAIP, debido a que de las 14 especies no se pudo obtener buenas muestras de textura, por la forma y tamaño de las hojas.

Como se aprecia en los resultados de clasificación al combinar las características de CAIP con las de textura aumenta el porcentaje de acierto, esto nos indica que el descriptor de textura mejora la selección entre especies.

En los Cuadros 4.6, 4.7, 4.8 y 4.9 mostramos los resultados de clasificación de plantas de base de datos PERALD sin y con descriptores de textura, combinando con las características mostradas en el Cuadro 4.3. Además, añadimos el tipo de hoja a la clasificación, haz y envés. Por eso tenemos 4 cuadros: sin textura y hoja haz, con textura y hoja haz, sin textura y hoja

Cuadro 4.8: Resultados de clasificación PERALD sin textura (hoja envés)

Combinación de características	#características	Precisión (%)
HAR + COL	55	96,95
DRC + DFM	106	83,39
DRC + HAR + COL	81	96,95
DFM + HAR + COL	135	97,33
DRC + DFM + HAR + COL	161	97,33

Cuadro 4.9: Resultados de clasificación PERALD con textura (hoja envés)

Combinación de características	#características	Precisión (%)
HAR + COL + DFMT	72	97,71
DRC + DFM + DFMT	123	93,32
DRC + HAR + COL + DFMT	98	96,95
DFM + HAR + COL + DFMT	152	97,52
DRC + DFM + HAR + COL + DFMT	178	97,52

envés, con textura y hoja envés. Para hacer las pruebas, usamos 27 especies y extrajimos las características CAIP y de textura (DFMT).

Viendo los resultados de clasificación de PERALD, observamos que hay una diferencia en porcentajes de acierto entre las hojas sin y con textura. En cada combinación de descriptores al añadir el descriptor de textura DFMT se mejora el resultado. Esto nos muestra que los descriptores de textura aportan una mejoría al proceso de clasificación de las plantas. Además, observamos que los resultados de PERALD son más altos que de ImageCLEF 2012. La razón sería la calidad y la resolución de las imágenes digitales de PERALD. Analizando los porcentajes de acierto, nos damos cuenta de que los mejores resultados (los aciertos más altos) se obtienen en combinación DRC+HAR+COL+DFMT para hoja haz con 96,95 % y en HAR+COL+DFMT para hoja envés con 97,71 %. En el primer caso la com-

binación usa un poco más de 50% de las características (98/178) y en el segundo es menos de la mitad (72/178). Esto indica que hay buenas posibilidades de mejorar los resultados al combinar estos descriptores con otros no incluidos en este trabajo. De esta manera, podemos decir que la textura es un buen discriminante para el estudio de reconocimiento y clasificación de plantas. Además, en el futuro se puede hacer un análisis de plantas combinando las características de textura de envés y haz de la hoja.

4.6.4. Análisis de la relevancia de clasificación

Haciendo el análisis de los resultados, observamos que todas las clases de PERALD tienen más de 80% como resultado de acierto. Hay más de 10 clases que llegan a 100% de acierto, la cantidad de imágenes que tienen es entre 12 y 20 por cada clase, además con 5 muestras por cada imagen que es un valor máximo.

Combinar las características de CAIP con la textura Dimensión Fractal Multiescala (DMFT) mejora la precisión de clasificación de cada una de las combinaciones. El mayor aumento de precisión, 10%, lo observamos en la combinación de Redes(DRC) + DFMT + DFM para borde. Esto indica que las características de textura obtenidas con el método Bouligand-Minkowski son buenos descriptores y pueden ser combinados con otros atributos para dar mejores resultados en los modelos de clasificación de plantas.

Capítulo 5

Conclusiones y trabajos futuros

5.1. Conclusiones

En este trabajo recreamos el procedimiento para identificación de plantas a través de atributos visuales extraídos de las imágenes digitales de hojas de diferentes especies de plantas. El objeto del presente trabajo fue evaluar la caracterización de la textura de las imágenes digitales de las hojas mediante el método Bouligand-Minkowski basado en DFM y verificar la importancia que este tiene en la clasificación y discriminación de especies. Para ello, específicamente nos concentramos en analizar la textura mediante el método basado en DFM, siguiendo dos estrategias: 1) analizar solamente el conjunto de características de DFM y cuán discriminante es por sí misma; y 2) Combinar el conjunto de características de DFM con otros conjuntos que caracterizan la morfología, textura de las hojas, como descriptores de Redes Complejas, descriptores de Haralick y Momentos de Color.

Para la estrategia 1, el mejor resultado de discriminación, usando como clasificador la red neuronal *Multilayer Perceptron*, fue de 71,04 % el cual podemos considerarlo como muy buen valor en la tarea de clasificación au-

tomática de las plantas. Cabe indicar que este resultado se consiguió con el análisis de la extracción de regiones de la hoja de planta con dimensiones de 128 x 128 píxeles.

