

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



PROYECTO FIN DE CARRERA

**Identificación de especies invasoras de plantas
en la isla de Gran Canaria a partir de su corteza**

Autor: Luis José Blanco Mier
Tutores: Carlos Manuel Travieso González
José María Quinteiro González
Pablo Hernández Morera
Titulación: Ingeniero de Telecomunicación
Fecha: Junio de 2016

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



PROYECTO FIN DE CARRERA

**Identificación de especies invasoras de plantas
en la isla de Gran Canaria a partir de su corteza**

HOJA DE FIRMAS

Alumno

Tutor

Fdo.: Luis José Blanco Mier

Fdo.: D. Carlos M. Travieso González

Tutor

Tutor

Fdo.: D. José M^a Quinteiro González

Fdo.: D. Pablo Hernández Morera

Fecha: Junio 2016

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



PROYECTO FIN DE CARRERA

TÍTULO DEL PROYECTO FIN DE CARRERA

HOJA DE EVALUACIÓN

Calificación: _____

Presidente

Fdo.: Nombre del Presidente

Vocal

Fdo.: Nombre del vocal

Secretario/a

Fdo.: Nombre del secretario

Fecha: Junio 2016

I. ÍNDICES

ÍNDICE

I. ÍNDICES	I
Índice de Ilustraciones	VII
Índice de Tablas	IX
Lista de acrónimos.....	XI
II. MEMORIA.....	1
CAPÍTULO 1: INTRODUCCIÓN.....	3
1.1 La biodiversidad	5
1.2 La biodiversidad en las islas Canarias	6
1.3 Marco tecnológico, social y económico	7
1.4 Antecedentes.....	9
1.4.1 Reconocedores automáticos de plantas	9
1.4.2 Desarrollo de Aplicaciones.....	13
1.5 Objetivo del proyecto	13
1.6 Estructura de la memoria.....	15
1.7 Peticionario	17
CAPÍTULO 2: LA BASE DE DATOS	17
2.1 Introducción.....	19
2.2 Recogida de muestras.....	19
2.3 Características de las imágenes	35
2.4 Sistemas y algoritmos de preprocesado de la imagen	36
2.4.1 Sistema Escala de grises (GRAY).....	37
2.4.2 Sistema de Ecuación del histograma (HistEq).....	38
2.4.3 Algoritmo NoBackground (NB)	39
CAPÍTULO 3: EXTRACCIÓN DE PARÁMETROS	43

3.1	Introducción	45
3.2	Local Binary pattern (LBP)	45
3.2.1	Metodología	45
3.2.2	Histograma (hLBP).....	47
3.2.3	Matriz (mLBP)	48
3.2.4	Algoritmos.....	49
3.3	Gray Level co-occurrence MATRIX (GLCM).....	50
3.4	Discrete Wavelet transform (DWT).....	53
3.5	Resize (RES).....	55
3.6	Sparse matrix (s...)	55
3.6.1	Metodología	56
3.6.2	Algoritmo	56
3.7	Estructura de los parámetros	56
CAPÍTULO 4: CLASIFICACIÓN		59
4.1	Introducción	61
4.2	Asignación de labels.....	61
4.3	Selección de muestras	63
4.3.1	Metodología	65
4.3.2	Entrenamiento	67
4.3.3	Test	70
4.4	La matriz de confusión	72
CAPÍTULO 5: EXPERIMENTOS Y RESULTADOS.....		75
5.1	Introducción	77
5.2	Metodología de experimentación.....	77
5.3	Experimentos cualitativos	78
5.3.1	Experimento 1: representación del algoritmo LBP	79

5.3.2	Experimento 2: Representación mapeada en color de LBP.....	81
5.3.3	Experimento 3: Representación múltiple de DWT de nivel 1.....	83
5.4	Experimentos cuantitativos	86
5.4.1	Árbol esquema	89
5.4.2	Experimento 4: Clasificador SVM con algoritmo LBP	93
5.4.3	Experimento 5: Algoritmo hLBP	93
5.4.4	Experimento 6: Sistema hLBP	94
5.4.5	Experimento 7: Introducción del DWT.....	99
5.4.6	Experimento 8: Compilación DWT	104
5.4.7	Experimento 9: GLCM	109
5.4.8	Experimento 10: DWT SOBRE GLCM	110
5.4.9	Experimento 11: DWT sobre MLBP y GLCM	113
5.5	Tabla resumen	116
CAPÍTULO 6: CONCLUSIONES Y LÍNEAS FUTURAS		117
6.1	Introducción.....	119
6.2	Cumplimiento de objetivos.....	119
6.3	Mejora de las prestaciones	121
6.4	Innovación.....	122
Referencias Bibliográficas.....		125
III. PROGRAMAS.....		131
PRO.1	Distribución de algoritmos.....	133
PRO.1.1	Módulo Principal (main.m).....	133
PRO.1.2	Módulo de Parametrización (Step1_Algorithms.m).....	133
PRO.1.3	Módulo de Clasificación (Step2_Classifier.m).....	134
PRO.1.4	Módulo de Resultados y Representaciones (Step3_Results.m).....	136
PRO.1.5	Funciones globales auxiliares	137

IV. PLIEGO DE CONDICIONES	139
PLI.1 Recursos <i>hardware</i> utilizados.....	141
PLI.2 Recursos <i>software</i> utilizados	141
V. PRESUPUESTO	143
PRE.1 Declaración Jurada	146
PRE.2 Desglose del presupuesto.....	147
PRE.2.1 Recursos Materiales	147
PRE.2.2 Trabajo Tarifado por el Tiempo Empleado	151
PRE.2.3 Derechos de visado del COIT	153
PRE.2.4 Gastos de tramitación y envío	154
PRE.2.5 Aplicación de impuestos.....	154

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Principales ecosistemas canarios	6
Ilustración 2: Imagen en color original	38
Ilustración 3: Imagen en escala de grises.....	38
Ilustración 4: Imagen original en escala de grises	39
Ilustración 5: Imagen ecualizada	39
Ilustración 6: Histograma de la imagen original.....	39
Ilustración 7: Histograma ecualizado	39
Ilustración 8: Imagen original	40
Ilustración 9: Imagen pixelada.....	40
Ilustración 10: Una iteración de LBP.....	46
Ilustración 11: Ejemplo de un histograma de 256 elementos.....	48
Ilustración 12: Interpretación de GLCM para 8 colores	50
Ilustración 13: Construcción de la GLCM	51
Ilustración 14: Variaciones de GLCM	52
Ilustración 15: Descomposición del espectro de la imagen	54
Ilustración 16: Representación de las imágenes resultantes de la DWT para 1, 2 y 3 niveles	55
Ilustración 17: Esquema del estiramiento producido por <i>sparse</i>	56
Ilustración 18: Representación del cálculo del hiperplano óptimo en una clasificación binaria	66
Ilustración 19: Esquema del entrenamiento del clasificador	68
Ilustración 20: Muestras correspondientes a dos clases representadas con dos parámetros	69
Ilustración 21: Definición de las regiones correspondientes a cada clase a partir de las muestras ...	70
Ilustración 22: Esquema del test del clasificador	71
Ilustración 23: Representación de tres muestras de test sobre un modelo entrenado	72
Ilustración 24: Ejemplo de una matriz de confusión con 2 clases	74

Ilustración 25: Esquema de un experimento cualitativo.....	78
Ilustración 26: Esquema de un experimento cuantitativo	78
Ilustración 27: Esquema de los algoritmos y sistemas de los experimentos 5 y 6	90
Ilustración 28: Esquema de los algoritmos y sistemas del experimento 7.....	91
Ilustración 29: Esquema de los algoritmos y sistemas de los experimentos del 8 al 11.....	92
Ilustración 30: Matriz de confusión del sistema hLBP con ecualización del histograma en clasificación de especies	95
Ilustración 31: Matriz de confusión del sistema hLBP con ecualización del histograma en clasificación de familias.....	96
Ilustración 32: Matriz de confusión del sistema hLBP con ecualización del histograma y sin <i>background</i> en clasificación de especies.....	97
Ilustración 33: Matriz de confusión del sistema hLBP con ecualización del histograma y sin <i>background</i> en clasificación de familias	98
Ilustración 34: Esquema de la aplicación de <i>resize+sparse</i>	103
Ilustración 35: Matriz de confusión de DWT1 completo para la clasificación por especies	105
Ilustración 36: Matriz de confusión de DWT1 completo para la clasificación por familias.....	106
Ilustración 37: Matriz de confusión de DWT2 completo para la clasificación por especies	107
Ilustración 38: Matriz de confusión de DWT2 completo para la clasificación por familias.....	108
Ilustración 39: Matriz de confusión de DWT y GLCM por especies	111
Ilustración 40: Matriz de confusión de DWT y GLCM por familias	112
Ilustración 41: Matriz de confusión de los tres sistemas más relevantes en una clasificación por especies	114
Ilustración 42: Matriz de confusión de los tres sistemas más relevantes en una clasificación por familias	115

ÍNDICE DE TABLAS

Tabla 1: Estado del arte sobre identificación de cortezas	12
Tabla 2: Características de las especies.....	27
Tabla 3: Origen, imagen general e imagen de muestra.....	34
Tabla 4: Código de <i>NoBackground</i>	42
Tabla 5: Código de LBP en su versión matriz.....	49
Tabla 6: Código de <i>sparse</i>	56
Tabla 7: Ejemplo de una estructura de parámetros	57
Tabla 8: Identificación de las familias	63
Tabla 9: Representación de la asignación de muestras.....	64
Tabla 10: Representación de mLBP	80
Tabla 11: Representación de mLBP con mapa de color.....	83
Tabla 12: Representación de 3 muestras al aplicarles la DWT de nivel 1	86
Tabla 13: Especificaciones del clasificador	88
Tabla 14: Resultados del algoritmo hLBP.....	93
Tabla 15: Resultados del sistema hLBP.....	94
Tabla 16: Resultados de la DWT de niveles del 1 al 4.....	100
Tabla 17: Resultados de la aplicación de <i>Nobackground</i> y <i>HistEq</i> sobre DWT	102
Tabla 18: DWT1 vs DWT1+2.....	104
Tabla 19: Resultados de la GLCM en las 4 direcciones	109
Tabla 20: Resultados de la DWT con GLCM.....	110
Tabla 21: Resultados de la aplicación de los tres sistemas más relevantes.....	113
Tabla 22: Resumen de los resultados	116
Tabla 23: Comparativa de los resultados de este trabajo con otros	121
Tabla 24: Costes de las herramientas Software.....	149

Tabla 25: Costes de las herramientas Hardware	150
Tabla 26: Factor de corrección de los honorarios	152
Tabla 27: Costes por tiempo empleado	152
Tabla 28: Coste de las herramientas y el tiempo empleado.....	153
Tabla 29: Cálculo del coste total del proyecto	154

LISTA DE ACRÓNIMOS

ACM: *Auto-correlation Method.*

COMM: *Co-Occurrence Matrix.*

DWT: *Discrete Wavelet Transform.*

EITE: *Escuela de Ingeniería de Telecomunicación y Electrónica.*

GLCM: *Gray-Level COMM.*

HLBP: *Histograma de LBP.*

HM: *Histogram Method.*

ITU: *Organización Internacional de las Telecomunicaciones.*

LBP: *Local Binary Pattern.*

LCLE: *Long Connection Length Emphasis.*

LSSVM: *Least Square SVM*

MMC: *Moving Median Centers.*

MNSM: *Multiple NSM.*

NN: *Neural Network.*

NSM: *Narrow Signal Model.*

PFC: *Proyecto Fin de Carrera.*

PNG: *Portable Network Graphics.*

RBF: *Radial Basis Function.*

RBPNN: *Radial Basis Probabilistic NN.*

RLM: *Run Length Method.*

SVM: *Support Vector Machine.*

TIC: *Tecnologías de la Información y la Comunicación.*

ULPGC: Universidad de Las Palmas de Gran Canaria.

II. MEMORIA



CAPÍTULO 1: INTRODUCCIÓN

Dios hizo nacer el árbol de vida y el árbol de la ciencia [...].

Génesis 2:9



1.1 LA BIODIVERSIDAD

La diversidad biológica, o biodiversidad, es el término por el que se hace referencia a la amplia variedad de seres vivos sobre la Tierra y los patrones naturales que la conforman. Esta diversidad forma la red vital de la cual todos forman parte integrante y de la cual tanto dependen. Ha hecho de la Tierra un lugar habitable y único para los seres humanos. Además, la diversidad biológica ofrece un gran número de bienes y servicios económicos, sociales y medioambientales [1].

La crisis de la biodiversidad es una amenaza seria al desarrollo humano. Pese a los renovados esfuerzos de estos últimos veinte años, la pérdida de diversidad biológica ha seguido su curso inexorable. Por lo tanto, es necesario actuar para salvar lo que queda [1]. Se han encontrado cinco causas principales que ocasionan esta pérdida:

- 1) El deterioro y la transformación del hábitat.
- 2) **La presencia y propagación de especies invasoras.**
- 3) La sobreexplotación de las poblaciones de especímenes.
- 4) La contaminación química de aire, agua y suelo.
- 5) El cambio climático sobre el ecosistema [2].

Para frenar la pérdida de biodiversidad hay que:

- Aumentar el esfuerzo de restauración de las especies en peligro.
- Reducir la explotación silvestre.
- **Conservar las áreas naturales.**

El interés de este proyecto radica en la conservación de las áreas naturales mediante la identificación y control de especies invasoras.

1.2 LA BIODIVERSIDAD EN LAS ISLAS CANARIAS

La problemática de la pérdida de la biodiversidad se hace todavía más relevante a nivel regional, puesto que el archipiélago canario posee una importante diversidad biológica, con una excepcional presencia de especies endémicas. Esto ha propiciado que las islas sean merecedoras de un reconocimiento universal. Su situación geográfica, relieve volcánico y especiales condiciones de aislamiento biológico [3] han dado lugar a una gran variedad de ecosistemas. Pasando por el cálido clima que ofrece la costa, se puede llegar a las húmedas selvas de la laurisilva, para luego subir hasta los secos matorrales de la cumbre (véase la Ilustración 1). Además, esta riqueza se extiende también a los ecosistemas marinos [4].

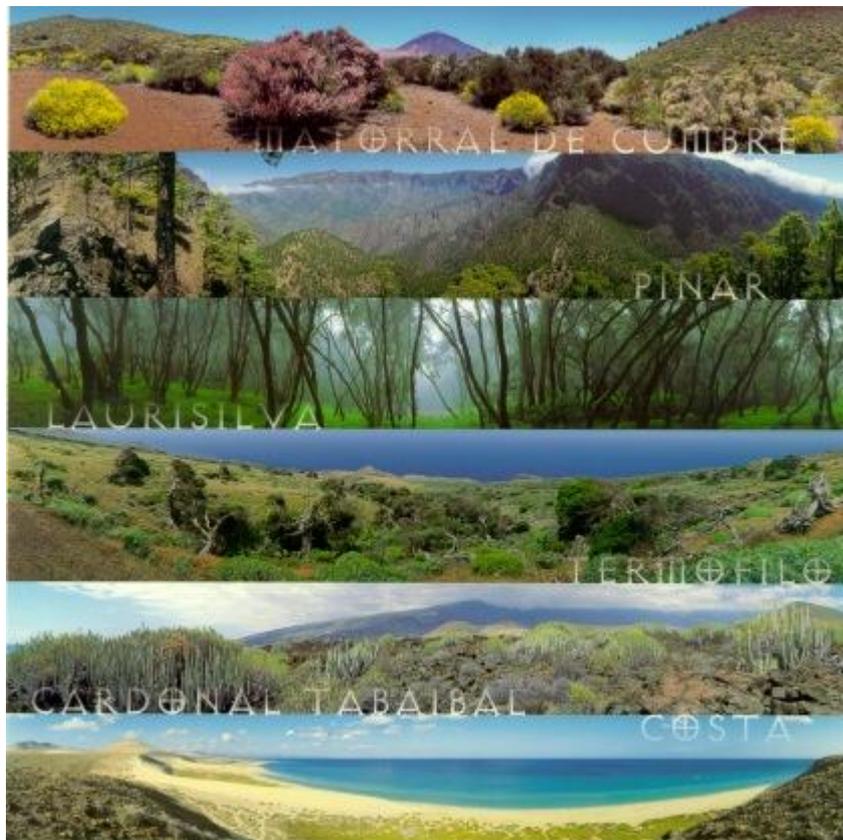


Ilustración 1: Principales ecosistemas canarios

Esta amplia variedad de ecosistemas ha favorecido el desarrollo de procesos evolutivos que han originado nuevas especies animales y vegetales. Se estima que casi el 30 % de las plantas y animales terrestres que habitan Canarias son endémicos [3].

Las singulares características de Canarias han permitido el desarrollo de una riqueza ecosistémica y biológica excepcional. Junto con las amenazas derivadas de la presión demográfica y de la competencia por los usos del suelo, se ha desarrollado una normativa específica de protección del territorio, los hábitats y las especies. Aproximadamente, el 42 % del territorio insular se encuentra adscrito a la Red Canaria de Espacios Naturales Protegidos, y a su vez, a la red europea Natura 2000 [5]. Además, el Catálogo Canario de Especies Protegidas recoge un total de 556 especies a proteger, de las cuales 64 están clasificadas como plantas y hongos invasores en la isla de Gran Canaria. Según se tiene catalogado por la plataforma *GesPlan*, en la isla de Gran Canaria existen diversas plantas invasoras las cuales hay que tener controladas y localizadas [6].

1.3 MARCO TECNOLÓGICO, SOCIAL Y ECONÓMICO

Sobre la pérdida de biodiversidad, actúan además factores globales, como son las costumbres de la **sociedad**, la situación **económica** o los mismos **tiempos**.

La época que nos ha tocado vivir recibe el nombre de Era de la Información debido al alcance que han tenido las tecnologías de la información y la comunicación. **Ordenadores, teléfonos e internet** son productos y servicios que se usan con frecuencia por casi cualquier persona en el mundo. Hay que recalcar que el dispositivo que engloba los conceptos de la **computación, la telefonía y la información** es, por excelencia, el teléfono inteligente o *smartphone*. Es un dispositivo ampliamente distribuido entre la población. Así lo reflejan las

estadísticas de *The International Telecommunication Union (ITU)*, que estima que el **95,5 %** de la población mundial posee un *smartphone* [7].

Actualmente, las Tecnologías de la Información y la Comunicación (**TIC**) se aplican de diferentes maneras para ayudar a conservar la biodiversidad. Creación de base de datos, monitorización de especies y detección de incendios son algunas de ellas [8].

La **protección del medio ambiente** se ha configurado socialmente como un valor. Es algo positivo y deseable. De una forma consistente, los sondeos registran desde hace tiempo que la **gente** se muestra **a favor de la conservación** de la naturaleza. Considera que el deterioro de la misma es un problema grave y piensa que alguien debería hacer algo al respecto con urgencia. Ese alguien es sobre todo quienes saben y pueden, los expertos y los gobiernos. Se tiende a pensar que la capacidad de actuar eficazmente está en manos del **conocimiento** y el **poder**.

En consecuencia, la protección del medio ambiente viene apareciendo como uno de los objetivos que las políticas públicas deben perseguir. No obstante, en la escala de prioridades, la calidad ambiental y la sostenibilidad aparecen subordinadas a otros objetivos que conciernen a aspectos fundamentales de la seguridad, el desarrollo y el equilibrio económico [9].

La conservación del medio ambiente se ha convertido en uno de los factores clave a la hora de mantener la competitividad del **sector turístico**, ya que la participación de este sector en el **PIB** y en la **generación de empleo** es tan **importante** que es necesario asegurar su permanencia y **garantizar** su éxito en el **futuro**. El medio ambiente ha de ser entendido desde un punto de vista amplio, abarcando desde los recursos naturales hasta la calidad ofrecida del servicio y, en tanto en cuanto estos factores se vean afectados por **la actividad turística**, ésta podría poner en **peligro** su propia existencia.