Para la estrategia 2, vimos 3 casos: resultados de CAIP (ImageCLEF 2012, 115 clases) no incluye características de textura pero tiene descriptores del contorno obtenidos con DFM, ImageCLEF 2012 (101 clase) y PERALD (27 clases) sin y con características de textura. En el primer caso, se observa que al combinar las características de DFM con los otros conjuntos de características, siempre se encuentra una mejora, es así por ejemplo que la combinación de los conjuntos de Haralick y momentos de color nos dan una precisión de 79,85 %, pero al incrementar el conjunto de características de Dimensión Fractal Multiescala, el acierto sube a 88,31 %. De igual manera, la combinación de características de los conjuntos de Redes Complejas, Haralick y Momentos de Color, otorgan una precisión de 86,61 %, pero cuando añadimos el conjunto de datos de Dimensión Fractal Multiescala, con mucha satisfacción verificamos que el acierto también se incrementa, a 90,41 %, siendo esta la mejor tasa de discriminación que se haya alcanzado, mejorando incluso el resultado encontrado en la literatura, que trabajó con la misma base de datos y un proceso similar (Brilhador *et al.*, 2013).

En el segundo y tercer caso, el comportamiento de los resultados coincide con el primer caso. Al combinar las características de Dimensión Fractal Multiescala (ImageCLEF 2012, 101 especies) con los otros conjuntos, siempre se encuentra una mejora; por ejemplo, combinación de los conjuntos de Haralick y momentos de color da una precisión de 77,26 %, pero al incrementar el conjunto de DFM aplicado al contorno y a la textura, el acierto sube a 89,14 %. Lo mismo sucede en caso de PERALD, hojas envés y haz, por ejemplo, combinación de los conjuntos de Haralick y Momentos de Color da

una precisión de 93,70 %, pero al incrementar el conjunto de DFM aplicado al contorno y a la textura, el acierto sube a 96,18 %.

Con lo desarrollado en el presente trabajo, se ha verificado que el conjunto de características extraídas mediante el método Bouligand-Minkowski ha aportado a la mejora de la clasificación de hojas de plantas. Al tener como hipótesis que la textura de las hojas presenta un comportamiento fractal, se buscó con el presente trabajo caracterizar esa propiedad mediante algoritmos que simulan el comportamiento fractal y a partir de ellos extraer las medidas que las caracterizan.

5.2. Recomendaciones y trabajos futuros

Como trabajo futuro se propone aplicar el método a un mayor conjunto de especies de plantas, de manera que este se constituya en parte de la metadata del proyecto de catálogo digital de plantas que se viene desarrollando en el proyecto del cual es parte el presente trabajo.

Se recomienda trabajar con otros clasificadores y otros extractores que puedan permitir la mejora de la tasa de clasificación. Del mismo modo, al tener una mayor cantidad de información, el proceso de caracterización y clasificación toma mayor tiempo, por lo que también se recomienda trabajar con técnicas de procesamiento paralelo y aplicar estrategias de aprendizaje profundo.

Bibliografía

- Aakif, A. y Khan, M. F. (2015). Automatic classification of plants based on their leaves. *Biosystems Engineering*, 139(Supplement C):66 – 75.
- Ahmed, N., Khan, U. G., y Asif, S. (2016). An automatic leaf based plant identification system. *Sci. Int*, 28(1):427–430.
- Arun Priya, C., Balasaravanan, T., y Thanamani, A. (2012). An efficient leaf recognition algorithm for plant classification using support vector machine. En *Pattern Recognition, Informatics and Medical Engineering (PRIME), 2012 International Conference on*, pp. 428–432.
- Backes, A. y Bruno, O. (2009). Plant leaf identification using multi-scale fractal dimension. En Foggia, P., Sansone, C., y Vento, M., editores, *Image Analysis and Processing – ICIAP 2009*, volumen 5716 de *Lecture Notes in Computer Science*, pp. 143–150. Springer Berlin Heidelberg.
- Backes, A. y Bruno, O. (2010). Plant leaf identification using color and multi-scale fractal dimension. En Elmoataz, A., Lezoray, O., Nouboud, F., Mammass, D., y Meunier, J., editores, *Image and Signal Processing*, volumen 6134 de *Lecture Notes in Computer Science*, pp. 463–470. Springer Berlin Heidelberg.
- Backes, A. R. y Bruno, O. M. (2012). Fractal and multi-scale fractal dimen-

- sion analysis: a comparative study of bouligand-minkowski method. *arXiv preprint arXiv:1201.3153*.
- Backes, A. R., Casanova, D., y Bruno, O. M. (2009). Plant leaf identification based on volumetric fractal dimension. *International Journal of Pattern Recognition and Artificial Intelligence*, 23(06):1145–1160.
- Backes, A. R., Casanova, D., y Bruno, O. M. (2012). Color texture analysis based on fractal descriptors. *Pattern Recognition*, 45(5):1984–1992.
- Beghin, T., Cope, J. S., Remagnino, P., y Barman, S. (2010). *Advanced Concepts for Intelligent Vision Systems: 12th International Conference, ACIVS 2010, Sydney, Australia, December 13-16, 2010, Proceedings, Part II*, capítulo Shape and Texture Based Plant Leaf Classification, pp. 345–353. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Brilhador, A., Colonhezi, T. P., Bugatti, P. H., y Lopes, F. M. (2013). Combining texture and shape descriptors for bioimages classification: a case of study in imageclef dataset. En *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, pp. 431–438. Springer.
- Coggins, J. M. (1983). *A Framework for Texture Analysis Based on Spatial Filtering*. Tesis doctoral, East Lansing, MI, USA. AAI8315444.
- Cope, J. S., Corney, D., Clark, J. Y., Remagnino, P., y Wilkin, P. (2012). Plant species identification using digital morphometrics: A review. *Expert Systems with Applications*, 39(8):7562–7573.
- da Fontoura Costa, L. y Cesar Jr., R. M. (2009). *Shape Classification and Analysis: Theory and Practice*. CRC Press, Inc., Boca Raton, FL, USA, 2nd edición.