En este sentido, el futuro del sector recae en la práctica de un **turismo sostenible**, es decir, en la adopción de un nuevo modelo de desarrollo turístico que recoja las consideraciones de sostenibilidad que permitan no sólo **garantizar el futuro económico del sector**, sino también conservar y gestionar adecuadamente el entorno en el que se desarrolla. La integración de la variable ambiental no se consigue únicamente con el ejercicio de prácticas medioambientales compatibles con el desarrollo económico, sino también con medidas políticas y **financiación específica para proyectos** relacionados [10].

Entendiendo cuál es el marco en el que el proyecto se mueve y el problema que supone la pérdida de la biodiversidad, en este trabajo **se propone el desarrollo de un sistema de reconocimiento de plantas** para la identificación de las que son **invasoras**.

1.4 ANTECEDENTES

En este apartado se muestran las **diferentes metodologías** utilizadas en el reconocimiento automático de plantas. Además, se exponen algunas **aplicaciones móviles** que se han desarrollado y se desarrollan actualmente para la clasificación de plantas.

1.4.1 Reconocedores automáticos de plantas

Como se verá más adelante, los reconocedores automáticos utilizan una serie de algoritmos para parametrizar las imágenes que forman una base de datos. La información extraída consiste en una serie de **parámetros** que son introducidos en el **clasificador**. Así como existen diferentes algoritmos y sistemas para la

parametrización, también existen diferentes tipos de clasificadores. Definiendo las dos partes, se obtiene un reconocedor automático que puede ser testado, entregando una serie de resultados.

En lo que respecta a la clasificación de plantas a través de imágenes de sus cortezas, se han encontrado ya diseñados varios prototipos. Se exponen a continuación, junto con sus condiciones iniciales y resultados:

- Con una base de datos de 25 muestras por clase, para 8 clases; parametrizando con un banco de filtros *Gabor*; y clasificando con un *Narrowband Signal Model* (NSM), se ha desarrollado un clasificador con una precisión del 51'5 %. Si en vez de ello, se utiliza un *Multiple Narrowband Signal Model* (MNSM), la precisión aumenta hasta el 96 % [11].

- Para una base de datos un poco más amplia, que consiste en 300 imágenes de 9 clases diferentes; si se clasifica con una *Support Vector Machine* (SVM); y aplicando los algoritmos de *Auto-correlation method* (ACM), *Co-occurrence matrix* (COMM), *histrogram method* (HM) y *discrete wavelet transform* (DWT); se obtienen unas precisiones del 65 %, 75 %, 62 % y 82'26 %, respectivamente. Los resultados mejoran si el clasificador en vez de ser SVM es un *Radial Basis Probabilistic Neural Network* (RBPNN): 72 %, 77 %, 65 % and 84'68 % [12].

- Con un análisis de las **características fractales** de la imagen, junto con el algoritmo COMM y un clasificador formado por una red neuronal (NN), se obtiene un reconocedor con una alta precisión: **91'7 %**. Además, el resultado supera las expectativas si se tiene en cuenta que la base de datos contiene **24 clases**, con al menos 16 imágenes por clase. No obstante, la tasa de entrenamiento supera el 93 % [13].

- Para una base de datos de 90 imágenes recortadas que se corresponde con 18 clases se aplican los algoritmos *Long Connection Length Emphasis* (LCLE) y

COMM. Los parámetros resultantes se introducen sobre diferentes k-Redes Neuronales (kNN). La precisión del Sistema para k=1 es 87'8 %, para k=5 es 84'4 % y para k=8, 21'1 % [14].

- *Run Length Method* (RLM), COMM y HM son los algoritmos para parametrizar un reconocedor sobre el que se prueban 3 clasificadores: 1-NN, 4-NN y el *Moving Median Centres* (MMC). El mejor resultado obtenido es para COMM sobre 1-NN, con un acierto del 89 %. La base de datos consta de 160 muestras que pertenecen a 9 especies diferentes [15].

- El último reconocedor que se expone en este apartado utiliza también COMM y DWT sobre un clasificador SVM. El éxito es de un 69'7 % para 1183 fotos de troncos de 11 especies diferentes [16].

Los resultados de todos estos reconocedores se resumen en la siguiente tabla:

Referencia	Algoritmos	Clasificadores	Nº de clases	Tasa de éxito
[11]	Banco de filtros	NSM	8	51,5 %
	<i>Gabor</i>	MNSM		96 %
[12]	ACM	SVM	9	65 %
	COMM			75 %
	HM			62 %
	DWT			82,26 %
	ACM	RBPNN		72 %
	COMM			77 %
	HM			65 %
DWT	84,68 %			
[13]	Análisis fractal+COMM	NN	24	91,7 %
[14]	LCLE+COMM	1-NN	18	87,8 %
		5-NN		84,4 %
		8-NN		21,1 %
[15]	COMM	1-NN	9	89 %
[16]	COMM+DWT	SVM	11	69,7 %

Tabla 1: Estado del arte sobre identificación de cortezas

1.4.2 Desarrollo de Aplicaciones

La Universidad de Columbia, la Universidad de Maryland y la *Smithsonian Institution* están trabajando en un sistema de reconocimiento de imágenes que permite la identificación de especies de plantas a partir de fotografías de sus flores, frutos, semillas, pétalos y corteza. El sistema está implementado sobre una aplicación móvil gratuita, llamada *Leafsnap*. La base de datos está compuesta hasta ahora por más de 300 especies de EEUU y Canadá. El sistema es semi-automático, ya que la clasificación final se la permite hacer al usuario [17].

En lo respecta a Europa, *Inria* ha desarrollado *Pl@ntNet*. Su funcionamiento es similar, por la salvedad de que los usuarios son los responsables de constituir la base de datos. De esta manera, el servicio proporciona la identificación de la especie a la vez que la imagen de muestra sirve para aumentar la precisión del clasificador [18].

Sin ir más lejos, la Universidad de Las Palmas de Gran Canaria (ULPGC), ya tiene experiencia con el reconocimiento automático de plantas. En el pasado propuso un sistema de **reconocimiento automático** de especies de plantas a través de un **escaneo de la hoja** para especies de laurisilva. Alcanzó una tasa de acierto del 88 % [19].

1.5 OBJETIVO DEL PROYECTO

El objetivo principal del proyecto es el **desarrollo e implementación de un reconocedor automático de plantas invasoras**. Mediante una fotografía de la corteza de un espécimen, el sistema debe determinar a qué especie pertenece dicho individuo. De esta forma, el usuario que quiera saber dicha información sólo tendría que capturar una imagen de la corteza. Identificar la especie de esta

manera es **menos invasivo** a que si, por ejemplo, se pretendiera realizar dicha identificación con el escaneo de una hoja. Si la identificación resulta fallida, eso querría decir que la planta en cuestión no se califica como invasora.

Además de la identificación automática de la especie de planta invasora a la que pertenece la fotografía de su corteza, se pretende conseguir:

- Hacer dicha identificación con una **alta precisión**.
- Detectar cuáles son los **algoritmos y sistemas más eficientes** en cuanto a la extracción de parámetros y la clasificación.
- Optimizar los recursos para que la identificación *in situ* tenga una **duración soportable**, con lo que el usuario pueda percibir la información en tiempo real.

Para lograr estos objetivos, se dispone de una base de datos de **23 especies de plantas** catalogadas como invasoras en la isla de Gran Canaria. **De cada especie** se tienen **40 fotografías** de cortezas, en formato *Portable Network Graphics* (PNG). Utilizando un programa orientado al procesamiento digital de la imagen, tal como **MATLAB** [20], se pretende **extraer los parámetros** de estas imágenes, para luego introducirlos en un **clasificador** [21]. Al final, se puede hacer un **análisis** detallado de la funcionalidad del sistema completo.

Teniendo en cuenta que en el PFC con título *Diseño de aplicación móvil para detección de plantas invasoras. Integración de framework IUMA*, **se ha desarrollado una aplicación** que gestiona el tema de las rutas de senderismo a lo largo de la isla, haciendo uso del GPS. Sin embargo, el algoritmo que realiza dicha detección solo se encuadró. Efectivamente, la implementación del reconocedor automático de plantas invasoras forma parte del presente proyecto, pero no su integración [22].

Como ya se ha visto, una de las causas de la pérdida de biodiversidad es la proliferación de especies invasoras. Este proyecto pretende dar solución al problema, tratando de conservar las áreas naturales a través del control de la propagación de las especies invasoras que predominen sobre las autóctonas.

1.6 ESTRUCTURA DE LA MEMORIA

Este documento consta de las siguientes secciones [23]:

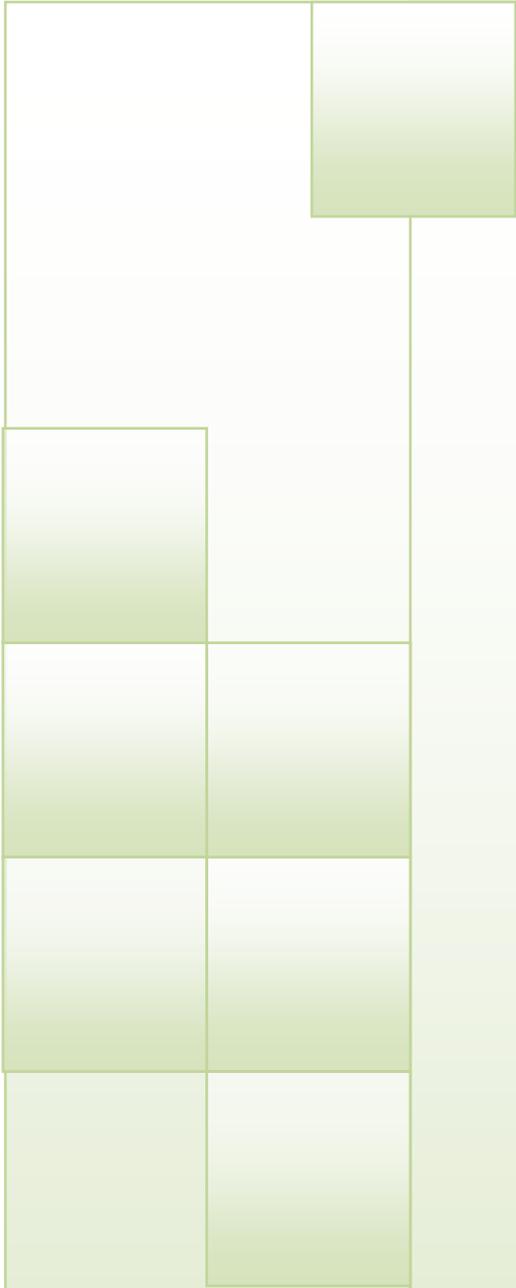
- a) **Portada.** Marca el inicio de este documento, indicando las personas y órganos institucionales que han colaborado en la realización del proyecto.
- b) **Hoja de firmas.** En ellas, los tutores y el propio autor aprueban la presentación de este proyecto. Además se dispone de una sección para que el tribunal lo evalúe.
- c) **Índices.** Es una guía para recorrer todo el documento. Con ella se puede encontrar fácilmente un apartado, ilustración o tabla. Así mismo, se incluye una lista de acrónimos que se repiten a lo largo del documento.
- d) **Memoria.** En ella se encuentra toda la documentación relevante en cuanto al desarrollo e implementación del reconocedor, junto con el impacto que representa. Además, se incluyen al final todas las referencias bibliográficas que correspondan.
- e) **Pliego de condiciones.** En el pliego de condiciones se definen las cláusulas que deben cumplirse entre el propietario del proyecto y su ejecutor.
- f) **Presupuesto.** Se detalla cuál es el coste estimado total de la realización de este proyecto.

Propiamente, la memoria se ha dividido en los siguientes capítulos:

- 1) **Introducción.** En esta primera sección, se trata de orientar al lector sobre los temas que se discutirán más adelante en cada apartado. Además, se define el marco tecnológico y medioambiental, para que luego quede justificado el objetivo del proyecto. Por otro lado, se muestra los sistemas que se han implementado o se están implementando hasta la fecha y que suponen una solución al problema planteado.
- 2) **Base de Datos.** Se describe todo lo referente a la base de datos utilizada para la realización de este proyecto. Está formada, únicamente, por imágenes en alta resolución. Además, se exponen algunos algoritmos y sistemas para realizar un pre-procesado de la imagen.
- 3) **Parametrización.** Como primera fase de la etapa de diseño, se muestran las diferentes técnicas utilizadas para tratar la base de datos con el objetivo de extraer su información más relevante.
- 4) **Clasificación.** Como segunda fase de la etapa de diseño, se describe el funcionamiento del tipo de clasificador utilizado en los procesos de entrenamiento y test. Además, se muestra la forma que van a tener los resultados finales.
- 5) **Experimentos y resultados.** Los diferentes algoritmos y sistemas aplicados en la extracción de parámetros junto con los clasificadores generados en el anterior apartado, proporcionan diferentes resultados. Esto sirve para encontrar el conjunto de algoritmos y sistemas con mayor funcionalidad.
- 6) **Conclusiones y líneas futuras.** Finalmente, se exponen las conclusiones que se extraen de los resultados obtenidos, junto con ideas para mejorar el sistema final. Además, se comenta la innovación que puede suponer este proyecto.

1.7 PETICIONARIO

Actúa como peticionario de este proyecto la Escuela de Ingeniería de Telecomunicación y Electrónica (EITE) de la ULPGC, siendo la realización de este Proyecto de Fin de Carrera (PFC) requisito indispensable para la obtención del título de **Ingeniero de Telecomunicación** [23].



CAPÍTULO 2: LA BASE DE DATOS

*La botánica no es una ciencia, es el arte de desecar plantas e
insultarlas en griego y latín.*

Alphonse Karr



2.1 INTRODUCCIÓN

En este capítulo se presenta la base de datos a la que se va a recurrir, indicando **cómo se ha conseguido**. Además, se hace una **descripción de cada especie** que la constituye. Por otro lado, se detallan algunos **sistemas y algoritmos** implementados para **mejorar las imágenes**, con la intención de facilitar su reconocimiento automático.

La base de datos desempeña dos objetivos en este proyecto. El primer objetivo es el **desarrollo del reconocedor automático** de plantas. A través de la parametrización de las imágenes de la base de datos, se pretende definir el clasificador. Con el primer objetivo cumplido y utilizando las muestras que no se usaron en la primera parte, **se prueba el sistema implementado**. Estas muestras simulan ser las entradas de este sistema, dando a la salida, indicadores de la funcionalidad de dicho sistema. Se explicará más sobre estos temas en capítulos posteriores.

2.2 RECOGIDA DE MUESTRAS

El punto de partida de este proyecto ha sido una base de datos de imágenes de plantas. En éstas aparece sólo una **sección de la corteza**. Hay que tener en cuenta que la base de datos **no está formada únicamente por árboles**, sino también por tuneras y hierbas, entre otras. Por esto, la palabra “tronco” no puede definir completamente las imágenes que se pretenden reconocer.

Aclarado esto, se dispone de una base de datos de 920 imágenes de cortezas de plantas. Éstas están divididas por directorios, donde cada uno de ellos se corresponde con una especie en concreto. Cada especie contiene a su vez 40

imágenes, lo que hace que el número de especies del que se dispone sea 23 (**40 imágenes/especie * 23 especies = 920 imágenes**).

A continuación, se muestra una tabla con el nombre científico, nombre común y una descripción de las características de cada especie.

Nombre científico	Nombre común	Características
<i>Acacia cyclops</i>	Acacia mayorera	Arbusto de la familia de las leguminosas de 3-4m de altura. Su follaje oculta al tallo y casi llega hasta el suelo. Las ramillas son angulosas de color castaño-verdoso, tornándose más redondeadas y oscuras con el tiempo. Presenta filodios erectos, planos, oblongos y estrechos de 4-9cm x 6-12mm, con nervios más o menos paralelos. Flores pentámeras, legumbre oblonga o linear con los márgenes engrosados, semillas elípticas de 5-7mm de largo dispuestas longitudinalmente con funículo grueso, rojo o anaranjado rodeando la semilla.
<i>Acacia cyanophylla/saligna</i>	Mimosa azul	Árbol perennifolio de entre 5 y 6m de altura, copa irregular de 4 a 6m de diámetro, ramas péndulas, hojas simples, alargadas, estrechas, a menudo curvadas, de entre 8 y 25cm de longitud y color verde-azulado; tronco tortuoso de corteza marrón-rojizo y más adelante fisurada de color gris oscuro, flores (marzo-mayo) amarillas o anaranjadas y frutos

		(verano) aplanados marrón-rojizo.
<i>Agave americana</i>	Pitera común, pita, maguey, magüey, pitaco	Planta de aspecto robusto de diámetro y altura similares (2m) formada por grandes rosetas basales de hojas largas, lanceoladas, carnosas, muy gruesas, espinosas en los márgenes y en el ápice y de color gris-azulado. Al llegar a su madurez aparece el tallo floral, que emerge a principios de primavera y florece en verano una única vez en su vida. Este tallo puede medir hasta 10m y las flores son de color amarillo pálido. Sus frutos se encuentran en cápsulas alargadas y las semillas son negras y aplanadas.
<i>Agave azul</i>	Agave tequilana	Planta perenne en forma de roseta de hojas largas, rígidas, puntiagudas, fibrosas, lanceoladas y de color verde-azulado que presentan espinas marginales y apicales. Alcanza una altura de entre 1'20 y 1'80m. Florece sólo una vez, en el extremo de un largo tallo floral (quiote) que crece cuando llega la madurez de la planta.
<i>Araucaria excelsa/ Heterophylla</i>	Pino de Norfolk, pino de pisos	Conífera perennifolia normalmente de entre 20 y 25m de altura, copa cónica de 3 a 8m de diámetro, tronco de corteza rugosa que se exfolia en escamas finas de color gris-amarronado en torno al cual ramas casi horizontales se disponen de forma simétrica formando pisos. Produce hojas de dos tipos en ramas fructíferas que llegan a ser punzantes. Sus hojas

		adultas son escamosas de color verde oscuro brillante de 4 a 5mm y sus flores (verano) marrón-amarillento o verdes (éstas se convierten en piñas marrones en otoño).
<i>Cupressus macrocarpa</i>	Ciprés de monterrey	Conífera de 10 a 25m de altura, copa cónica de entre 6 y 12m de diámetro, hojas aromáticas, escamosas y persistentes de 1'5 a 2mm color verde oscuro. Su corteza es fisurada gris-rojiza, sus flores (invierno) amarillas o verdes y su fruto, marrón-grisáceo, cuya maduración se produce en otoño.
<i>Eriobotrya japonica</i>	Níspero del Japón	Arbolillo perennifolio de entre 5 y 10m de altura, copa redondeada de 4 a 6m de diámetro, tronco de corteza lisa gris-amarronado, hojas simples, lanceoladas y gruesas de 10 a 30cm verde oscuro brillante por el anverso y verde-blanquecino por el reverso. Florece en otoño con flores de color blanco-amarillento y sus frutos (que maduran en primavera) son amarillo-anaranjados.
<i>Eucalyptus camaldulensis</i>	Eucalipto fluvial rojo, gomero rojo	Árbol perennifolio de 30 a 45m de altura, copa irregular de entre 10 y 20m de diámetro, tronco de corteza laminar que se desprende en placas o escamas grisáceas, blanquecinas o marrón-rojizo; hojas simples, lanceoladas de entre 8 y 30cm de color grisáceo, verde-azulado o verde pálido mate. Sus flores (primavera-verano) son blancas y sus frutos

		(otoño) marrones.
<i>Ficus carica</i>	Higuera	Árbol caducifolio de copa extendida e irregular de entre 6 y 10m de diámetro y altura de 5 a 9m. Sus hojas son simples, palmeadas, con lóbulos redondeados y olorosos, de color verde oscuro por el anverso y verde blanquecino el reverso, y de una longitud que va desde 12cm hasta los 25cm. Su tronco es de corteza lisa gris, sus flores (primavera) son diminutas y verdosas y sus frutos son de color verde o violeta oscuro y maduran desde el verano hasta principios de otoño.
<i>Leucaena leucocephala</i>	Aromo blanco	Arbusto o árbol pequeño de 5-8m de altura, de copa algo desgarbada y tronco delgado de color marrón-blanquecino. Sus hojas son bipinnadas, con entre 3 y 10 pares de pinnas de 5-20 pares de foliolos verde glauco lineares y oblongos cada una. Sus flores están dispuestas en inflorescencias axilares o terminales. Capítulos globosos pedunculados y flores (mayo-enero) con 10 estambres muy cortos color crema o blanco verdoso. Fruto tipo legumbre de color marrón.
<i>Nicotiana glauca</i>	Tabaco moruno, bobo, gandul	Arbusto o arbolillo perennifolio de hasta 7m de altura. La corteza de su tronco es de color pardo-grisácea y sus ramas son verdes. Es de hojas ovaladas a lanceoladas de entre 5 y 25cm de longitud, cubiertas de una capa de pruina de color blanco-azulado. Sus

		flores (de abril a octubre) son amarillas de cáliz tubular y corola en tubo estrecho y largo y sus semillas son diminutas de color negro.
<i>Opuntia azurea</i>	Coyotillo	Planta arbustiva compacta de la familia de las cactáceas cuyo desarrollo puede darse en horizontal o en vertical y su altura suele estar en torno al metro. Es de los pocos cactus que presenta un color púrpura en las areolas (alrededor de las espinas) y en el borde de los segmentos (que tienen apariencia de hoja carnosa, plana y de forma obovada). Los segmentos de esta especie son de color gris-azulado, azul-verdoso o violáceo. A veces tiene un pequeño tronco. Es de púas largas concentradas en la mitad superior del cladodio o sólo sobre el borde superior. Florece de marzo a mayo con flores de color amarillo brillante y centro rojo. Sus frutos son rojos o púrpura.
<i>Opuntia dillenii</i>	Tunera india	Arbusto cactáceo de tallo suculento, muy ramificado, que puede alcanzar los 3m de altura. Sus cladodios, de color azul-verdoso o gris-verdoso, son obovado-oblongos, menos carnosos que los de otras especies, aplanados hacia el interior y unidos sucesivamente. Es de púas largas amarillas y rígidas; flores amarillas o anaranjadas y fruto subgloboso morado sin espinas.
<i>Opuntia durangensis</i>		Especie de cactus en forma de arbusto cuyas secciones son ovoides y de color verde claro, en las

<i>is</i>		que se encuentran grupos de, generalmente, 3 púas cortas de color amarillo (oscurecen cuando envejecen) muy separados entre sí. Sus frutos son rojizos.
<i>Opuntia maxima</i>	Chumbera, tuna, nopal	Arbusto espinoso, a veces arborescente, de entre 1 y 4m de altura, con tallos transformados en cladodios (conocidos vulgarmente como “palas”) carnosos, suculentos, obovados, aplanados, verdes, de 20-60cm x 10-25cm. Presenta un tronco de hasta 35cm de diámetro, flores (mayo-junio) amarillas o rojizas y frutos ovoides verdes, naranjas o rojos. Normalmente tienen espinas muy variables en densidad (3-6) y tamaño. Son divergentes y blancas.
<i>Opuntia pycnantha</i>		Arbusto de la familia de las cactáceas que suele extenderse horizontalmente. Sus cladodios, de 10-18cm x 8-13cm, están densamente poblados de grupos de finas espinas cortas cuyas bases se encuentran muy próximas entre sí.
<i>Opuntia tomentosa</i>	Tunera de terciopelo	Tunera arboriforme de desarrollo vertical de 2 a 6m de alto. Su tronco puede llegar a los 40cm de diámetro en su base. Sus segmentos miden 15-30cm x 6-12cm y son gruesos, ovalados y de color verde oscuro. Esta especie puede carecer de espinas o tenerlas finas y de escaso tamaño. Sus flores surgen en las épocas más cálidas y son amarillas, anaranjadas o rojizas. Los frutos son rojos cuando maduran.

<p><i>Phoenix dactylifera</i></p>	<p>Palma, palmera datilera</p>	<p>Palmera de hasta 20m de altura, de un solo estípote bastante delgado (40-50cm de diámetro) que con frecuencia se curva. La copa no es demasiado frondosa y está formada por palmas pinnadas de color verde pálido grisáceo de 6 a 7m de longitud con espinas duras y largas en la zona inferior del pecíolo. Florece entre abril y junio con flores de color crema o amarillo y sus frutos son bayas alargadas rojizo-anaranjadas al principio y luego, cuando maduran, castaño encarnado.</p>
<p><i>Ravenala madagascariensis</i></p>	<p>Árbol del viajero, palma del viajero</p>	<p>Planta herbácea que supera los 10m de altura. Desarrolla un pseudotallo debido a las vainas foliares endurecidas. Sus hojas presentan largos peciolos de un verde intenso que recuerdan a las hojas de los bananos, distribuidas en forma de abanico sobre un solo plano. Sus flores son de color blanco-crema, el fruto es marrón y las semillas azules.</p>
<p><i>Ricinus communis</i></p>	<p>Tartaguera</p>	<p>Planta herbácea alta de hasta 3-6m, de color verde claro a azul-grisáceo, en ocasiones rojiza. De tallo grueso y leñoso y hojas profundamente palmatilobadas de 10-60cm de diámetro y borde irregularmente dentado-glanduloso. Flores agrupadas en inflorescencias terminales y frutos en cápsula globosa con 3 lóculos, cubierta de púas blandas que se hacen más rígidas hacia la madurez.</p>

<i>Rumex lunaria</i>	Vinagrera	Planta perenne de porte arbustivo de entre 1 y 3m. Sus hojas son carnosas de color verde profundo, de forma ovalada truncada en la base y a menudo más ancha que larga. Su fruto es redondeado y marrón-rojizo. Presenta inflorescencias ramificadas de diciembre a mayo.
<i>Schinus molle</i>	Falso pimentero común, aguaribay	Árbol perennifolio de 4 a 15m de altura, copa redondeada o extendida, de un diámetro de entre 5 y 10m, ramas péndulas de hojas compuestas pinnadas de entre 15 y 30cm de largo de color verde brillante y tronco tortuoso marrón oscuro de corteza escamosa y agrietada. Su floración tiene lugar en primavera y en verano con flores amarillentas o de color blanco-crema y sus frutos son rojizos o rosados de maduración estival y otoñal.

Tabla 2: Características de las especies.

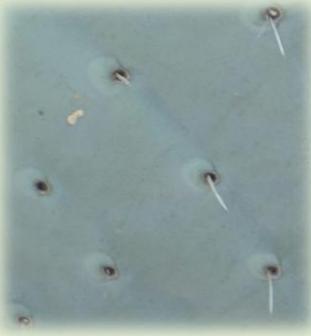
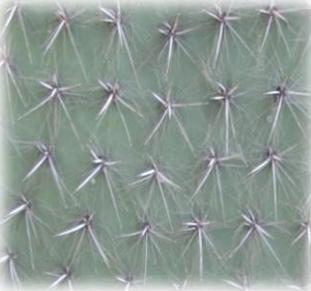
Acompañando a esta tabla, se muestra otra con el origen y una imagen general de cada especie. En la última columna, se puede observar una muestra extraída de la base de datos, que se corresponde con la especie en cuestión.

Nombre científico	Origen	Imagen general	Imagen de la corteza
<i>Acacia cyclops</i>	Oeste y sur de Australia		
<i>Acacia cyanophylla/saligna</i>	Suroeste de Australia		
<i>Agave americana</i>	México		

<p><i>Agave azul</i></p>	<p>México</p>		
<p><i>Araucaria excelsa/ Heterophylla</i></p>	<p>Isla de Norfolk, Australia</p>		
<p><i>Cupressus macrocarpa</i></p>	<p>California, EEUU</p>		

<i>Eriobotrya japonica</i>	China y Japón		
<i>Eucalyptus camaldulensis</i>	Australia		
<i>Ficus carica</i>	Región mediterránea y oeste de Asia		

<p><i>Leucaena leucocephala</i></p>	<p>México</p>		
<p><i>Nicotiana glauca</i></p>	<p>Argentina, Paraguay y Bolivia</p>		
<p><i>Opuntia azurea</i></p>	<p>México; y Texas, EEUU.</p>		

<p><i>Opuntia dillenii</i></p>	<p>Centroamérica y Caribe</p>		
<p><i>Opuntia durangensis</i></p>	<p>México</p>		
<p><i>Opuntia maxima</i></p>	<p>México</p>		
<p><i>Opuntia pycnantha</i></p>	<p>México; y Carolina del Sur, EEUU.</p>		

<p><i>Opuntia tomentosa</i></p>	<p>México y Nicaragua</p>		
<p><i>Phoenix dactylifera</i></p>	<p>Norte de África y oeste de Asia</p>		
<p><i>Ravenala madagascariensis</i></p>	<p>Madagascar</p>		

<p><i>Ricinus communis</i></p>	<p>África tropical</p>		
<p><i>Rumex lunaria</i></p>	<p>Italia</p>		
<p><i>Schinus molle</i></p>	<p>Sur y oeste de Sudamérica</p>		

Tabla 3: Origen, imagen general e imagen de muestra.

Toda esta información de partida ha sido recopilada por el Departamento de Señales y Comunicaciones de la EITE de la ULPGC. Como inciso, sólo queda

decir que es la primera vez que se utiliza esta base de datos en un trabajo. Esto recalca la innovación que supone este proyecto.

2.3 CARACTERÍSTICAS DE LAS IMÁGENES

El departamento se ha ocupado de la captura de las fotografías, utilizando para ello una cámara digital. Las imágenes han sido tomadas en el **campus universitario de Tafira** y en el **jardín botánico Viera y Clavijo** (Las Palmas de Gran Canaria), durante los meses de mayo y junio del año 2015. Las imágenes muestran pequeñas diferencias de calidez debido a las **variaciones de las condiciones climáticas**, que oscilaban entre soleado y lluvioso. Se ha tenido especial cuidado en que las fotografías se captasen de la forma más directa posible, y sin daños, quemaduras o calvas.

La resolución varía mucho para cada imagen. Esto se debe a que, además, se recortaron las imágenes para que cada fotografía muestre, únicamente, la corteza de la planta. No obstante, debido a que algunos marcos de las fotos no se recortan sobre una de las dos dimensiones, se deduce que esa dimensión en concreto tiene la longitud máxima: **4608 píxeles**.

El formato de las imágenes es *png*, con una **profundidad de color de 24 bits**. Se utiliza este formato para garantizar una excelente calidad y no excederse en el espacio en disco que ocupan dichas imágenes, ya que PNG realiza una compresión sin pérdidas. Este sistema es adecuado para pocas variaciones de color, lo que lo hace ideal para esta base de datos [24].

Como se ha visto en el apartado anterior, las imágenes o muestras están **organizadas en carpetas** con el nombre de la especie. Dentro de cada una de ellas, se encuentran 40 imágenes, cuyo nombre va desde **1.png** hasta **40.png**. Con esta nomenclatura se facilita la ejecución repetitiva de un sistema o algoritmo sobre cada imagen. En total, la base de datos ocupa 2,44 GB (**2.623.738.568 bytes**).

La naturaleza de las imágenes puede ser interpretada como **texturas**. Esto es una característica a tener en cuenta en el capítulo siguiente, debido a que la elección de los algoritmos y sistemas a implementar se ve condicionada por dicha naturaleza.

2.4 SISTEMAS Y ALGORITMOS DE PREPROCESADO DE LA IMAGEN

El pre-procesado de la imagen es la aplicación de programas dedicados a **mejorar la presentación** de dicha imagen sin tener en cuenta su naturaleza. En contraposición, los sistemas y algoritmos que sí tienen en cuenta que las imágenes son texturas son los descritos en el próximo capítulo.

Tanto para este apartado como para el próximo capítulo, es necesario discernir entre sistema y algoritmo. Tal y como se ve en este proyecto, un **sistema** es una composición y estructura **ya definidos** sobre el entorno de programación utilizado. Cumplen con unos conceptos teóricos computacionales y matemáticos. En todos los casos, los sistemas **forman parte de un *toolbox*** del entorno utilizado: MATLAB.

Un **algoritmo** también parte de unos conceptos teóricos. Sin embargo, **no se dispone de la definición** de dichos conceptos. La tarea de definir los algoritmos recae en este proyecto. En cuanto al entorno, es idéntico.

Es importante tener en cuenta que, en todos los casos, **las imágenes son** tratadas como **matrices**, donde cada elemento se corresponde con un píxel de la imagen. Así, se pueden realizar funciones computacionales y matemáticas sobre las mismas.

A continuación, se muestran **dos sistemas y un algoritmo** utilizados en el pre-procesado de cada una de las imágenes de la base de datos. Al hacerlo, el entorno **genera un directorio nuevo**, similar a la base de datos, donde se guardan las imágenes resultantes de cada sistema/algoritmo. El nombre del directorio es asignado en función del sistema/algoritmo y de todos los demás por los que hayan pasado previamente las imágenes.

2.4.1 Sistema Escala de grises (GRAY)

Teniendo en cuenta que se pretende interpretar la **textura** de las cortezas de las plantas, la información que se puede extraer del **color de la imagen es irrelevante**. De hecho, en una misma especie puede haber diferencias significativas de color entre dos muestras. Por esta razón, se pasan las muestras a **escala de grises**, dando como resultado imágenes en blanco y negro. En concreto, son 920 imágenes en blanco y negro, una por cada muestra en la base de datos.

Al eliminar el color, es decir, 2 de los 3 campos que definen una imagen, la **profundidad del color pasa de 24 a 8 bits**. Esto se corresponde con los **256 colores grises** que la imagen puede tomar.

Las imágenes en escala de grises son utilizadas en todo el proyecto, ya que descartan el color. Así, **deja de ser necesario el acceso a la base de datos original**. En el siguiente ejemplo, se muestra la imagen antes (izquierda) y después (derecha) de pasar por el sistema.



Ilustración 2: Imagen en color original



Ilustración 3: Imagen en escala de grises

2.4.2 Sistema de Ecuación del histograma (HistEq)

La ecualización del histograma es una transformación de los valores o colores más frecuentes a otros próximos, pero que son menos frecuentes. Así, la corteza queda mejor definida porque **el contraste se ve aumentado**.

Se denomina así porque, con esta transformación, el histograma se vuelve casi-plano, donde los **colores** tienen, aproximadamente, la **misma frecuencia de aparición** por píxel. Si se representara la imagen en una función de distribución, el resultado sería una línea casi-recta que va desde el punto $[0,0]$ hasta el punto $[255,1]$.

A continuación se puede observar la imagen en escala de grises antes (izquierda) y después (derecha) de ser ecualizada. Debajo de las imágenes se muestran sus histogramas correspondientes.



Ilustración 4: Imagen original en escala de grises



Ilustración 5: Imagen ecualizada

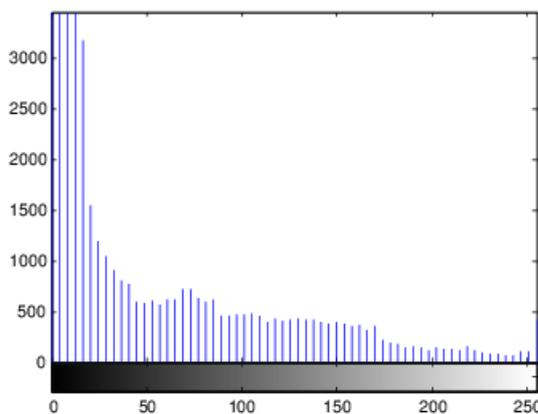


Ilustración 6: Histograma de la imagen original

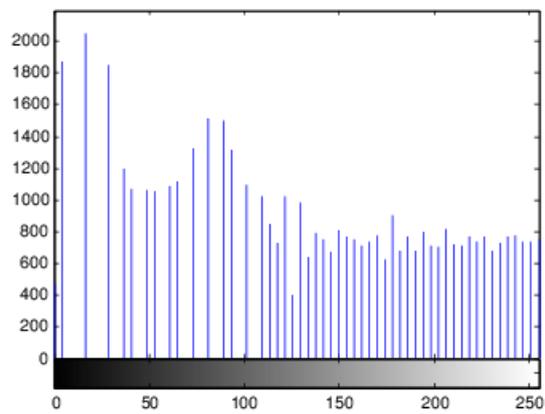


Ilustración 7: Histograma ecualizado

2.4.3 Algoritmo NoBackground (NB)

NoBackground ha sido un algoritmo diseñado e implementado para solucionar un **defecto** que aparece en **casi todas las imágenes**. Se trata de la **reflexión** que hace la **luz solar** sobre la superficie de la planta y que la cámara capta de manera involuntaria. Esto se debe a que dicha superficie, rara vez es plana, lo que hace que haya regiones de la imagen que son más luminosas que

otras de la misma imagen. En vista a que esto pueda afectar a la aplicación de otros algoritmos y sistemas posteriores (en concreto, al *Local Binary Pattern* (LBP) y al COMM), el algoritmo se aplica **para paliar el efecto del Sol**.

Si se tiene en cuenta que se trata de una **propagación de baja frecuencia sobre una región** de la superficie, el defecto se puede separar de lo que es la corteza. Si el **fondo se extrae**, entonces la imagen tendrá un brillo **general uniforme**. El algoritmo se puede dividir en 3 pasos:

1. **Obtener el fondo de la imagen.** La imagen se divide en bloques de píxeles. A cada bloque se le asigna el valor correspondiente al valor medio del grupo de píxeles que encierra ese bloque. La forma de cada bloque es la misma: un rectángulo con una relación idéntica a la de la imagen, pero con las dimensiones reducidas por un factor de escala. El ejemplo que se muestra a continuación, funciona igual, a excepción de que el patrón no es rectangular, sino circular. En él, se puede observar como la imagen resultante queda pixelada.

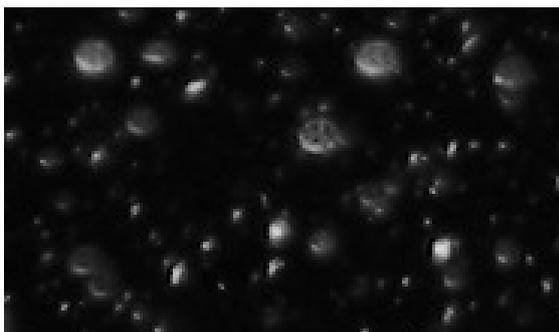


Ilustración 8: Imagen original



Ilustración 9: Imagen pixelada

2. **Calcular el brillo medio general de la imagen.** Se calcula un valor base de brillo para asignárselo a la imagen resultante después de que se resta el fondo de la imagen original. Aquél será el nuevo valor

medio de brillo. La siguiente ecuación muestra cómo se calcula este valor:

$$\mu = \sum_x^{\langle M \rangle} \sum_y^{\langle N \rangle} \frac{img[x, y]}{MN} \quad \text{Eq 1}$$

donde M y N son las dimensiones de la imagen original

3. **Substracción del fondo.** Como la imagen original y la resultante del paso 1 tienen la misma resolución, se pueden restar. Esto significa que el fondo se elimina de la imagen. Además, se establece el brillo general de la imagen calculado en el paso 2. Todo esto queda descrito mediante la siguiente fórmula:

$$RESULT\ IMG = ORIGINAL\ IMG - BACKGROUND + \mu \quad \text{Eq 2}$$

Para finalizar, se expone el código descrito para este algoritmo:

```
function subs=subBackground(img,varargin)
if nargin>1
    scale=varargin{1};
else
    scale=30;
end
XY=size(img);
XY=XY./scale;
XY=round(XY);
background=imopen(img,strel('rectangle',XY));
u=mean(mean(img));
subs=img-background+u;
end
```

Tabla 4: Código de *NoBackground*



CAPÍTULO 3: EXTRACCIÓN DE PARÁMETROS

Mide lo que sea mensurable y haz mensurable lo que no lo sea.