- Devyver, P. y Kittler, J. (1982). *Pattern Recognition: A Statistical Approach*. Prentice-Hall.
- Du, J.-X., Wang, X.-F., y Zhang, G.-J. (2007). Leaf shape based plant species recognition. *Appl. Math. Comput.*, 185(2):883–893.
- Du, J.-x., Zhai, C.-M., y Wang, Q.-P. (2013). Recognition of plant leaf image based on fractal dimension features. *Neurocomputing*, 116:150–156.
- Falconer, K. (2004). *Fractal geometry: mathematical foundations and applications*. John Wiley & Sons.
- Fu, K.-S. y Rosenfeld, A. (1976). Pattern recognition and image processing. *IEEE transactions on computers*, 25(12):1336–1346.
- Goëau, H., Bonnet, P., Joly, A., Bakic, V., Barthélémy, D., Boujemaa, N., y Molino, J.-F. (2013). The imageclef 2013 plant identification task. En *CLEF*.
- Gonzalez, R. C. y Woods, R. E. (2006). *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA.
- Haralick, R. M. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5):786–804.
- Haralick, R. M., Shanmugam, K., y Dinstein, I. H. (1973). Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, (6):610–621.
- Harish, B. S., Hedge, A., Venkatesh, O., Spoorthy, D. G., y Sushma, D. (2013). Classification of plant leaves using morphological features and zernike moments. En *Advances in Computing, Communications and Informatics (ICACCI), 2013 International Conference on*, pp. 1827–1831.

- Hausdorff, F. (1918). Dimension und äußeres maß. *Mathematische Annalen*, 79(1):157–179.
- Jelinek, H. F. y Fernandez, E. (1998). Neurons and fractals: how reliable and useful are calculations of fractal dimensions? *Journal of neuroscience methods*, 81(1):9–18.
- Jobin, A., Nair, M. S., y Tatavarti, R. (2012). Plant identification based on fractal refinement technique (frt). *Procedia Technology*, 6:171 – 179. 2nd International Conference on Communication, Computing & Security [ICCCS-2012].
- Kadir, A., Nugroho, L. E., Susanto, A., y Santosa, P. I. (2012). Experiments of zernike moments for leaf identification. *Journal of Theoretical and Applied Information Technology (JATIT)*, 41(1):82–93.
- Kebapci, H., Yanikoglu, B., y Unal, G. (2010). Plant image retrieval using color, shape and texture features. *The Computer Journal*, p. bxq037.
- Kerut, E. K., Given, M., y Giles, T. D. (2003). Review of methods for texture analysis of myocardium from echocardiographic images: a means of tissue characterization. *Echocardiography*, 20(8):727–736.
- Khotanzad, A. y Hong, Y. H. (1990). Invariant image recognition by zernike moments. *IEEE Transactions on pattern analysis and machine intelligence*, 12(5):489–497.
- Laine, A. y Fan, J. (1993). Texture classification by wavelet packet signatures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11):1186–1191.

- Larese, M. G., Bayá, A. E., Craviotto, R. M., Arango, M. R., Gallo, C., y Granitto, P. M. (2014). Multiscale recognition of legume varieties based on leaf venation images. *Expert Systems With Applications*, 41(10):4638–4647.
- Laws, K. I. (1980). Textured image segmentation. Technical report, DTIC Document.
- Lopes, R. y Betrouni, N. (2009). Fractal and multifractal analysis: A review. *Medical Image Analysis*, 13(4):634 – 649.
- Mandelbrot, B. B. (1983). *The Fractal Geometry of Nature*. W. H. Freedman and Co., New York.
- Manjunath, B. S., Ohm, J.-R., Vasudevan, V. V., y Yamada, A. (2001). Color and texture descriptors. *IEEE Transactions on circuits and systems for video technology*, 11(6):703–715.
- Martinez, O. B., de Oliveira Plotze, R., Falvo, M., y de Castro, M. (2008). Fractal dimension applied to plant identification. *Information Sciences*, 178(12):2722–2733.
- Naresh, Y. y Nagendraswamy, H. (2016). Classification of medicinal plants: An approach using modified lbp with symbolic representation. *Neurocomputing*, 173(Part 3):1789 – 1797.
- Nixon, M. y Aguado, A. (2002). *Feature Extraction and Image Processing*. Electronics & Electrical. Newnes.
- Oncevay-Marcos, A., Juarez-Chambi, R., Khlebnikov-Núñez, S., y Beltrán-Castañón, C. (2015). Leaf-based plant identification through morphological characterization in digital images. En *Computer Analysis of Images and Patterns*, pp. 326–335. Springer.


- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11(285-296):23–27.
- Peitgen, H.-O., Jürgens, H., y Saupe, D. (1992). *Recursive Structures: Growing of Fractals and Plants*, pp. 9–65. Springer New York, New York, NY.
- Pinedo, P., Rengifo, M., Cerruti, E., y Pinedo, T. M. (1997). *Plantas medicinales de la amazonia peruana: estudio de su uso y cultivo*. Número SB293 P65.
- Plotze, R. d. O., Falvo, M., Pádua, J. G., Bernacci, L. C., Vieira, M. L. C., Oliveira, G. C. X., y Bruno, O. M. (2005). Leaf shape analysis using the multiscale minkowski fractal dimension, a new morphometric method: a study with passiflora (passifloraceae). *Canadian Journal of Botany*, 83(3):287–301.
- Pydipati, R., Burks, T., y Lee, W. (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture*, 52(1–2):49 – 59.
- Rashad, M., El-Desouky, B., y Khawasik, M. S. (2011). Plants images classification based on textural features using combined classifier. *International Journal of Computer Science and Information Technology*, 3(4):93–100.
- Rumelhart, D. E., Hinton, G. E., y Williams, R. J. (1988). Neurocomputing: Foundations of research. capítulo Learning Internal Representations by Error Propagation, pp. 673–695. MIT Press, Cambridge, MA, USA.
- Russ, J. C. (2016). *The image processing handbook*. CRC press.

- Sack, L. y Scoffoni, C. (2013). Leaf venation: structure, function, development, evolution, ecology and applications in the past, present and future. *New Phytologist*, 198(4):983–1000.
- Schroeder, M. (2009). *Fractals, chaos, power laws: Minutes from an infinite paradise*. Courier Corporation.
- Simpson, M. (2010). *Plant Systematics*. Elsevier Science.
- Takayasu, H. (1990). *Fractals in the physical sciences*. Manchester University Press.
- Theodoridis, S. y Koutroumbas, K. (2009). Chapter 7 - feature generation {II}. En Theodoridis, S., , y Koutroumbas, K., editores, *Pattern Recognition (Fourth Edition)*, pp. 411 – 479. Academic Press, Boston, fourth edition edición.
- Tricot, C. (1994). *Curves and fractal dimension*. Springer Science & Business Media.
- Tuceryan, M. y Jain, A. K. (1993a). Handbook of pattern recognition and computer vision. capítulo Texture Analysis, pp. 235–276. World Scientific Publishing Co., Inc., River Edge, NJ, USA.
- Tuceryan, M. y Jain, A. K. (1993b). Texture analysis. *Handbook of pattern recognition and computer vision*, 2:207–248.
- Vianna, G. y Cruz, S. (2014). Using multilayer perceptron networks in early detection of late blight disease in tomato leaves. En *Proceedings on the International Conference on Artificial Intelligence (ICAI)*, p. 1. The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp).

- Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y.-X., Chang, Y.-F., y Xiang, Q.-L. (2007). A leaf recognition algorithm for plant classification using probabilistic neural network. En *Signal Processing and Information Technology, 2007 IEEE International Symposium on*, pp. 11–16. IEEE.
- Xie, X. (2008). A review of recent advances in surface defect detection using texture analysis techniques. *ELCVIA Electronic Letters on Computer Vision and Image Analysis*, 7(3).
- Yanikoglu, B., Aptoula, E., y Tirkaz, C. (2014). Automatic plant identification from photographs. *Machine Vision and Applications*, 25(6):1369–1383.
- Yanikoglu, B. A., Aptoula, E., y Tirkaz, C. (2012). Sabanci-okan system at imageclef 2012: Combining features and classifiers for plant identification. En *CLEF (Online Working Notes/Labs/Workshop)*.
- Zhang, G.-J., Wang, X.-F., Huang, D.-S., Chi, Z., Cheung, Y.-M., Du, J.-X., y Wan, Y.-Y. (2004). A hypersphere method for plant leaves classification. En *Intelligent Multimedia, Video and Speech Processing, 2004. Proceedings of 2004 International Symposium on*, pp. 165–168.
- Zhang, H., Yanne, P., y Liang, S. (2012). Plant species classification using leaf shape and texture. En *Industrial Control and Electronics Engineering (ICICEE), 2012 International Conference on*, pp. 2025–2028. IEEE.

Apéndice A

Artículo presentado en
CAIP2015



Leaf-Based Plant Identification Through Morphological Characterization in Digital Images

Arturo Oncevay-Marcos^(*), Ronald Juarez-Chambi, Sofía Khlebnikov-Núñez,
and César Beltrán-Castañón

Department of Engineering, Research Group on Pattern Recognition and Applied
Artificial Intelligence, Pontificia Universidad Católica Del Perú, Lima, Perú
{foncevay,ronald.juarez,cbeltran}@pucp.pe, sjlebn@pucp.edu.pe

Abstract. The plant species identification is a manual process performed mainly by botanical scientists based on their experience. In order to improve this task, several plant classification processes has been proposed applying pattern recognition. In this work, we propose a method combining three visual attributes of leaves: boundary shape, texture and color. Complex networks and multi-scale fractal dimension techniques were used to characterize the leaf boundary shape, the Haralick's descriptors for texture were extracted, and color moments were calculated. Experiments were performed on the ImageCLEF 2012 train dataset, scan pictures only. We reached up to 90.41% of accuracy regarding the leaf-based plant identification problem for 115 species.