Galileo Galilei



3.1 INTRODUCCIÓN

En este capítulo se presentan los sistemas y algoritmos dedicados a la extracción de parámetros de las imágenes, también denominada **parametrización**. Estos son el **LBP**, el **COMM** o **GLCM** y el **DWT**. Los tres son descritos en función de su campo de aplicación y características. Además, se presenta un sistema que modifica el tamaño de las imágenes y un algoritmo que **convierte las matrices en vectores**. Todo esto se hace para que los datos cumplan con la estructura que necesita el clasificador.

3.2 LOCAL BINARY PATTERN (LBP)

LBP es un operador de textura muy eficiente y de gran simplicidad, que etiqueta los píxeles de una imagen en referencia a uno. Debido a su simplicidad computacional, el operador LBP es un método popular en el procesamiento digital de la imagen. La ULPGC abala su aplicación con exitosos proyectos de reconocimiento automático de imágenes [25], [26], [27].

3.2.1 Metodología

LBP proporciona una matriz, donde cada elemento indica el gradiente de la imagen original. La posición de dicho elemento coincide con la posición de los píxeles de la imagen original. Para conseguirla hay que realizar una serie de operaciones computacionales:

1. Para empezar, se toma un **bloque de 3x3** píxeles de la imagen original. Para este caso, sus valores serán números enteros entre 0 y 255.
2. De ese bloque, se toma el valor del **píxel central** como umbral. Este es **comparado** con cada uno de los **píxeles restantes**. Si el valor del píxel es menor que el umbral, el resultado será un 0; sino, 1.

- Como la operación se hace en conjunto, el resultado es **un nuevo bloque** de 3x3 con valores binarios, es decir, ó 0 ó 1. Este nuevo bloque no tiene centro.
- Si se quita el centro, en total hay **8 elementos**. Tratando de estirar la matriz en un vector, se elige un punto de partida y una dirección arbitrarios. Entonces, se obtiene un número binario de 8 bits. La ilustración 10 muestra las 4 operaciones aplicadas.

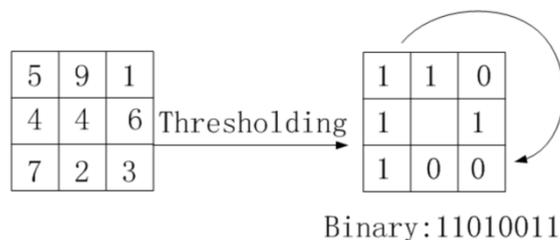


Ilustración 10: Una iteración de LBP

- Si se transforma este número binario de 8 bits a un **número entero** sin signo, se obtiene, nuevamente, un número entero comprendido **entre el 0 y el 255**. A modo de ejemplo, se muestra la transformación del caso anterior.

$$11010011b=211d$$

- Todas estas operaciones hay que repetir las para todos los bloques de 3x3 que se puedan tomar, tal y como se hizo en el paso 1. Los píxeles que están en los bordes no serán nunca píxeles centrales en un bloque. Por lo tanto, el número de bloques 3x3 que se puede obtener es de **(M-2)x(N-2) píxeles**, donde M y N es la resolución de la imagen original. Obviamente, la dirección en la que se recorre el bloque, en el paso 4, no puede cambiar.

Estas operaciones sigue la siguiente descripción matemática:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad \text{Eq 3}$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

- Siendo LBP el bloque de 3x3 que se pretende generar y **P**, la cantidad de píxeles sin contar el central, es decir, **8**. En cuanto a **R**, es la distancia de los píxeles con respecto al central, que para este caso, se escoge el más básico: **1**. Esto se debe a que la comparación es con los píxeles adyacentes.
- La comparación de uno de los P píxeles (g_p) con el central (g_c) viene indicada por la función $s(x)$. Si el valor de la resta es negativo, s será 0. En cualquier otro caso, 1.
- La multiplicación en base 2 y potencia p da lugar a una separación de los píxeles antes de su integración con la sumatoria. El resultado es un número comprendido entre el 0 y 2^P-1 .

Llegados a este punto, existen **dos variaciones** del sistema. Se pueden colocar los resultados a modo de **histograma** o en una **matriz**.

3.2.2 Histograma (hLBP)

Esta variación hace al sistema más ágil. No se necesita construir la matriz o imagen para hallar su histograma.

7. Para hacerlo, se genera un vector vacío de **256 elementos**, uno por cada posible valor que puede obtenerse del paso 5.

8. Por cada valor que se obtenga, se incrementa en 1 el elemento de esa posición. De esta forma, se está contando la frecuencia de aparición de cada número. En la gráfica, se puede observar un ejemplo de histograma de 256 elementos.

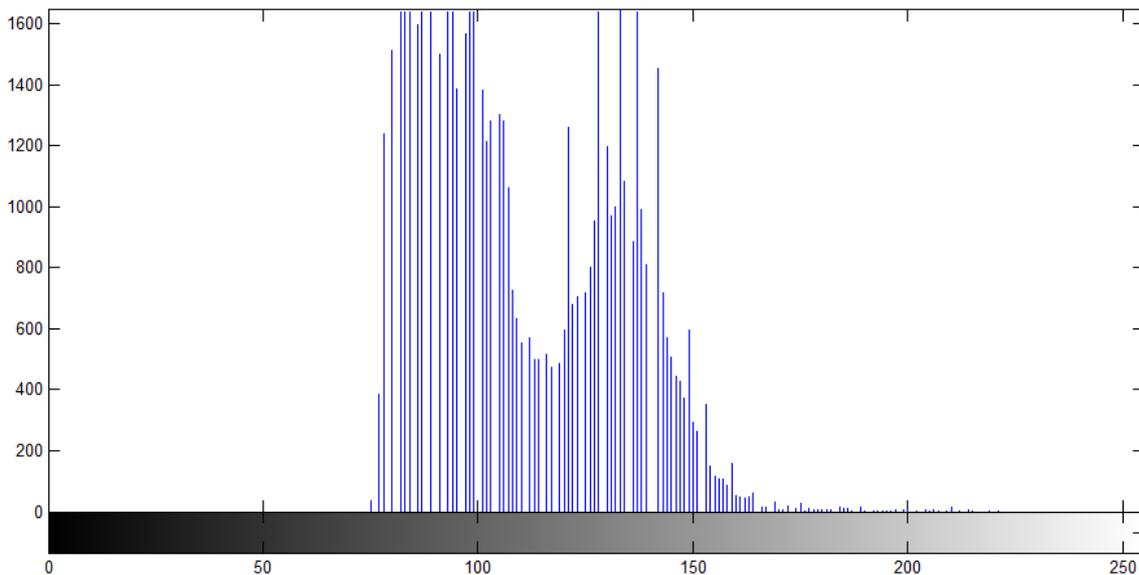


Ilustración 11: Ejemplo de un histograma de 256 elementos

9. Teniendo en cuenta el comportamiento del clasificador en el siguiente capítulo, el histograma es normalizado referido al elemento más frecuente. Para hacerlo, se toma el valor máximo del histograma y divide cada elemento por ese. El resultado será un vector de 256 elementos con números reales entre el 0 y el 1.

3.2.3 Matriz (mLBP)

A diferencia del histograma, esta variación del sistema es más completa, ya que indica la posición de cada elemento. Además, puede ser representada como una imagen y no como una simple gráfica. Es más, de la propia imagen se puede extraer el histograma, pero no al contrario. Sin embargo, toda esta operación es computacionalmente más aparatosa.

7. Si en el histograma se generaba un vector vacío de 256, aquí se crea una **matriz** vacía cuyo dimensionado es **(M-2)x(N-2)**.
8. Cada valor que sale del paso 5 es colocado en esta matriz. Si es representada como imagen, es posible que conserve la forma de la imagen original. Sin embargo, hay que tener en cuenta que **los píxeles no representan** valores de luminancia, sino un **gradiente** de la vecindad.

3.2.4 Algoritmos

Aunque se dispone del sistema LBP, se ha desarrollado e implementado este algoritmo en MATLAB. La principal diferencia con respecto a los otros sistemas es que la duración de estos es menor. A continuación, se muestra el código:

```
function imgLBP=myLBP(img)
tic;
[X,Y]=size(img);
imgLBP=zeros(X-2,Y-2,'uint8');
for r=2:X-1
    for c=2:Y-1
        Binary=zeros(1,8,'uint8');
        Binary(1)=img(r,c+1)>img(r,c);
        Binary(2)=img(r-1,c+1)>img(r,c);
        Binary(3)=img(r-1,c)>img(r,c);
        Binary(4)=img(r-1,c-1)>img(r,c);
        Binary(5)=img(r,c-1)>img(r,c);
        Binary(6)=img(r+1,c-1)>img(r,c);
        Binary(7)=img(r+1,c)>img(r,c);
        Binary(8)=img(r+1,c+1)>img(r,c);
        n=bin2dec(int2str(Binary));
        imgLBP(r-1,c-1)=uint8(n);
    end
end
'LBP finalizado'
toc;
```

Tabla 5: Código de LBP en su versión matriz

3.3 GRAY LEVEL CO-OCCURRENCE MATRIX (GLCM)

Otro de los sistemas que se utiliza en la parametrización de texturas es el COMM, o particularmente llamado **GLCM**, ya que trabaja con imágenes en escala de grises. Su principio es muy parecido al LBP, ya que GLCM trata de obtener el gradiente de los píxeles de la imagen [25]. Las operaciones a seguir son:

1. Se toma un píxel y se compara con su adyacente a la derecha. Solo se tiene en cuenta los 3 bits más significativos del valor de cada píxel. Esto es equivalente a utilizar una imagen con una profundidad de color de 3 píxeles, que es igual a 8 colores. En la ilustración se puede interpretar cómo los píxeles toman valores entre el 1 y el 8 en función de la escala de grises.

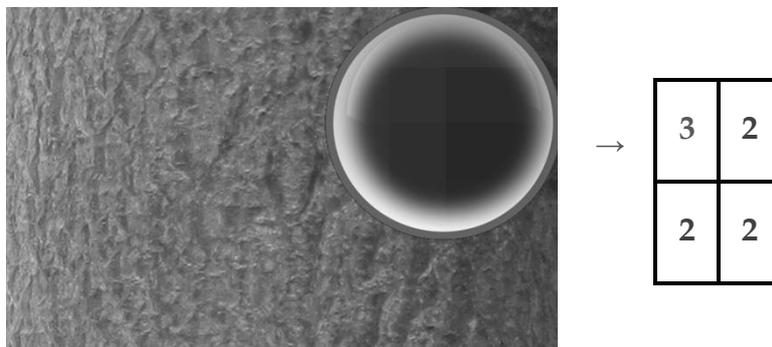


Ilustración 12: Interpretación de GLCM para 8 colores

2. Se crea una matriz vacía de **8x8**, este número coincide con la profundidad de color.
3. Se incrementa el elemento de la fila que indica el primer píxel y el de la columna que indica el segundo píxel.
4. Se repiten los pasos 1 y 3 para cada pareja de píxeles que puedan tomarse. El resultado será una matriz como la que se ve a continuación, cuyos valores más altos indican una mayor frecuencia de aparición de determinados patrones.

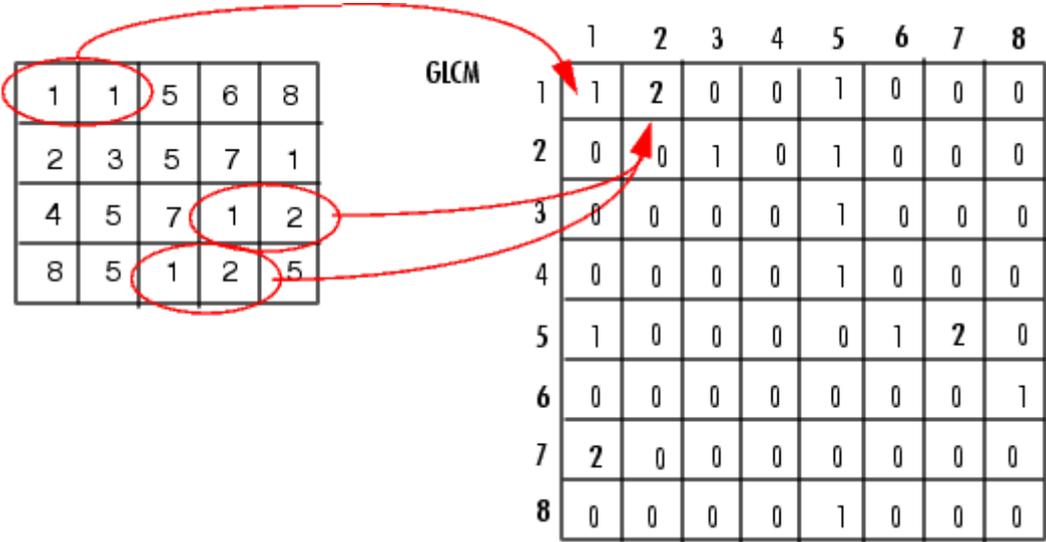


Ilustración 13: Construcción de la GLCM

Al igual que para LBP, existen variaciones del sistema para otras direcciones. Si en vez de tomar el píxel de la derecha, se toma el superior, hay una desviación de 90° en el sistema. Si se toma el de la derecha o el de la izquierda adyacente a este último, el desvío es de 45° y 135°, respectivamente, referido al sistema original. Los ángulos 180°, 225°, 270° y 315° no se utilizan. Esto se debe a que la GLCM resultante aportaría la misma información que sus suplementarios. Comparar un píxel A con otro B, es equivalente a comparar B con A. Simplemente, la GLCM se transpondría.

Si $Y=GLCM(X,alpha)$

Y además, $Z=GLCM(X,alpha+180°)$ **Eq 4**

Entonces $Y=Z'$

Si en vez de tomar el píxel adyacente, se coge el siguiente más próximo, la distancia habrá aumentado a 2. Esta variación, en cuanto a la **distancia**, **no se aplica en este proyecto**, simplemente se contempla.

El siguiente ejemplo muestra gráficamente el patrón de selección para los dos tipos de variación, donde D indica la distancia, y entre corchetes se indica las coordenadas de un píxel referido al otro:

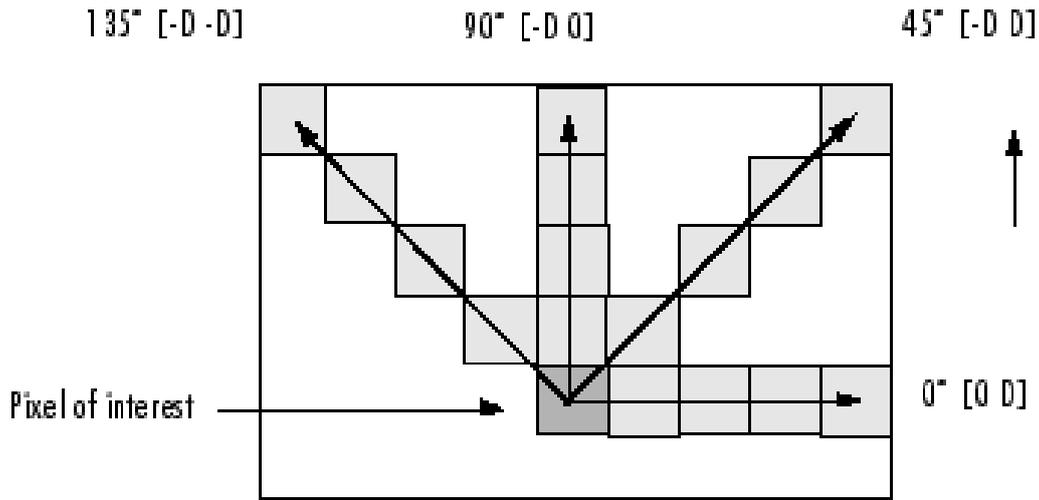


Ilustración 14: Variaciones de GLCM

La función que describe este sistema de forma matemática se muestra a continuación:

$$C_{\Delta x, \Delta y}(i, j) = \sum_{p=1}^n \sum_{q=1}^m \begin{cases} 1, & \text{if } I(p, q) = i \text{ and } I(p + \Delta x, q + \Delta y) = j \\ 0, & \text{otherwise} \end{cases} \quad \text{Eq 5}$$

Simbología:

- Δx y Δy es la posición del segundo píxel a comparar con respecto al primero. Por ejemplo, para $D=1$ a 0° , $\Delta x=1$ y $\Delta y=0$.
- I es la imagen original y C es la matriz resultante.
- Los índices de la imagen original son p y q , con un tamaño de n y m . Esto es su resolución.
- Los índices de la matriz de concurrencia son i y j , que en el caso por defecto van de 1 a 8. Para la matriz, esto hace un total de **8x8=64 coeficientes**.

Cuando el valor de un pixel coincide con el primer índice de la matriz y además, el valor del segundo pixel coincide con el segundo índice, se incrementa el valor coeficiente.

3.4 DISCRETE WAVELET TRANSFORM (DWT)

Si bien los anteriores algoritmos y sistemas estaban orientados a actuar sobre las dimensiones espaciales de la imagen, **DWT** actúa sobre su **espectro**. Así, se pueden detectar pequeñas características que diferencien una especie de otra. DWT procede con el eje horizontal y vertical de la imagen de manera simultánea. De esta manera, es fácil detectar patrones con orientaciones muy diferentes. El sistema sigue ciertos pasos:

1. La imagen se introduce en **dos filtros** complementarios. **Uno es paso bajo y el otro es paso alto**, cuya frecuencia de corte está en el mismo punto: $\pi/2$. Este filtrado se hace **sobre la primera dimensión** de la imagen. El resultado es dos imágenes, una con la parte en baja frecuencia de la imagen y la otra, con la parte alta. En lo que respecta a los espectros, ambos tienen la mitad de su eje anulado.
2. A continuación, se **diezma** la imagen en un factor de 2. Esto ensancha el espectro el mismo factor. De esta forma, el espectro vuelve a ocupar la totalidad del eje.
3. Para cada imagen se **repiten** los pasos 1 y 2, pero esta vez sobre la **segunda dimensión** de las imágenes. El resultado **final** es **cuatro imágenes**: una con la parte baja-baja del espectro, otra con la baja en la primera dimensión y con la alta en la segunda, la tercera con la alta en la primera y la baja en la segunda, y la última, con las dos partes altas. No obstante, debido a los

diezmados, cada imagen tiene ahora un tamaño aproximado de la cuarta parte de la original.

En el esquema de la Ilustración 15 se muestra el diagrama de bloques:

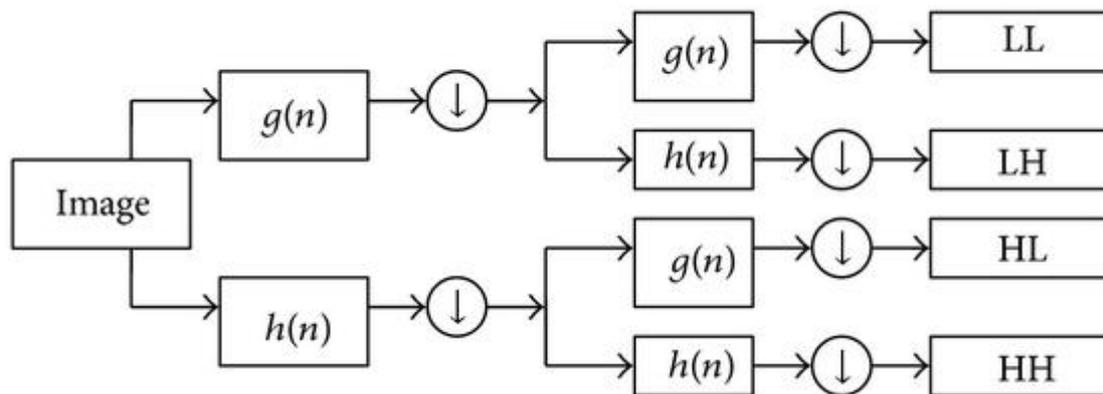


Ilustración 15: Descomposición del espectro de la imagen

Es bastante habitual, que aún después de hacer esto, la imagen de la parte **baja-baja** siga conteniendo una **gran cantidad de información**. Por lo tanto, es metódico aplicar de nuevo el sistema sobre esta imagen. Esto se denomina **aplicar DWT en 2º nivel**, con la obtención de 4 nuevas imágenes. Descartando la que ha sido filtrada en última instancia, el conjunto total es de 7 imágenes. Si se aplica en 3er grado, serán 10. No obstante, hay que tener en cuenta que el límite que determina la graduación DWT depende de la resolución de la imagen original, ya que llegará un punto en el que sea inútil filtrar y diezmar más la imagen.

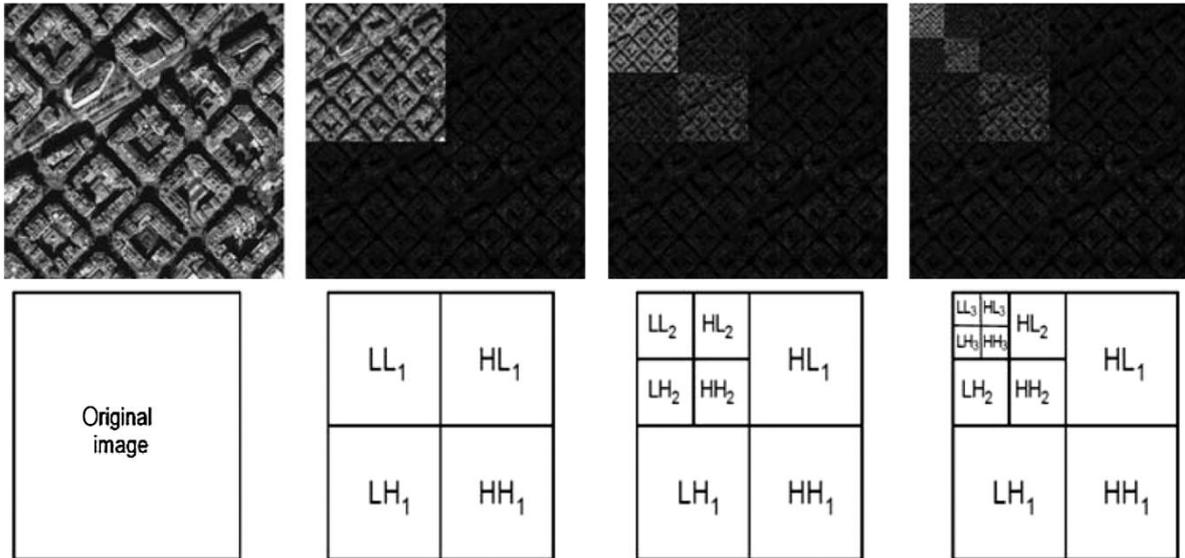


Ilustración 16: Representación de las imágenes resultantes de la DWT para 1, 2 y 3 niveles

3.5 RESIZE (RES)

Resize es un método que **modifica el tamaño de las matrices** con la intención de uniformarlo para todas las imágenes, sin provocar pérdida de información ni afectar negativamente al sesgo. Indicando una resolución, la imagen resultante tendrá dicho tamaño, sin importar el que tuviera en la matriz original.

Probablemente, este sistema actúe como interpolador lineal y/o diezmador sobre señales bidimensionales, como son las imágenes.

3.6 SPARSE MATRIX (S...)

Sin otro nombre más ocurrente con el que bautizar el algoritmo, sparse matrix, simplemente estira una matriz, de tal forma que todos los elementos de la

matriz pasen a estar en un **nuevo vector**. Es equivalente a extraer fila a fila la matriz para luego concatenarlas.

3.6.1 Metodología

El tamaño del nuevo vector es $L=M \cdot N$, donde M y N son la cantidad de filas y columnas de la matriz original, tal y como indica la Ilustración 17.

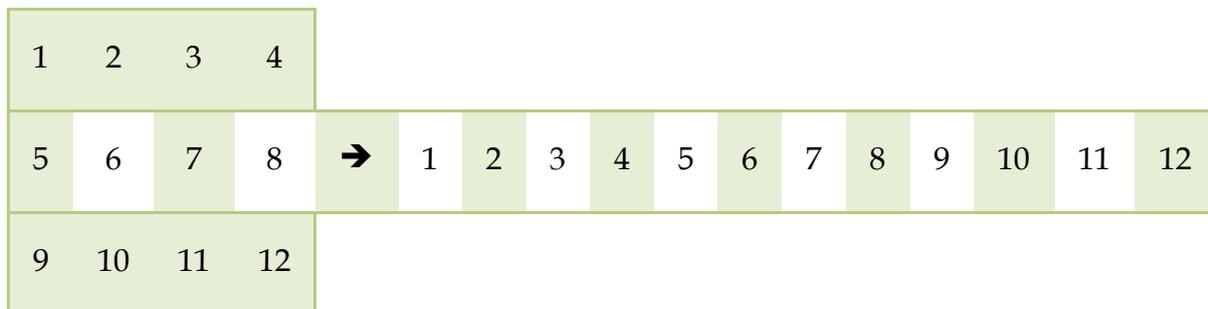


Ilustración 17: Esquema del estiramiento producido por *sparse*

3.6.2 Algoritmo

El código que describe este algoritmo es más sencillo que su explicación:

```
function array=matSparse(mat)
array=mat(:)';
```

Tabla 6: Código de *sparse*

3.7 ESTRUCTURA DE LOS PARÁMETROS

Es importante describir la estructura que deben llevar los parámetros para que puedan ser introducidos en el clasificador, ya que **los datos deben estar en una estructura en forma de matriz**. Ordenados por filas se encuentra cada una de

las muestras, junto con un número de identificación denominado *label* que indica a qué especie pertenece la muestra. Ordenados por columnas, se encuentran todos los parámetros resultantes de los sistemas y algoritmos explicados previamente. Sin embargo, sólo se aceptan los parámetros en forma vectores. La Tabla 7, muestra como debe ser esta estructura.

Muestras	Label (Especie)	HLBP				sGLSM				...
1	1	0	1	...	255	0	1	...	64	
2	1									
...	1									
40	1									
41	2									
...	...									
80	2									
81	3									
...	...									
920	23									

Tabla 7: Ejemplo de una estructura de parámetros

CAPÍTULO 4: CLASIFICACIÓN

¡Ser o no ser, esa es la cuestión!

Hamlet, de William Shakespeare



4.1 INTRODUCCIÓN

En este capítulo, se realiza en esencia, la clasificación de las muestras pertenecientes a especies de plantas. Primero, se describe una etapa previa, en la cual se **preparan los datos** que se van a introducir en el clasificador. Hay que asignar a cada muestra el **identificador denominado *label***, y además, se debe producir **una selección de muestras** para introducir en el clasificador. Con esto preparado, se explica el funcionamiento teórico del **clasificador** y la cuestión que suponen sus dos fases: la fase de **entrenamiento** y la fase de **test**.

4.2 ASIGNACIÓN DE LABELS

Si se recuerda la **estructura de datos vista en el apartado anterior**, se vio que las muestras estaban acompañadas de un **identificador de clase**. Este sirve para indicar a qué **especie** pertenece la muestra en cuestión. Además, cada muestra viene acompañada por el conjunto de **parámetros** extraídos en la fase de parametrización.

Con el fin de guiar al clasificador, **hay que etiquetar cada muestra**. Esto sirve para que **el clasificador sepa** a qué clase pertenece cada muestra. Así, las muestras cuyos *labels* sean idénticos pertenecen a la misma clase. Entonces, es conveniente manejar los identificadores de especie como si fueran los propios *labels*. De esta manera, el clasificador tendrá la tarea de discernir entre una especie y otra.

Yendo un poco más lejos, se propone un **segundo labelling** o agrupación para la ejecución de otro clasificador que sea menos restrictivo. En vez de discernir entre especies, la finalidad de este nuevo clasificador será la de **identificar entre familias** de especies. A continuación, se expone una tabla. La segunda columna indica cuál es la nueva agrupación:

Nombre de la especie	Nombre de la familia	Imagen de muestra
<i>Acacia cyclops</i>	Acacias	
<i>Acacia saligna cyanophylla</i> A		
<i>Acacia saligna cyanophylla</i> B		
American agave	Agaves	
Blue agave		
<i>Araucaria excelsa heterophylla</i>		
<i>Cupressus macrocarpa</i>		
<i>Eriobotrya japonica</i>		
<i>Eucalyptus camaldulensis</i>		
<i>Ficus carica</i>		
<i>Leucaena leucocephala</i>		
<i>Nicotiana glauca</i>		
<i>Opuntia azurea</i>	Opuntias	
<i>Opuntia dillenii</i>		
<i>Opuntia duragensis</i>		

Opuntia maxima		
Opuntia pycnantha		
Opuntia tomentosa		
Phoenix dactylifera	Palmeras	
Ravenala madagascariensis		
Ricinus communis		
Rumex lunaria		
Schinus molle		

Tabla 8: Identificación de las familias

Los *labels* no son más que números naturales. Así los interpreta el clasificador. Sin embargo, como se ha visto en este apartado, están **referidos a especies**, para un caso, **y a familias de especies**, para el otro caso.

4.3 SELECCIÓN DE MUESTRAS

A partir de la parametrización, se tienen que cumplir dos fases en la clasificación: el entrenamiento y el test. En ambas fases, se introducen las muestras de la estructura de parámetros. No obstante, hay que tener en cuenta que el entrenamiento condiciona el test. Para mantener el sesgo, **la proporción de muestras para cada especie debe ser similar**, tanto en entrenamiento como en test. Con la idea de optimizar el rendimiento el clasificador ante nuevas muestras, **los**

conjuntos de entrenamiento y test deben ser disjuntos. Además, para obtener los resultados más objetivos, se van a utilizar **todas las muestras de la base de datos.**

Para cumplir estas dos condiciones, se toma la estructura de parámetros original y se divide en dos: una para la fase de **entrenamiento** y la otra, para la fase de **test**. Para hacerlo, se toma un número determinado de muestras para cada especie. Nuevamente, para que los resultados sean objetivos, el conjunto de muestras se escoge de forma aleatoria. De esta manera, las muestras que están dentro del conjunto serán para el entrenamiento y, consecuentemente, el resto son para test.

El número de muestras que se asigna a sendas estructuras viene dado por la **tasa de entrenamiento**. Es un porcentaje que indica con cuántas muestras, sobre el total, se entrena. Se ha escogido de forma arbitraria una tasa de entrenamiento del **75 %**. Esto quiere decir que, de las 40 muestras por especie de la parametrización, se seleccionan **30 para entrenar** y las **10 restantes, para test**. Recordando que la base de datos contiene 23 especies, esto hace un **total de 690** muestras para entrenar y **230** para testear. El esquema que se muestra a continuación resume la estructuración.

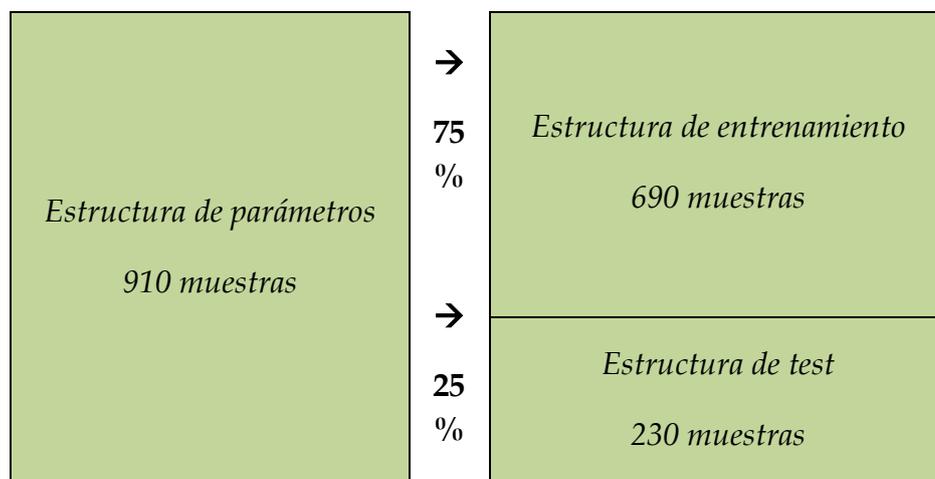


Tabla 9: Representación de la asignación de muestras

4.3.1 Metodología

Para la clasificación, se va a usar **una Máquina de Vectores de Soporte**, en inglés *Support Vector Machine* (SVM). Se desarrolló con el objetivo de minimizar el riesgo estructural mediante la optimización de los **márgenes entre clases**. Este tipo de clasificador resulta adecuado debido a la variabilidad de unos parámetros que son ruidosos [26].

El *kernel* es uno de los recursos de este tipo de clasificadores. Es la **definición de una función** para el cálculo del hiperplano, lo que hace al clasificador generalista, apto para una amplia variedad de aplicaciones. El *kernel* que se utiliza por defecto es *Radial Basis Function* (RBF). Es una función muy conocida en el campo de la estadística porque **representa la distribución normal**. Está definida como:

$$K(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}\right) \quad \text{Eq 6}$$

Siendo x y x' valores multidimensionales, $\|\mathbf{x} - \mathbf{x}'\|^2$ es la distancia euclídea entre dos puntos. Por su parte, σ^2 es la varianza de las muestras.

No obstante, la SVM peligra con el denominado **sobre-entrenamiento**. Este problema consiste en que la naturaleza de las muestras **no esté sesgada**. Esto quiere decir que las muestras no representan con naturalidad la clase en cuestión, ya sea por el **bajo número de muestras** o por una **desviación** de la media o la varianza. La consecuencia será un mayor número de equivocaciones a la hora de clasificar.

Una SVM es capaz de minimizar el error que supone la clasificación con el **cálculo del hiperplano óptimo** que separe y **maximice el margen entre** dos o más **clases**. Para hacerlo, se genera un hiperespacio en base a los parámetros. **Las muestras son representadas** en el mismo en forma de puntos. Cada punto es una muestra, con sus respectivos **parámetros como coordenadas**. De esta forma, el número de dimensiones coincide con el número de parámetros. Aquellos puntos que estén más cercanos a otras clases son definidos como los *vectores de soporte*. En base a ellos, se calculan los márgenes mínimos de cada clase. En función de éstos, se traza un hiperplano equidistante entre una pareja de clases. Esto se puede observar en la siguiente ilustración:

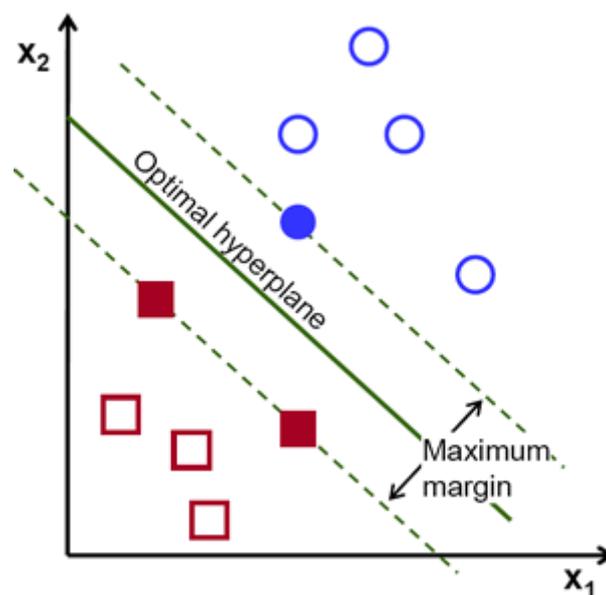


Ilustración 18: Representación del cálculo del hiperplano óptimo en una clasificación binaria

Si en una dimensión o en un conjunto de dimensiones, hay muestras de una misma clase que tienden a localizarse en una región en concreto del hiperespacio, estas muestras se pueden identificar. Si además, es la única clase que ocupa esa región, la identificación de esa especie será inequívoca.

Particularizando, la máquina implementada es una *Least Square Support Vector Machine* (LSSVM). La principal diferencia es que no se traza un hiperplano de separación, sino una **hipersuperficie** que bordea los vectores de soporte.

La clasificación de múltiples clases en este LSSVM se hace en **modo 1vs1**; que no es más que la **superposición** de modelos **bi-clase**. Esto quiere decir que para cada clase se traza un modelo, con una de las clases etiquetada con (+) y el resto, con (-). La identificación de una muestra para cada modelo, resulta en vectores de clase. En conjunto, estos indican, por votación, cuál es la clase más probable a la que pertenece la muestra. En el caso en el que la muestra no entre en **ninguna de las regiones, se rechaza**.

Sabiendo cómo funciona el clasificador, a continuación se definen las dos fases en las que opera dicho clasificador. La primera es la etapa de entrenamiento; la segunda, la de test. Ésta es consecuente de aquella.

4.3.2 Entrenamiento

La primera etapa de clasificación es la etapa de entrenamiento. Supone la implementación de un modelo mediante un gran conjunto de datos, como el visto en la asignación de muestras. Para hacerlo, el clasificador recibe todas las muestras con sus correspondientes *labels*. El resultado es un modelo de clasificador que se puede interpretar como **un hiperespacio** con las muestras **representadas en forma de puntos**, donde las coordenadas equivalen a los parámetros. El proceso se resume en el siguiente esquema:

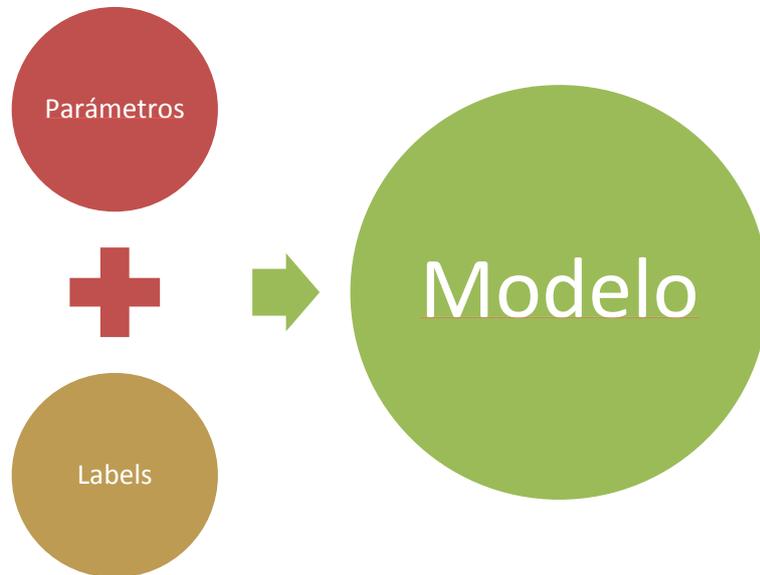


Ilustración 19: Esquema del entrenamiento del clasificador

A modo de ejemplo, se muestra un espacio de dos dimensiones con las muestras de la estructura de entrenamiento en la Ilustración 20. Los colores y formas dictan la clase o *label* a la que pertenece cada muestra.