Keywords: Leaf-based plant identification · Complex networks · Multi-scale fractal dimension · Haralick's descriptors · Color moments

1 Introduction

Taxonomic classification of plants is a difficult challenge to botanists due to the great biodiversity of plant species and the variety of different biological attributes to analyze. Botanists have the duty of preserve and increase the content of herbariums and plant catalogs from species collection and identification tasks. Now the identification challenge is moved to a computational approach, applying pattern recognition techniques to automatize the plant identification task using digital images of leaves.

In pattern recognition, a set of visual morphological traits are gathered to design or apply mathematical models which allow species discrimination and identification. There are many techniques in the literature related to leaf-based identification by using digital images because is the part of the plant with most visual attributes and properties: shape, boundary, color, texture, venation and so forth [1]. Some of this approaches are described below.

Leaf boundary features often were extracted taking into account the region they cover [2] or the contour analysis [3]. Another approach is carried out on the

basis of leaf skeletonization [4] that can be extended to the leaf venation composition. A variety of techniques are applied over skeleton leaf such as complex networks [5–7] and fractal dimension [1, 5, 6, 8].

Another potential features are the color and texture of the leaf. Color is usually analyzed in image retrieval problems based on visual contents [9]. In addition, four color moments are extracted from leaf-based plant identification process [10, 11]. On the other hand, the texture characteristics are used for leaf classification, and although texture features can not discriminate plants on their own, they could be merged with other descriptors [12]. In this approach, some of the most tested features are based on Gabor filters [13, 14], Local Binary Patterns (LBP) [6, 14] and Gray Level Co-occurrence Matrix (GLCM) [15, 16].

In this paper, a leaf feature vector is obtained by processing boundary shape, color and texture properties. Complex networks and Multi-scale fractal dimension were used to extract boundary features. The Haralick's descriptors were extracted from the texture leaf area by using GLCM, and three color moments were computed (standard deviation, asymmetry and kurtosis). Then, we trained a multilayer perceptron classifier with these features. The experimentation was performed on the ImageCLEF 2012 leaf image dataset [17]. Also, a 10-fold cross validation proves high acceptance rate for the implemented framework.

The rest of the paper is organized as follows, in Section 2 we describe briefly the procedure proposed for the image processing and classification; Section 3 explains the conceptual framework of the features extracted. Furthermore, experimentation and results were detailed in Section 4. Finally, Section 5 presents the conclusion about our results and future works.

2 Procedure

The proposed procedure for this study is shown in Fig. 1. The digital images of scanned leaves go through a pre-processing phase for the leaf area segmentation using Otsu approach [18]. Also, the leaf contour and venation (known as leaf skeleton) has been extracted. Figure 2 shows the desired result. For this work, we only consider the leaf boundary for shape features extraction. The complete extraction process is explained in the next section. At the end, we applied the multilayer perceptron (MLP) [19] with the features extracted as input.




Fig. 1. Proposed procedure for the study




Fig. 2. Image leaf pre-processing (skeletonization)

3 Feature Extraction

3.1 Complex Networks for Boundary Shape Approach

In general, a graph or network is a set of elements called nodes and connections known as edges. However, a complex network refers to a graph with no trivial properties compared with simple graphs, as well as it has considerable number of nodes and edges [20].

There are many theoretical models of complex networks such as Erdős-Rényi, scale-free, random models, etc. In this paper we used Watts-Strogatz network model which owns a small-world property [21]. The study of the dynamic properties of this model —measurements were obtained from the evolution based on number of connected components— will produce a set of descriptors or a feature vector which will be used for the classification task [22].

Degree Descriptors Using Complex Networks Signature. In this section, we describe the process of signature characterization focused on complex network [20]. Let S the boundary leaf trace represented as a set of points $S = [s_1, s_2, \dots, s_N]$, whose components $s_i = [x_i, y_i]$ represent each vertex i of the boundary contour. Then, in order to apply complex networks theory to this problem, we have created the equivalence of S as a representation of graph $G = \langle V, E \rangle$. Each pixel of the skeleton is represented as a node of the network, i.e. $S = V$. A set of edges E connect each pair of vertices establishing, in this way, the network. E is calculated using Euclidean distance d . Therefore, the matrix is represented by the adjacency matrix with weight W and dimension $N \times N$:

$$w_{ij} = W([w_i, w_j]) = d(s_i, s_j) \quad (1)$$

Dynamic Evolution on Complex Networks. Initially, the set of edges E connect all vertex in the network, as a network with regular behavior. However, a regular network does not have any particular property. Therefore, it is necessary to convert this initial regular network in a complex network, in order to use relevant properties that can be applied later. In this sense, a threshold transformation is used. This approach allows a characterization that describes a

list of transient features of the dynamic evolution of the network. Also, a degree normalization is required. For this reason, after consider the network transformation, the feature vector denoted by φ is calculated as the concatenation of the average (k_μ) and maximum degree (k_κ) for each stage of the network evolution and thus we get the characterization proposed for a signature by using complex networks [5].

$$\varphi = [k_\mu(T_0), k_\kappa(T_0), k_\mu(T_1), \dots, k_\mu(T_Q), k_\kappa(T_Q)] \tag{2}$$

3.2 Multi-scale Fractal Dimension for Boundary Shape Extraction

The fractal dimension is a characteristic to measure leaf’s shape complexity. In this work we will use the Bouligand-Minkowski method. According to this method, fractal dimension is defined as $FD \sim 2 - \frac{\log A(d)}{\log(d)}$, where $A(d)$ is the area of the leaf dilated by a distance d . The method is based on the correlation between an object boundary and the space it occupies [1, 8].