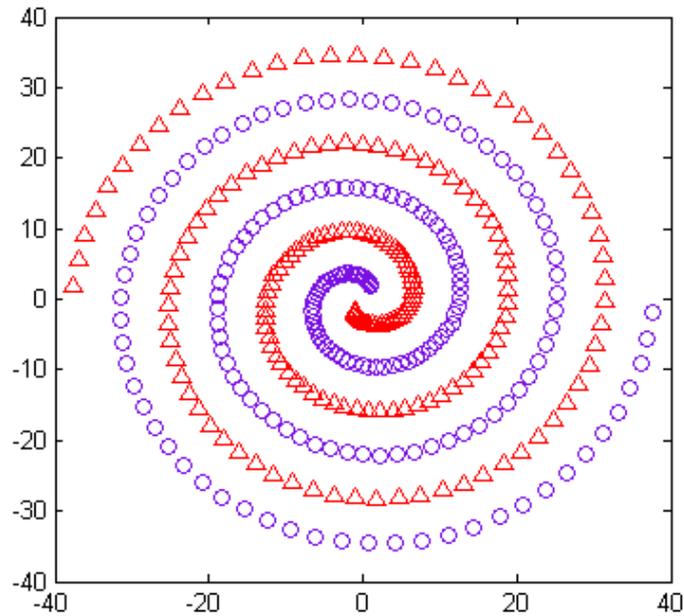


Ilustración 20: Muestras correspondientes a dos clases representadas con dos parámetros

A partir de aquí, el clasificador **calcula los márgenes entre una clase y otra**, para luego trazar las fronteras que separan las regiones. De esta forma, se **proyectan las regiones** que definen el modelo de clasificador. En la ilustración 21 se pueden ver dos áreas: la verde se corresponde con la clase (o) y la blanca, con la (Δ).

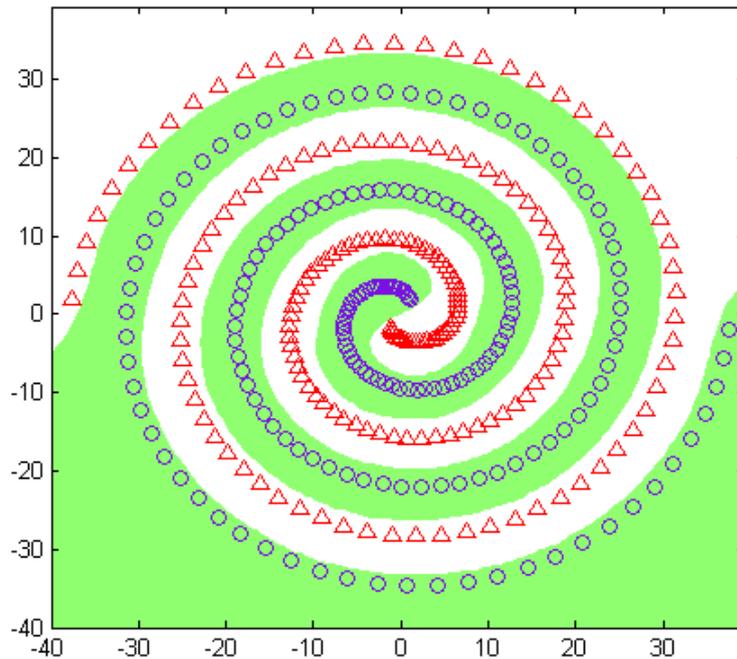


Ilustración 21: Definición de las regiones correspondientes a cada clase a partir de las muestras

Una vez se dispone del modelo, se procede a analizar su funcionalidad.

4.3.3 Test

En la fase de test, se evalúa el **comportamiento del clasificador**. Ahora, los parámetros de cada muestra de la estructura de datos correspondiente son introducidos en el modelo, anteriormente implementado. No obstante, los *labels* que acompañan a cada muestra no se incorporan al clasificador debido a que es ahora él el que genera un vector de salida de clases. Esto quiere decir que al introducir una muestra en el clasificador, se obtiene un **identificador de la clase** a la que pertenece dicha muestra. Sin embargo, hay que suponer que el clasificador **puede equivocarse** y que la muestra que se ha introducido perteneciera a otra clase. Para saber si el clasificador funciona correctamente, la muestra debe ser

comparada con el *label* que la acompañaba en la estructura de test. Nuevamente, se resume su esquema:

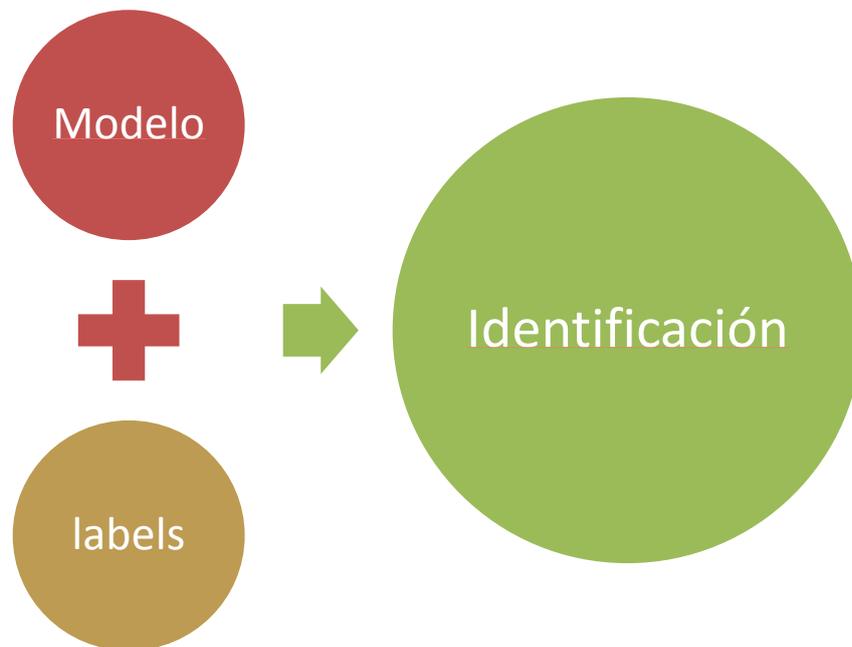


Ilustración 22: Esquema del test del clasificador

Partiendo de la etapa de entrenamiento, se dispone de un clasificador con las regiones ya definidas. La ilustración 23 sigue el ejemplo del apartado anterior. En ella, las 3 muestras que se observan, se corresponden con las nuevas introducidas por la estructura de test. La muestra representada por (o) se ha identificado correctamente, al igual que (Δ) sobre la región blanca. No obstante, la tercera muestra se ha posicionado, desafortunadamente, sobre la región equivocada.

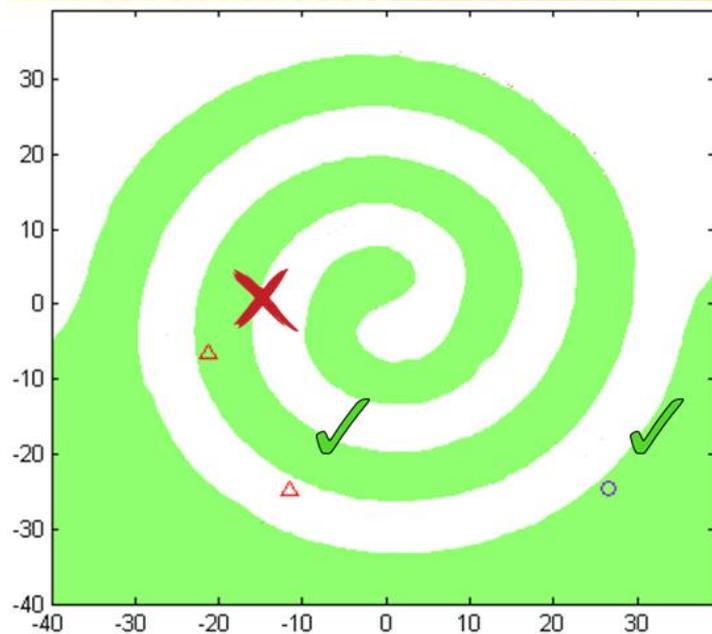


Ilustración 23: Representación de tres muestras de test sobre un modelo entrenado

La cantidad de aciertos y fallos se compila en una matriz de confusión. Un concepto que se explica en el siguiente apartado.

4.4 LA MATRIZ DE CONFUSIÓN

La matriz de confusión es una matriz de tamaño $N \times N$, donde **N** es el **número de clases** que trata el clasificador de diferenciar. De cada test que se hace uno de los clasificadores implementados, se extrae una matriz. Esta guarda la información de los aciertos y fallos de forma indexada. Cada fila de la matriz representa el número de **predicciones** que se ha hecho de cada clase, mientras que cada columna representa la **clase real**. Cuanto mayores sean los valores de la **diagonal principal**, con respecto al resto, se puede decir que el clasificador mejora.

De esta matriz se puede extraer un parámetro determinante para verificar la funcionalidad del clasificador. Es la tasa de acierto. Es una relación entre el

número de aciertos con respecto al número total de clasificaciones. Visto de otra manera, es la relación entre la diagonal principal con respecto al total de la matriz. Matemáticamente se define como:

$$Tasa\ de\ acierto = \sum_k^{<N>} \frac{MdC(k, k)}{Total} \quad \text{Eq 7}$$

En la ilustración 24, se puede observar una matriz de confusión para dos clases. En verde, aparecen los aciertos. Ha habido 446 muestras de la clase 1 clasificadas correctamente, al igual que 236 muestras de la clase 2. Por otro lado, en rojo se ven los fallos: 5 muestras de la clase 2 se han interpretado como si fueran de la clase 1; y 12 muestras de la clase 1, como si fueran de la clase 2. Además, el sistema añade un borde a la matriz que calcula las tasas de acierto y fallo para cada clase. En azul, está representada **la tasa de acierto global**.

Confusion Matrix

Output Class	1	2	
	446 63.8%	5 0.7%	98.9% 1.1%
2	12 1.7%	236 33.8%	95.2% 4.8%
	97.4% 2.6%	97.9% 2.1%	97.6% 2.4%
	1	2	Target Class

Ilustración 24: Ejemplo de una matriz de confusión con 2 clases

La matriz de confusión es el resultado final. Se generará una por cada clasificador que se ponga a prueba. Todo esto se pone en práctica en el siguiente capítulo.



CAPÍTULO 5: EXPERIMENTOS Y RESULTADOS

Da igual. Prueba otra vez. Fracasa otra vez. Fracasa mejor.

Samuel Beckett



5.1 INTRODUCCIÓN

En este capítulo, se describe cómo se ha puesto a prueba el sistema completo: la base de datos; **parametrizada con los algoritmos y sistemas desarrollados; y los clasificadores implementados**. Para empezar, se **describen los experimentos llevados a cabo**. Se diferencian dos tipos de experimentos. Esto supone que los procesos de representación varían uno con respecto al otro.

5.2 METODOLOGÍA DE EXPERIMENTACIÓN

En este apartado, se expone **cómo se han llevado a cabo los experimentos**. Inicialmente, se tiene en cuenta que se han realizado dos tipos de experimentos: experimentos **cualitativos** y experimentos **cuantitativos**. Por lo tanto, hay que definir cuál ha sido el procedimiento para cada uno de ellos.

Al empezar la experimentación, se comenzó con un análisis de la funcionalidad de los algoritmos y sistemas parametrizadores mediante **experimentos cualitativos**. Esto quiere decir que los experimentos produjeron resultados cuya **información** no era cuantificable, sino **subjetiva**. En los tres experimentos de este tipo que se han desarrollado, se han generado las imágenes correspondientes a la salida de un sistema y un algoritmo de la etapa de parametrización. Esto da lugar a la representación de dichas imágenes con la intención de interpretar la información que brindan de forma visual. Esto se resume en el siguiente esquema:

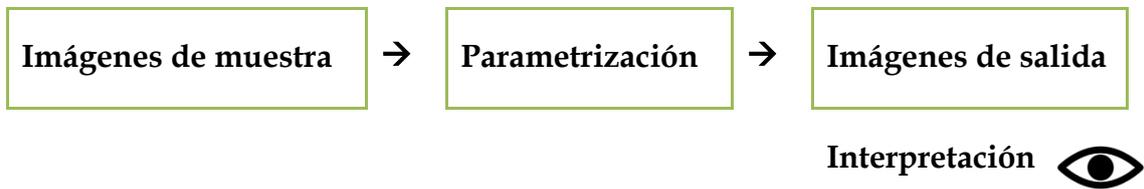


Ilustración 25: Esquema de un experimento cualitativo

Sabiendo que la etapa de parametrización funciona correctamente, se han desarrollado **experimentos cuantitativos**, que dan como resultado una **información cuantificable**: datos, porcentajes, parámetros, números, etc. En esta parte, ya se incluye el clasificador, que formando parte del sistema, da como resultado **una matriz de confusión para cada modelo**. A diferencia de los experimentos cualitativos, en los cuantitativos se toma una serie de uno o más sistemas y/o algoritmos. A esta serie se la conocerá como **cadena**. Con ello, hay que recordar que para cada cadena, se generan dos matrices de confusión: una para especies y otra para familias. De cada matriz se obtiene el parámetro que mejor define la funcionalidad del sistema: **la tasa de acierto** (véase la Ilustración 26).

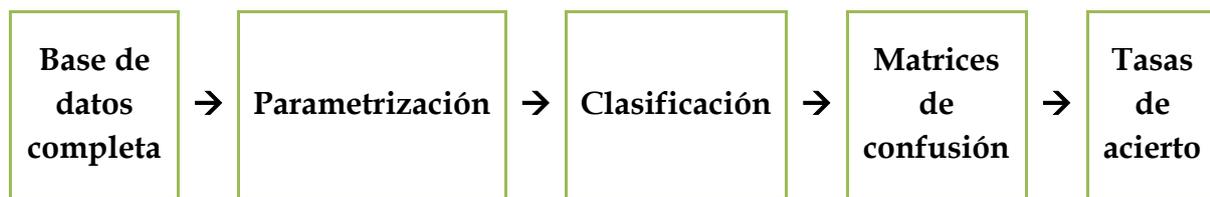


Ilustración 26: Esquema de un experimento cuantitativo

5.3 EXPERIMENTOS CUALITATIVOS

Para un primer análisis de la funcionalidad de los algoritmos y sistemas de la fase de parametrización, se llevaron a cabo **tres experimentos**. El objetivo era

observar las imágenes e interpretar si aparecían similitudes y diferencias entre muestras.

5.3.1 Experimento 1: representación del algoritmo LBP

Partiendo de la elección de **3 muestras arbitrarias de 3 especies diferentes**, se aplicó el algoritmo mLBP que se había desarrollado. El resultado fue una matriz con el mismo formato que la imagen de entrada. Por esta razón, la representación no fue complicada.





Tabla 10: Representación de mLBP

Haciendo un análisis visual de las imágenes, se puede decir que el algoritmo **LBP consigue extraer información** relevante en cuanto a la textura de cada corteza. Desgraciadamente, la duración de la ejecución del algoritmo fue de varios minutos por cada imagen. Una primera conclusión que se extrajo es que la implementación del algoritmo mLBP junto con la base de datos completa requeriría el **almacenamiento en disco de cada imagen**. Así, no habría que repetir algoritmos y sistemas que se hubieran ejecutado previamente.

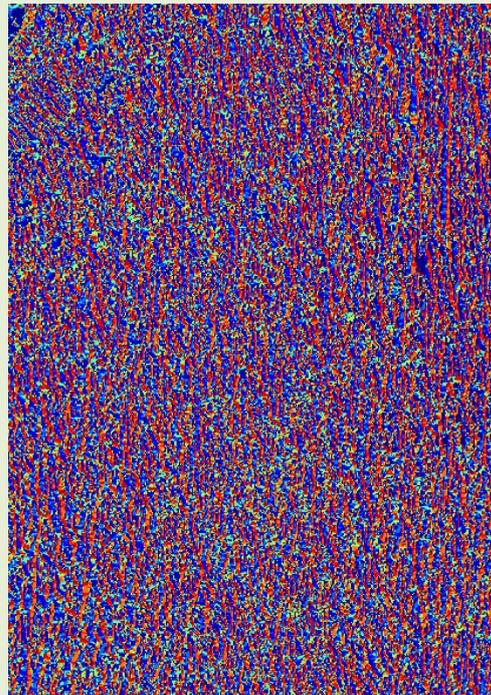
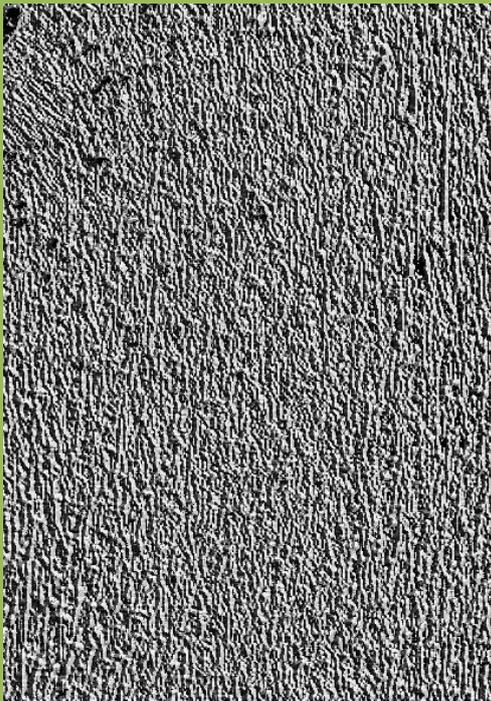
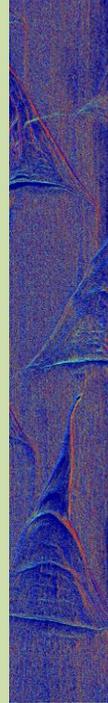
5.3.2 Experimento 2: Representación mapeada en color de LBP

Considerando el experimento anterior, la escala de grises en la que se representaba por defecto la imagen, no permitía discernir entre valores cercanos del MLBP. Por lo tanto, se propuso un mapeado en color. Se representa a continuación:

Imagen LBP con mapa en escala de grises



Imagen LBP con mapa en color



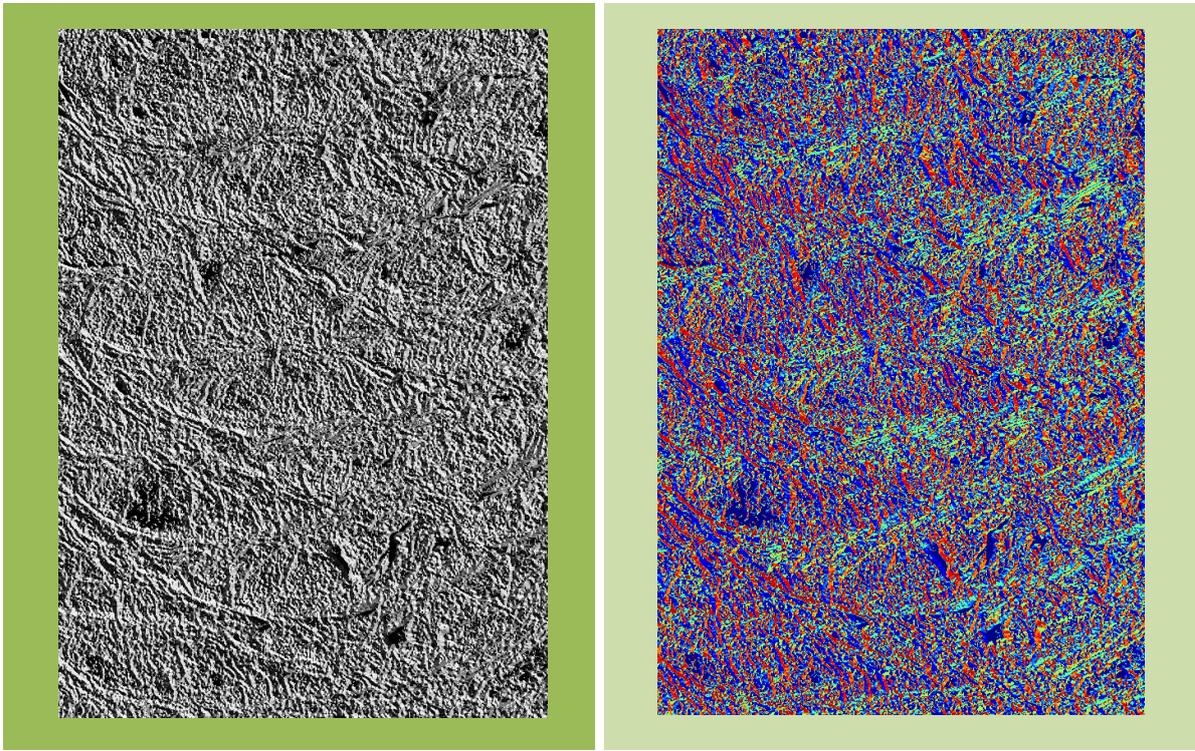


Tabla 11: Representación de mLBP con mapa de color

Ahora sí se puede apreciar una tendencia en la frecuencia de aparición de determinados valores: por ejemplo, en la tercera muestra, se repite mucho más el color cian que en las otras dos muestras. Como cada color está asociado con un valor de la matriz LBP, esto quiere decir que el valor asociado al **cian presenta una mayor frecuencia de aparición** es esta muestra. MATLAB reconoce este mapa de color como *jet*.

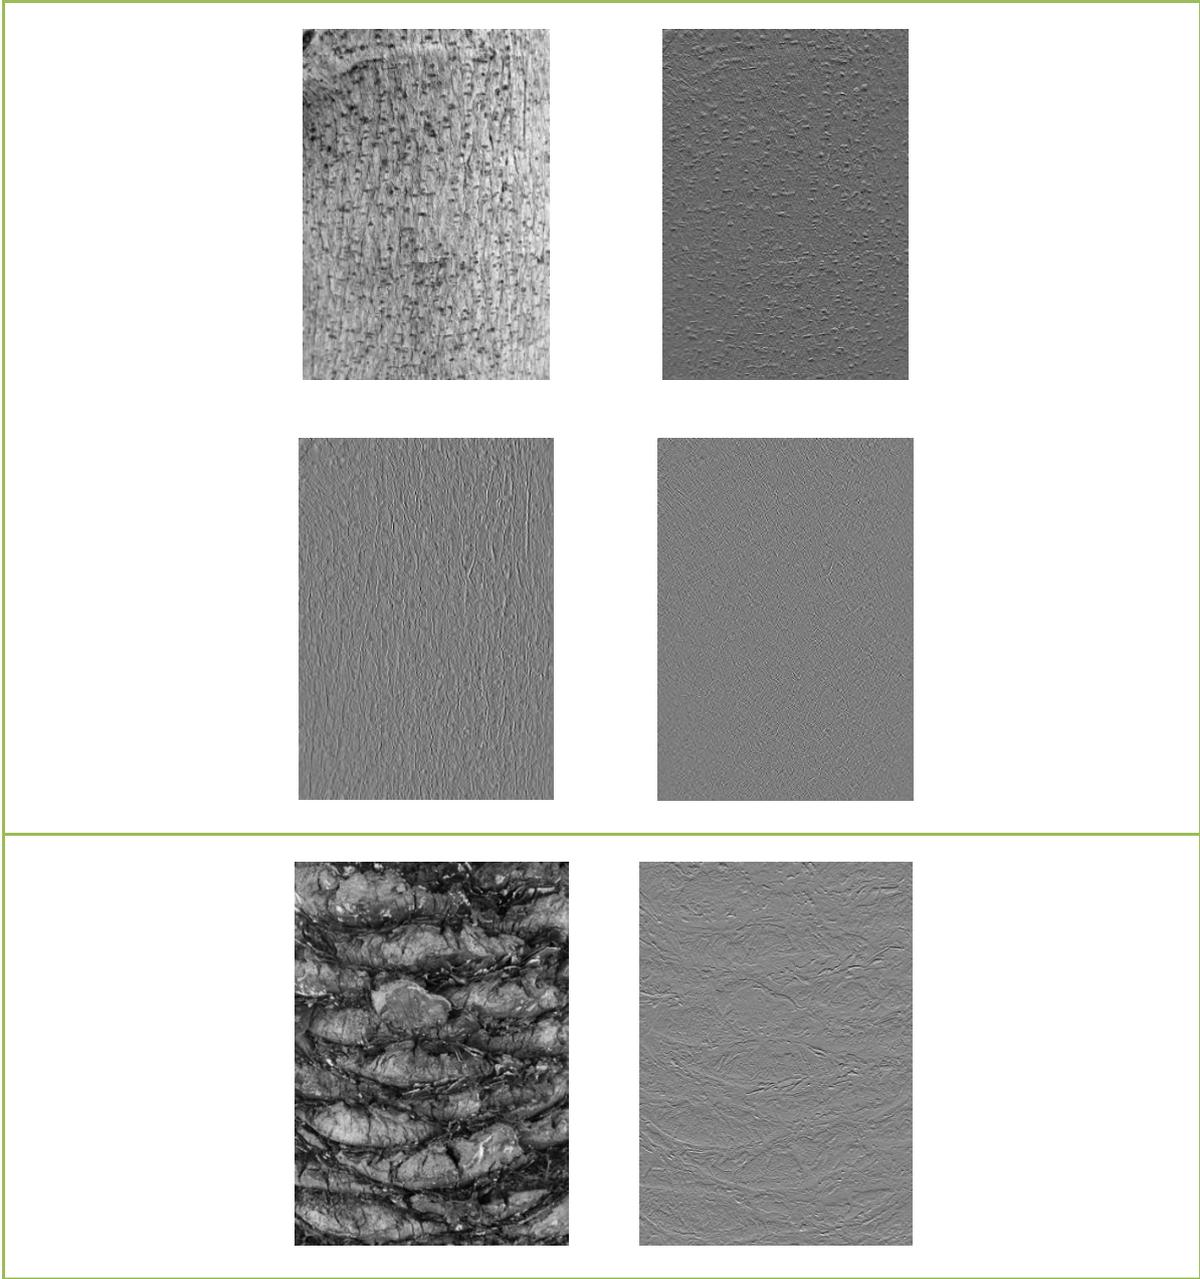
5.3.3 Experimento 3: Representación múltiple de DWT de nivel 1

Además, se hizo una representación del sistema DWT. A diferencia de mLBP, en este se generan 4 imágenes por muestra. Lo que se representa a continuación es la compilación de esas cuatro imágenes como es habitual en este

sistema, con la parte baja-baja del espectro de la imagen en la esquina superior izquierda y la parte alta-alta, en la inferior derecha.

Compilación DWT de nivel 1





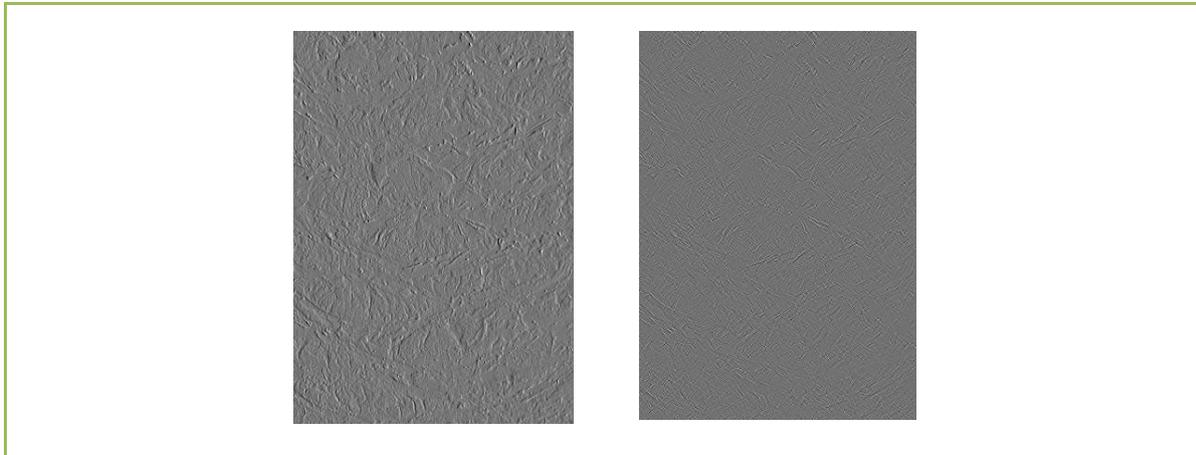


Tabla 12: Representación de 3 muestras al aplicarles la DWT de nivel 1

Para la primera muestra, apenas se observa que haya una separación de información con la única aplicación de un nivel del sistema DWT. Sin embargo, para las otras dos, sí se produce tal división. En la segunda muestra, se aprecia una **separación entre las vetas y los nodos del tronco**. Se puede decir que la división que ejecuta **DWT produce nuevas texturas**. Por lo tanto, se cree que puede ayudar en la identificación de especies.

5.4 EXPERIMENTOS CUANTITATIVOS

Llevando a cabo un análisis más laborioso del sistema completo se ha comprobado el grado de confusión del clasificador. Con un total de **8 experimentos** se han obtenido una considerable **cantidad de tasas de acierto** para las **diferentes cadenas de algoritmos y sistemas**. El principal objetivo era comprobar las tasas de acierto de todos estos sistemas y algoritmos de la fase de parametrización para detectar el conjunto que mejor funciona. Para cada experimento hay unos procesos y características comunes. El esquema general de experimentación sigue estos pasos:

1. **Elección de las cadenas de parametrización:** Para formar una cadena, se elige uno o más algoritmos y sistemas de pre-procesado y extracción de parámetros. A continuación, se define el orden de ejecución de cada uno. Considerando la repetitividad que supone la elección de múltiples cadenas, se agrupan varias cadenas en un solo experimento. Cada experimento está definido, principalmente, por el algoritmo o sistema más relevante.

Hay dos restricciones para la elección de cada cadena: La primera es que **no se puede aplicar un algoritmo o sistema que procese la imagen cuando el predecesor siquiera genera una imagen** o matriz. La segunda tiene que ver con que **el clasificador no acepta imágenes o matrices** como datos de entrada. Tienen que ser vectores. Como indicación, queda comentar que la elección de determinados algoritmos, sistemas y el orden de ejecución dependen de la intuición y la tendencia al éxito. Si la ejecución de un algoritmo o sistema es absurda en esa posición de la cadena, no tiene sentido hacerlo. Así mismo, un algoritmo o sistema que demuestre una alta tasa de acierto merece incluirse en futuras cadenas.

2. **Ejecución de la parametrización:** Una vez se ha definido la cadena de algoritmos y sistemas, se procede con su ejecución. Teniendo en cuenta la duración de la aplicación de los experimentos cualitativos y el concepto de la cadena de algoritmos y sistemas, se ideó una forma para no repetir secuencias ya ejecutadas. Cada vez que se ejecuta un algoritmo o sistema, el programa carga y guarda en disco todas las imágenes, matrices o vectores de salida. La ruta tiene un nombre asignado conforme a la cadena en cuestión.

3. **Implementación de los clasificadores:** Con la estructura de datos que se forma a partir de la etapa de parametrización, se implementan dos clasificadores uno para la identificación de especies y otro para la identificación de familias. Esto se hace en cada cadena de manera regular. A partir del experimento 5 en adelante, sólo se implementan LSSVMs, que quedan definidos por los siguientes parámetros:

Parámetro	Valor
Tipo	Clasificador
Número de clases	23 especies 14 familias
<i>Kernel</i>	RBF
Tasa de entrenamiento	75 %
Número de muestras	690 para entrenamiento 230 para test
Modo de clasificación	1 vs 1

Tabla 13: Especificaciones del clasificador

4. **Obtención de resultados:** Por cada cadena, se obtienen parejas matrices de confusión. De ellas se pueden extraer sus correspondientes tasas de acierto, que serán las que determinarán la funcionalidad del sistema experimentado. Algunos de los sistemas generaban más de una imagen, por lo que habrá experimentos que muestren más de una pareja de tasas

de acierto. Por simplicidad, **sólo se representan las matrices cuyas tasas de acierto son bastante relevantes**. Todos estos datos se han recopilado y se pueden extraer del directorio: *.../Proyecto/Matlab/Tested*.

5.4.1 Árbol esquema

La cantidad de cadenas escogidas puede ser abrumadora. Tanto para no perderse durante la experimentación como para no confundirse en esta redacción, se ha dibujado el mapa que representa todas las cadenas aplicadas. En él viene indicado cuál es el experimento donde se ha ejecutado dicha cadena.