In summary, the method applies dilatation process to the object (leaf), obtaining the ratio between the area and the radius of the dilatation. The object dilatation is obtained by using a set of distances:

$D = \{1, \sqrt{2}, 2, \sqrt{5}, \sqrt{8}, 3, \sqrt{10}, \dots, d\}$, where D is the Euclidean distance between pixel’s position which is calculated using Euclidean Distance Transform (EDT) (as seen in Fig. 3). For each distance, the object area is calculated. In this case, the area is the sum of all pixels between original object and the dilatation with the distance d .

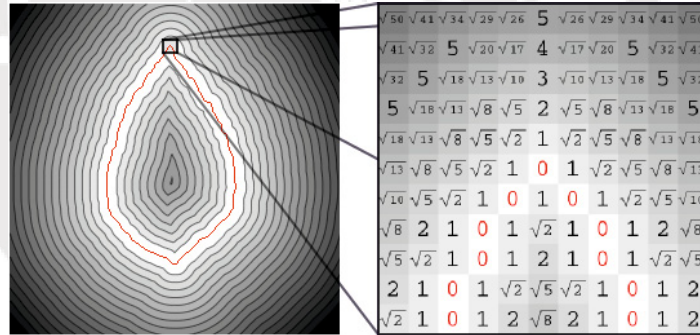


Fig. 3. Image of a leaf boundary after dilatation (left). Zoom in to a sample of distances (right).

The Fractal dimension (FD) is estimated by the $\log A(d)-\log(d)$ curve (as seen in Fig. 4), and the gradient of this curve is the fractal dimension.

Sometimes, the FD numeric value cannot describe the complexity of an object or does not have enough useful information, because two objects may have a similar value but belong to different classes. Another disadvantage is the dependence on the used scale [23]. Then, in order to improve the characterization of an object, the Multi-scale Fractal Dimension (MFD) was used. This is defined as:

$$MFD = 2 - \frac{du(t)}{dt} \tag{3}$$




Fig. 4. $\log A(d)$ by $\log(d)$ curve

where $du(t)/dt$ represents the derivative of the *log-log* curve.

In this way, to obtain the MFD, we need to calculate the derivative of the *log-log* curve. In order to get this derivative, we need to smooth the *log-log* curve to clean high frequency noise. To do this, we applied at regular steps of δ size a Gaussian smoothing filter with $\sigma = \delta/2\pi$. After testing different values of δ , we found that a value of 0.05 gave us the best success rate in the identification task. A sample for the mentioned curves is shown in Fig. 5.

3.3 Color and Texture Features

Color Moments. Color moments are measures that allow similarity analysis between images through its colors. The moments are used because the different values in a color channel (from an image) could represent a probabilistic distribution. In this way, the central moments that describes a probability distribution function are used in the characterization of image colors [24].

Due to the statistical descriptive nature of the moments, this features are scalable and invariant to image rotation. The three main color moments applied by Stricker and Orengo [25] are: Mean, Standard Deviation and Asymmetry. The last one provides information about the form of the color distribution (how much symmetric or assymetric). Besides, it had been considered another color moment called Kurtosis [11], that also analyzes the distribution form by processing the proportion of the variance regarding the concentration of the near and far values to the Mean. In this work, the Mean was not considered in the analysis due to the variation of the leaf color tone through different seasons (reflected in the image dataset). Finally, the three remaining moments were calculated due to the valuable information regarding the form of the distribution of values in each RGB color space channel.

Haralick's Descriptors. The texture features proposed by Haralick [26] are statistical descriptors, and they are extracted from matrices known as GLCM (Gray Level Co-occurrence Matrix). These matrices represent the distribution of




Fig. 5. Sample of MFD curves for 4 objects of two different classes. The curves of one class are shown using dashed lines, while the other ones have a solid style.

the different gray levels in pixels of an image and they have a widespread use in the image processing area due to its ability to obtain valuable information about neighboring pixels in different positions on an image [27].

Because of the amount of values embedded in the GLCM, Haralick proposes a reduction to fourteen statistical descriptors: f_H^1 a f_H^{14} . These descriptors preserve the relevance of the content in the matrix. For this research, the GLCM was calculated using four directions (0° , 90° , 180° , 270°), which is usually applied in biological textures [28], and a distance $d = 1$ in order to take advantage of the analysis at the pixel adjacency level. The fourteen descriptors are calculated for each of the four directions in the neighborhood, and this also helps to reduce the dependence on the GLCM with image rotation caused by the properties of spatial relationships of the pixels.

4 Results and Discussion

For the experimentation, the selected digital images correspond to the scan leaves from the training dataset of the ImageCLEF 2012 [17]. The whole dataset is composed by images (scanned, scan-like and photograph) from 126 plant species, but only 115 plant species have scan digital images of their leaves, with a total of 4,870 instances.

For this image dataset, features described in Section 3 were extracted, and a MLP classification algorithm was trained through a 10-fold cross validation. The number of attributes for each kind of features are shown in Table 1.

The results from the classification process with different combinations of the features are displayed in Table 2. It is shown that each group of features contributes to the improvement of the classification result. For instance, the boundary approach from complex networks and multi-scale fractal dimension features perform well individually and in combination. On the other hand, the color and texture features overcome expectations working in pair, and they show satisfying results as complements from the other attributes too.

Table 1. Features extracted

Abv.	Groups of Features	#features
CND	Complex Network Degree descriptors	26
MFD	Multi-scale Fractal Dimension with $d = 0.05$	68
Har	14 Haralick's descriptors in 4 directions	56
Col	3 Color moments in each RGB's channels	9
	Total	159

Table 2. Results from classification

Features included	#features	Accuracy (%)
CND	26	45.83
MFD	68	64.78
(Har + Col)	65	79.85
CND + MFD	94	72.03
CND + (Har + Col)	91	86.61
MFD + (Har + Col)	94	88.31
CND + MFD + (Har + Col)	159	90.41

Regarding the best general result, it is obtained from the combination of all features with a 90.41% of accuracy. This score value moderately exceeds a study in the same image dataset with a similar process [29], where a maximum accuracy of 87.5% was achieved, with 218 features and even fewer species (only 54 plant species were analyzed due to the unbalanced number of samples for each class).

In order to analyze how many of the correctly classified samples are relevant, we make a detailed review of the precision score, which in our best result reached up to 90.3% (almost equal to the accuracy). Figure 6 shows a scatterplot of the individual precision obtained by each plant species versus the different number of images found in the dataset, and the analysis for this classification result is described below.

First at all, it is observed that the rightmost points (meaning a bigger number of images for each plant species) have obtained a high precision value. Also, there are eight plant species that achieved a 100% score in this metric, and their number of images is between 10 and 181, which is the maximum value. This fact supports a good overall score of the classification process.

On the other hand, it is noted that there is a very little number of plant species that obtained a precision value below to 50%. In detail, there are eleven plant species in this range, and eight of them have zero precision. However, these plant species contain the fewest number of images in the dataset (less than 10, and even several species with less than 5 images). That is the reason why those plant species got a low (even zero) score, but it did not affect the overall outcome significantly.




Fig. 6. From the best classification result: individual precision versus the number of images per each plant species



Fig. 7. An image sample of each plant species that achieved 100% precision on the best classification result



Fig. 8. An image sample of each plant species with zero precision on the best classification result

An image sample for the best (100% precision) and worst (zero precision) classified species from our best classification model are shown in Fig. 7 and Fig. 8, respectively. As can be seen, there are visual properties with significant differences between the image samples from both sides. Therefore, with a balanced number of images for each plant species, the overall outcome could be improved. However, the obtained results are promising, because only eight plant species (out of 115 in total) were negated by the classifier, and only three other species couldn't surpass a 50% precision margin.

5 Conclusion and Future Work

In this study, we propose a procedure for leaf-based plant identification through visual attributes extracted from digital images. We have analyzed the boundary shape (by using complex networks and multi-scale fractal dimension), texture (by extracting Haralick's descriptors) and color (with three moments: standard deviation, assymetry and kurtosis). The best classification result with the MLP achieved 90.41% of accuracy, and this is an auspicious value in the task of automatic plant specie classification from leaf digital images. Besides, there were only few species that could not obtain a relevant individual score (11 of 115 classes below a 50% precision margin).

As future work, venation features will be extracted applying complex networks and multi-scale fractal dimension from the leaf skeleton. In addition, the proposed process will be tested on other leaves image dataset, including a plant catalog (under development) collected from Amazon in Perú. Finally, the performance and time processing will be analyzed in order to scale the procedure to a bigger dataset.

Acknowledgments. For this study, the authors acknowledge the support of CONCYTEC-Perú with STIC-AmSud 2013 under the FERMI project, and the Programa Nacional de Innovación para la Competitividad y Productividad, Perú, under the contract 183-FINCyT-IA-2013. This paper is part of a bigger research project funded by grants from the aforementioned Peruvian government programs.

References

1. Bruno, O.M., de Oliveira Plotze, R., Falvo, M., de Castro, M.: Fractal dimension applied to plant identification. *Inf. Sci.* **178**(12), 2722–2733 (2008)
2. Lee, C.L., Chen, S.Y.: Classification of leaf images. *Int. J. Imaging Syst. Technol.* **16**(1), 15–23 (2006)
3. Pauwels, E.J., de Zeeuw, P.M., Ranguelova, E.B.: Computer-assisted tree taxonomy by automated image recognition. *Eng. Appl. Artif. Intell.* **22**(1), 26–31 (2009)
4. Gu, X., Du, J.-X., Wang, X.-F.: Leaf recognition based on the combination of wavelet transform and gaussian interpolation. In: Huang, D.-S., Zhang, X.-P., Huang, G.-B. (eds.) *ICIC 2005*. LNCS, vol. 3644, pp. 253–262. Springer, Heidelberg (2005)
5. Backes, A.R., Bruno, O.M.: Shape classification using complex network and multi-scale fractal dimension. *Pattern Recogn. Lett.* **31**(1), 44–51 (2010)
6. Casanova, D., Florindo, J.B., Gonçalves, W.N., Bruno, O.M.: Ifsc/usp at imageclef 2012: plant identification task. In: *Proceeding of CLEF 2012 Labs and Workshop, Notebook Papers* (2012)
7. Arora, A., Gupta, A., Bagmar, N., Mishra, S., Bhattacharya, A.: A plant identification system using shape and morphological features on segmented leaflets: team iitk, clef 2012. In: *Proceeding of CLEF 2012 Labs and Workshop, Notebook Papers* (2012)
8. de Oliveira Plotze, R., Falvo, M., Pádua, J.G., Bernacci, L.C., Vieira, M.L.C., Oliveira, G.C.X., Bruno, O.M.: Leaf shape analysis using the multiscale minkowski fractal dimension, a new morphometric method: a study with passiflora (passifloraceae). *Can. J. Bot.* **83**(3), 287–301 (2005)

9. Zhang, X., Zhang, F.: Images features extraction of tobacco leaves. In: Congress on Image and Signal Processing, CISP 2008, vol. 2, 773–776. IEEE (2008)
10. Man, Q.K., Zheng, C.H., Wang, X.F., Lin, F.Y.: Recognition of plant leaves using support vector machine. In: Huang, D.-S., Wunsch II, D.C., Levine, D.S., Jo, F.-Y. (eds.) ICIC 2008. CCIS, vol. 15, pp. 192–199. Springer, Heidelberg (2008)
11. Kadir, A., Nugroho, L.E., Susanto, A., Santosa, P.I.: Leaf classification using shape, color, and texture features. arXiv preprint [arXiv:1401.4447](https://arxiv.org/abs/1401.4447) (2013)
12. Choras, R.S.: Image feature extraction techniques and their applications for cbir and biometrics systems. *International Journal of Biology and Biomedical Engineering* **1**(1), 6–16 (2007)
13. Kebapci, H., Yanikoglu, B., Unal, G.: Plant image retrieval using color, shape and texture features. *The Computer Journal* (2010) bxq037
14. Lin, F.Y., Zheng, C.H., Wang, X.F., Man, Q.K.: Multiple classification of plant leaves based on gabor transform and IBP operator. In: Huang, D.-S., Wunsch II, D.C., Levine, D.S., Jo, K.-H. (eds.) ICIC 2008. CCIS, vol. 15, pp. 432–439. Springer, Heidelberg (2008)
15. Ehsanirad, A.: Plant classification based on leaf recognition. *International Journal of Computer Science and Information Security* **8**(4), 78–81 (2010)
16. Kadir, A., Nugroho, L.E., Susanto, A., Santosa, P.I.: Neural network application on foliage plant identification. arXiv preprint [arXiv:1311.5829](https://arxiv.org/abs/1311.5829) (2013)
17. Goëau, H., Bonnet, P., Joly, A., Barthelemy, D., Boujemaa, N., Molino, J.: The imageclef 2012 plant image identification task. In: *ImageCLEF 2012 Working Notes* (2012)
18. Otsu, N.: A threshold selection method from gray-level histograms. *Automatica* **11**(285–296), 23–27 (1975)
19. Werbos, P.: *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. (1974)
20. Backes, A.R., Casanova, D., Martinez, O.B.: A complex network-based approach for boundary shape analysis. *Pattern Recogn.* **42**, 54–67 (2009)
21. Barabási, A.L.: *Linked: The new science of networks*. (2002)
22. Castañón, C.A.B., Chambi, R.J.: Using complex networks for offline handwritten signature characterization. In: Bayro-Corrochano, E., Hancock, E. (eds.) *CIARP 2014*. LNCS, vol. 8827, pp. 580–587. Springer, Heidelberg (2014)
23. Backes, A.R., Martinez, O.: Fractal and multi-scale fractal dimension analysis: a comparative study of bouligand-minkowski method. *CoRR* abs/1201.3153 (2012)
24. Shih, J.-L., Chen, L.-H.: Color image retrieval based on primitives of color moments. In: Chang, S.-K., Chen, Z., Lee, S.-Y. (eds.) *VISUAL 2002*. LNCS, vol. 2314, p. 88. Springer, Heidelberg (2002)
25. Stricker, M.A., Orengo, M.: Similarity of color images. In: *IS&T/SPIE's Symposium on Electronic Imaging: Science & Technology*, International Society for Optics and Photonics, pp. 381–392 (1995)
26. Haralick, R.M., Shanmugam, K., Dinstein, I.H.: Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics* **6**, 610–621 (1973)
27. Gonzalez, R.C., Woods, R.E.: *Digital image processing* (2002)
28. Porebski, A., Vandenbroucke, N., Macaire, L.: Neighborhood and haralick feature extraction for color texture analysis. In: *Conference on Colour in Graphics, Imaging, and Vision*, Society for Imaging Science and Technology, vol. 2008, pp. 316–321 (2008)
29. Brillhador, A., Colonhezi, T.P., Bugatti, P.H., Lopes, F.M.: Combining texture and shape descriptors for bioimages classification: a case of study in imageCLEF dataset. In: Ruiz-Shulcloper, J., Sanniti di Baja, G. (eds.) *CIARP 2013, Part I*. LNCS, vol. 8258, pp. 431–438. Springer, Heidelberg (2013)