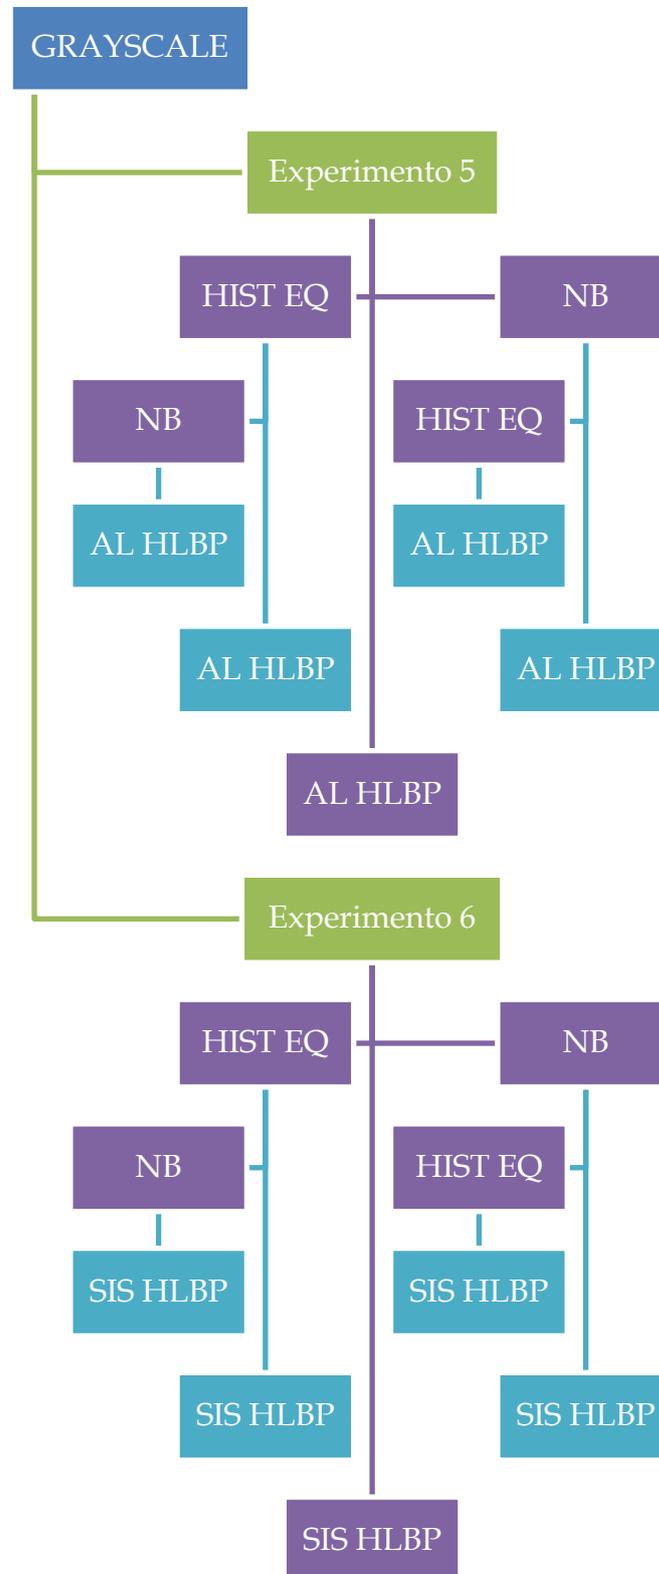


Ilustración 27: Esquema de los algoritmos y sistemas de los experimentos 5 y 6

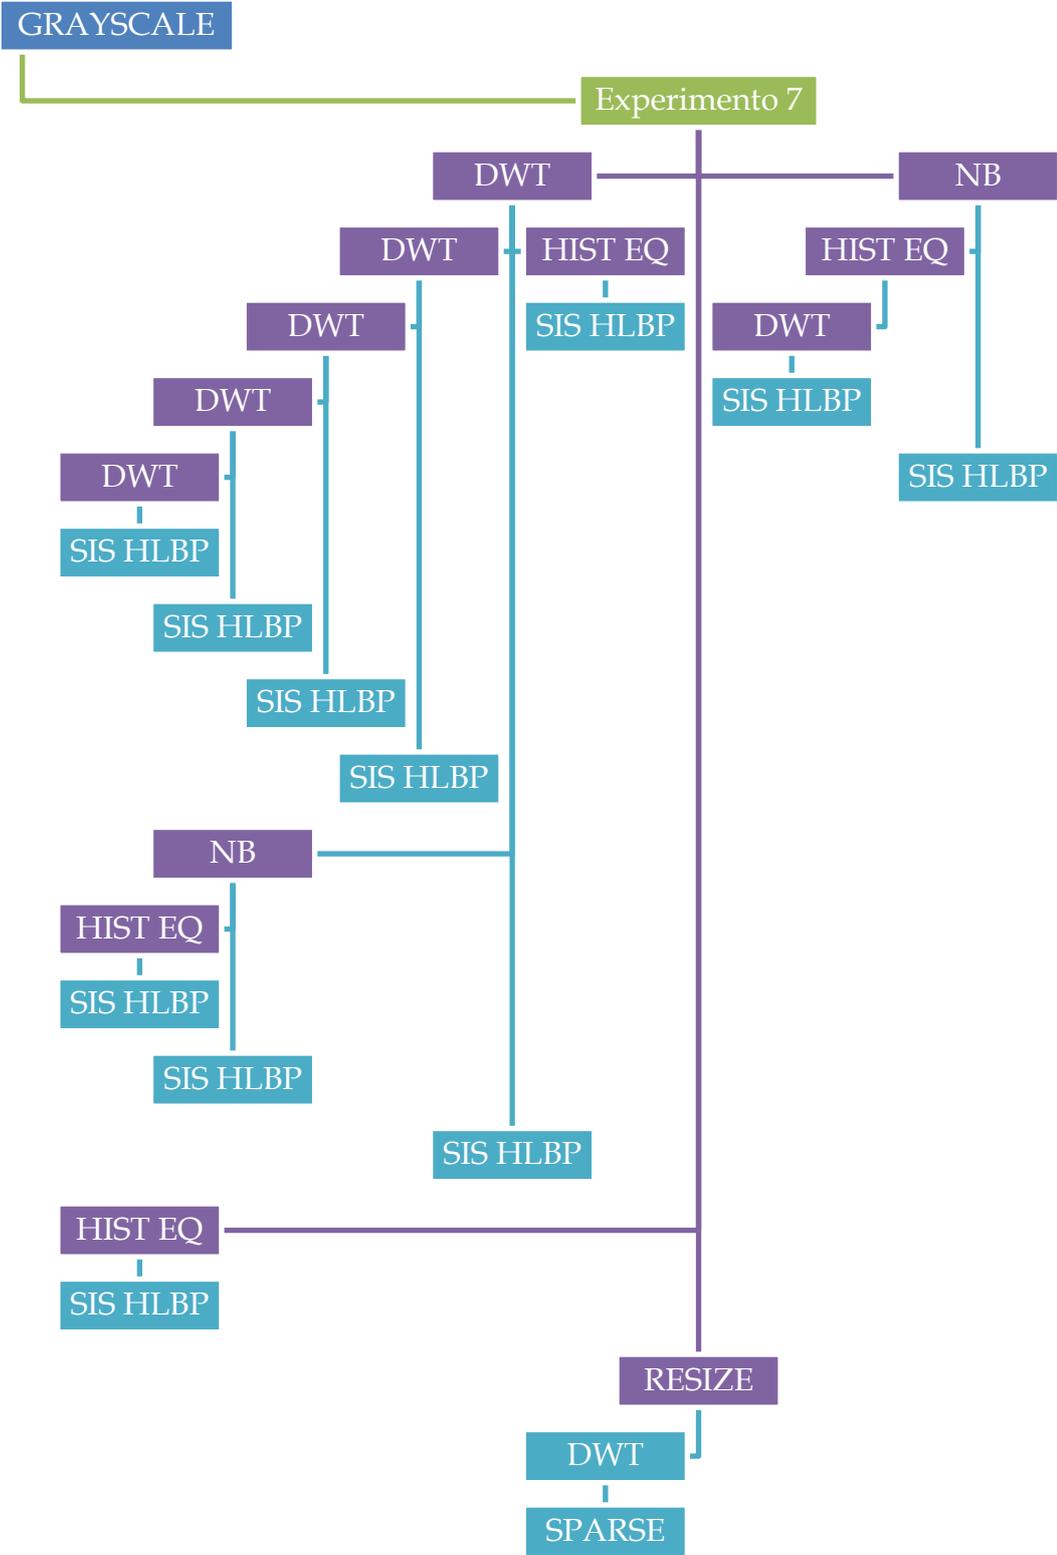


Ilustración 28: Esquema de los algoritmos y sistemas del experimento 7

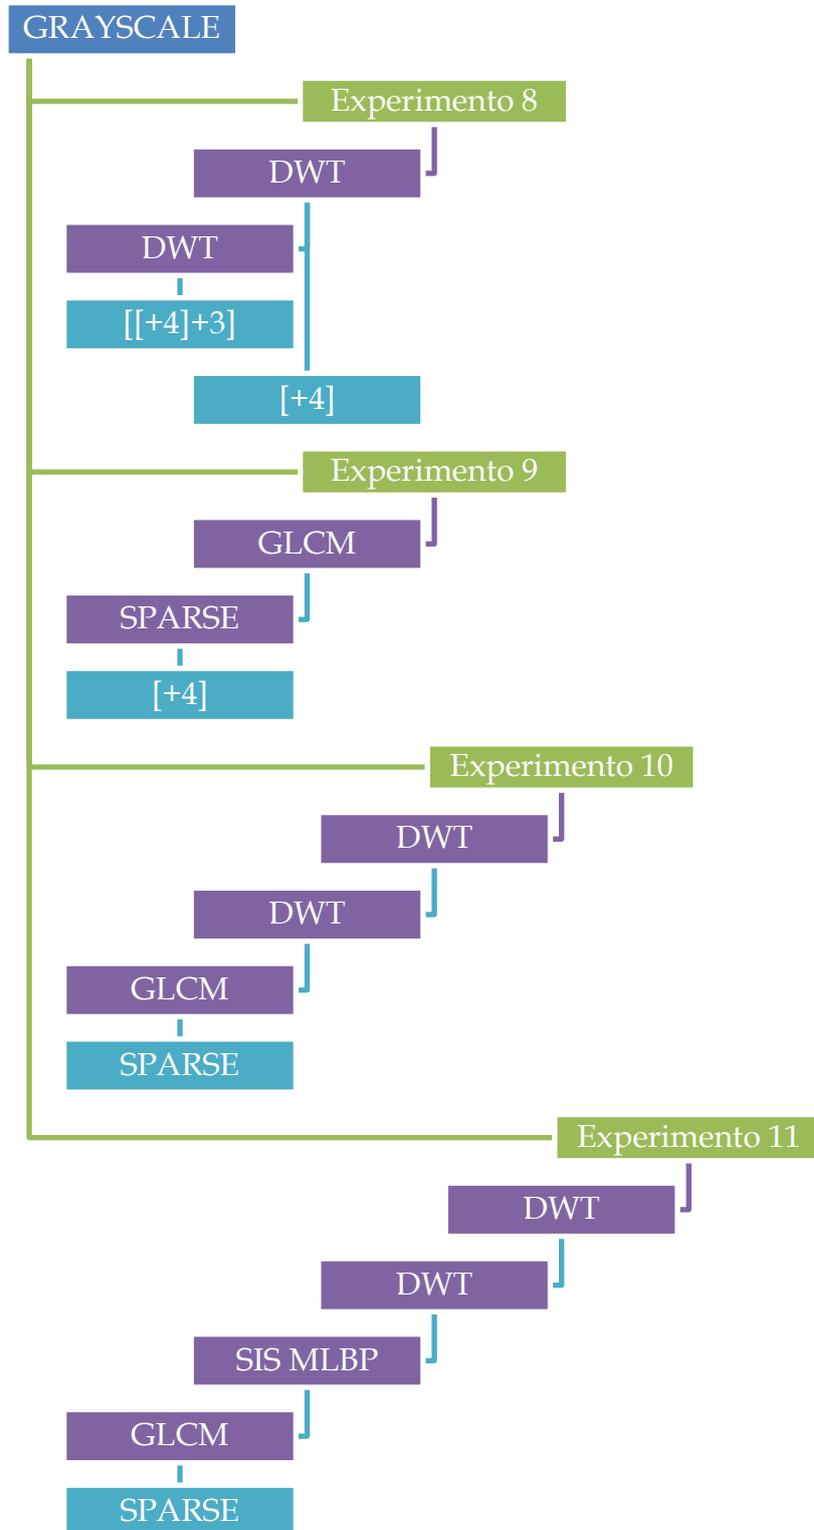


Ilustración 29: Esquema de los algoritmos y sistemas de los experimentos del 8 al 11

5.4.2 Experimento 4: Clasificador SVM con algoritmo LBP

El primer clasificador que se ejecutó fue una máquina de soporte genérica. Lamentablemente, su **implementación no funcionó**. Este error se achaca a que el sistema no soportaba un conjunto tan grande de parámetros.

Este experimento se califica como **FRACASO**. A partir de esta conclusión, se ha utilizado el sistema LS-SVM. Es el único aplicado en los restantes experimentos. Como el SVM genérico se descartó tan pronto, no se le ha querido dar más protagonismo.

5.4.3 Experimento 5: Algoritmo hLBP

El primer algoritmo que fue aplicado fue el LBP en su versión de histograma. Aunque los resultados no fueron muy esperanzadores, sí se pudo hacer un pre-procesado intermedio de las imágenes. Así, se podía extraer una primera conclusión sobre la aplicación del algoritmo *NoBackground* y del sistema *HistEq*. Se ejecutaron 5 cadenas y se obtuvieron sus 10 tasas de acierto correspondientes. Se pueden observar en la tabla 14.

Sistema de clasificación	AL HLBP	NB+ AL HLBP	H+ AL HLBP	NB+H+ AL HLBP	H+NB+ AL HLBP
Especie	44.7761 %	44.8980 %	37.1728 %	40.9326 %	38.6473 %
Familia	54.1872 %	56.7164 %	47.1698 %	50.4717 %	50.9524 %

Tabla 14: Resultados del algoritmo hLBP

Este experimento se califica como **INSUFICIENTE**. Aunque el sistema funcionara, el resultado del clasificador es pésimo. El identificador se equivoca la mitad de las veces. No obstante, ahora se sabe que el algoritmo *NoBackground*, mejora ligeramente la precisión del hLBP.

5.4.4 Experimento 6: Sistema hLBP

En vista a los malos resultados que demostró el experimento anterior, se ha repetido haciendo una **importante modificación**. En vez de aplicar el algoritmo hLBP desarrollado en este proyecto, se utiliza un sistema que, supuestamente, funcionaba de manera equivalente. Afortunadamente, este supuesto resultó ser falso, ya que la sustitución del algoritmo con el sistema trajo consigo los siguientes resultados:

Sistema de clasificación	SIS HLBP	NB+ SIS HLBP	HEQ+ SIS HLBP	NB+HEQ+ SIS HLBP	H+NB+ SIS HLBP
Especie	81.6038%	82.3810 %	82.7103 %	82.8054 %	79.4521 %
Familia	84.4749 %	83.8565 %	83.7209 %	85.2679 %	15.1515 %

Tabla 15: Resultados del sistema hLBP

Este experimento se califica como **BUENO**. Demuestra que el algoritmo hLBP funcionaba de manera incorrecta. En cuanto al pre-procesado de la imagen, esta vez parece que con la aplicación de *HistEq* y del *NoBackground* se alcanzan unas tasas de acierto máximas hasta ahora. A continuación, se exponen sus matrices de confusión:

Confusion Matrix

Output Class	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23		
1	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100%	
2	1	10	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	66.7%
3	0	0	5	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	55.6%
4	0	0	0	5	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4.4%
5	0	0	0	0	5	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	55.6%
6	0	0	0	0	0	6	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30.0%
7	0	0	0	0	0	0	4	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	44.4%
8	0	0	0	0	0	0	0	3	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30.0%
9	0	0	0	0	0	0	0	0	6	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	75.0%
10	0	0	0	0	0	0	0	0	0	8	2	0	0	0	0	0	0	0	0	0	0	0	0	0	80.0%
11	0	0	0	0	0	0	0	0	0	0	3	7	3	0	0	0	0	0	0	0	0	0	0	0	70.0%
12	0	0	0	0	0	0	0	0	0	0	0	6	2	0	0	0	0	0	0	0	0	0	0	0	75.0%
13	0	0	0	0	0	0	0	0	0	0	0	0	6	1	0	0	0	0	0	0	0	0	0	0	85.7%
14	0	0	0	0	0	0	0	0	0	0	0	0	0	9	5	0	0	0	0	0	0	0	0	0	64.3%
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	4	0	0	0	0	0	0	0	0	55.6%
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	3	0	0	0	0	0	0	0	66.7%
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7	3	0	0	0	0	0	70.0%
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	1	0	0	0	0	85.7%
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	2	0	0	0	81.8%
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	2	0	0	75.0%
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7	6	0	0	83.8%
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4	1	0	80.0%
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	0	100%
	87.5%	100%	55.6%	55.6%	55.6%	60.0%	40.0%	37.5%	66.7%	30.0%	77.8%	66.7%	50.0%	90.0%	40.0%	66.7%	90.0%	75.0%	77.8%	40.0%	90.0%	8.2%	12.5%	0.0%	1.8%

Ilustración 30: Matriz de confusión del sistema hLBP con ecualización del histograma en clasificación de especies

Confusion Matrix

1	27 12.6%	0 0.0%	1 0.5%	0 0.0%	2 0.9%	1 0.5%	4 1.9%	1 0.5%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	71.1% 28.9%
2	0 0.0%	15 7.0%	2 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	78.9% 21.1%
3	1 0.5%	2 0.9%	53 24.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	1 0.5%	1 0.5%	0 0.0%	89.8% 10.2%
4	0 0.0%	0 0.0%	1 0.5%	18 8.4%	0 0.0%	0 0.0%	94.7% 5.3%								
5	1 0.5%	0 0.0%	0 0.0%	1 0.5%	7 3.3%	0 0.0%	0 0.0%	77.8% 22.2%							
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.7%	0 0.0%	0 0.0%	100% 0.0%						
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 1.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 3.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
9	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	6 2.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	75.0% 25.0%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 3.3%	2 0.9%	0 0.0%	0 0.0%	0 0.0%	77.8% 22.2%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 1.4%	8 3.7%	0 0.0%	0 0.0%	0 0.0%	72.7% 27.3%
12	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 3.3%	3 1.4%	0 0.0%	63.6% 36.4%
13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 1.4%	0 0.0%	100% 0.0%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.7%	100% 0.0%
	90.0% 10.0%	83.3% 16.7%	93.0% 7.0%	94.7% 5.3%	77.8% 22.2%	88.9% 11.1%	44.4% 55.6%	70.0% 30.0%	75.0% 25.0%	70.0% 30.0%	80.0% 20.0%	87.5% 12.5%	37.5% 62.5%	100% 0.0%	83.7% 16.3%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
	Target Class														

Ilustración 31: Matriz de confusión del sistema hLBP con ecualización del histograma en clasificación de familias

Confusion Matrix

Output Class	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	9	0	0	0	1	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
4	0	0	0	7	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
5	0	0	0	1	7	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0
6	0	0	0	0	1	6	1	0	0	0	0	0	0	0	0	0	0	0	0	2	2	0	0
7	0	1	1	0	0	0	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
9	0	0	0	0	0	0	0	0	1	8	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	1	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	3	10	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	1	0	0	0
14	0	0	0	1	0	0	0	0	0	0	0	0	0	0	10	1	1	0	1	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	2	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	5	0	0	0
19	0	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	0	0	9	0	0	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	1
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	8
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10
	100%	0.0%	7.8%	7.8%	7.5%	0.0%	0.0%	7.1%	0.0%	0.0%	6.7%	0.0%	8.0%	0.0%	8.9%	2.5%	0.0%	5.6%	0.0%	6.0%	2.5%	8.9%	100%
	0.0%	0.0%	2.2%	2.2%	2.5%	4.0%	0.0%	4.2%	0.0%	0.0%	3.3%	0.0%	4.0%	0.0%	1.1%	7.5%	0.0%	4.4%	0.0%	4.0%	7.5%	1.1%	0.0%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23

Ilustración 32: Matriz de confusión del sistema hLBP con ecualización del histograma y sin background en clasificación de especies

Confusion Matrix

1	27 12.1%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	3 1.3%	1 0.4%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	81.8% 18.2%
2	0 0.0%	15 6.7%	2 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	88.2% 11.8%
3	0 0.0%	1 0.4%	56 25.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.2% 1.8%
4	0 0.0%	0 0.0%	1 0.4%	16 7.2%	4 1.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	76.2% 23.8%
5	1 0.4%	1 0.4%	0 0.0%	1 0.4%	6 2.7%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 1.8%	0 0.0%	0 0.0%	42.9% 57.1%
6	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 3.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	87.5% 12.5%
7	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	4 1.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	80.0% 20.0%
8	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.0% 10.0%
9	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	9 4.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	81.8% 18.2%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 2.7%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	85.7% 14.3%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 1.3%	9 4.0%	0 0.0%	0 0.0%	0 0.0%	75.0% 25.0%
12	0 0.0%	1 0.4%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 2.7%	2 0.9%	0 0.0%	60.0% 40.0%
13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 3.1%	0 0.0%	100% 0.0%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.5%	90.9% 9.1%
	90.0% 10.0%	78.9% 21.1%	93.3% 6.7%	84.2% 15.8%	60.0% 40.0%	87.5% 12.5%	44.4% 55.6%	90.0% 10.0%	100% 0.0%	60.0% 40.0%	90.0% 10.0%	60.0% 40.0%	77.8% 22.2%	100% 0.0%	83.9% 16.1%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
	Target Class														

Ilustración 33: Matriz de confusión del sistema hLBP con ecualización del histograma y sin *background* en clasificación de familias

En cuanto a la clasificación por especies, la matriz de confusión en la que aparece el sistema *HistEq*, muestra que los fallos más frecuentes ocurren con clases adyacentes. Sin embargo, con el algoritmo *NoBackground*, hay una mayor dispersión. **Esto hace a las dos cadenas se complementen.**

5.4.5 Experimento 7: Introducción del DWT

En este experimento, se introdujo otro de los sistemas más relevantes. Con la intención de llevar a cabo un análisis espectral de la imagen, se ha aplicado la **DWT en varios niveles y cadenas**. Hay que recordar que la aplicación de una DWT genera 4 imágenes: *ll*, *lh*, *hl* y *hh*. Se ha hecho por tanto, un análisis por separado, para así saber cuál es la imagen que más información aporta. Se pueden distinguir tres partes fundamentales en este experimento: la **experimentación con el nivel DWT**, la introducción del **pre-procesado de la imagen** y la sustitución del sistema hLBP, por el *resize* junto con el *sparse*.

5.4.5.1 EXPERIMENTO 7.1: EL NIVEL DE DWT.

En esta primera parte, se pretendía comprender el alcance de aplicar DWT de forma recursiva. Debido a que la descomposición de la imagen puede ayudar en la identificación, pero, en contraposición, esto implica un mayor tiempo de procesado. Se pretendía encontrar el nivel que ofrece la información más relevante. Para ello, se necesitan las tasas de acierto parciales:

Cadena	Precisión Especies	Precisión Familia
DWT1LL+SIS HLBP	84.9765 %	89.4273 %
DWT1LH+SIS HLBP	72.0379 %	74.2222 %
DWT1HL+SIS HLBP	74.537 %	75.3488 %
DWT1HH+SIS HLBP	62.6214 %	71.3636 %
DWT2LL+ SIS HLBP	85.9729 %	92.3423 %
DWT2LH+ SIS HLBP	73.3645 %	78.5388 %

DWT2HL+ SIS HLBP	77.2093 %	81.2207 %
DWT2HH+ SIS HLBP	59.4340 %	64.7059 %
DWT3LL+ SIS HLBP	82.7434 %	87.3303 %
DWT3LH+ SIS HLBP	67.4641 %	75.2294 %
DWT3HL+ SIS HLBP	73.6364 %	77.6256 %
DWT3HH+ SIS HLBP	56.2500 %	61.991 %
DWT4LL+ SIS HLBP	76.1682 %	82.3256 %
DWT4LH+ SIS HLBP	54.3590 %	64.5161 %
DWT4HL+ SIS HLBP	69.1943 %	68.0556 %
DWT4HH+ SIS HLBP	50.7177 %	53.8462 %

Tabla 16: Resultados de la DWT de niveles del 1 al 4

Nuevamente, se observa que la parte baja-baja (*ll*) de la imagen contiene la mayor parte de la información relevante, ya que en comparación con el resto de imágenes al mismo nivel, es la que mayor tasa de acierto tiene. También se puede ver que el punto óptimo se alcanza en el nivel 2 con casi un **86 %** de precisión para la identificación de especies y un **92 %** para la de familias.

5.4.5.2 EXPERIMENTO 7.2: EL PREPROCESADO SOBRE DWT

Esta segunda parte, sigue la misma metodología que el experimento 6: la **aplicación del pre-procesado** sobre el sistema a analizar. Así se obtienen estas tasas:

Cadena	Precisión Especies	Precisión Familia
NB+HEQ+DWT1HH+SIS HLBP	64.8148 %	74.1784 %
NB+HEQ+DWT1HL+SIS HLBP	75.0000 %	83.1050 %
NB+HEQ+DWT1LH+SIS HLBP	76.8868 %	79.8165 %
NB+HEQ+DWT1LL+SIS HLBP	81.1927 %	87.1111 %
NB+DWT1HH+SIS HLBP	62.5592 %	70.6422 %
NB+DWT1HL+ SIS HLBP	38.8073 %	80.5430 %
NB+DWT1LH+ SIS HLBP	75.1174 %	78.9238 %
NB+DWT1LL+ SIS HLBP	82.1101 %	85.0877 %
HEQ +DWT1HH+ SIS HLBP	66.9856 %	69.0909 %
HEQ+DWT1HL+ SIS HLBP	73.2719 %	80.3653 %
HEQ+DWT1LH+ SIS HLBP	74.7664 %	77.8302 %
HEQ+DWT1LL+ SIS HLBP	83.1818 %	89.2857 %
DWT1HH+HEQ+ SIS HLBP	64.0777 %	73.3032 %
DWT1HL+HEQ+ SIS HLBP	78.7736 %	75.4630 %
DWT1LH+HEQ+ SIS HLBP	75.8294 %	78.6667 %
DWT1LL+HEQ+ SIS HLBP	82.6484 %	87.4439 %
DWT1HH+NB+HEQ+ SIS HLBP	67.5799 %	76.3889 %
DWT1HL+NB+HEQ+ SIS HLBP	77.7778 %	82.8054 %
DWT1LH+NB+HEQ+ SIS HLBP	77.8281 %	83.7209 %
DWT1LL+NB+HEQ+ SIS HLBP	86.4253 %	88.1579 %
DWT1HH+NB+ SIS HLBP	67.9070 %	76.1261 %

DWT1HL+NB+ SIS HLBP	78.5714 %	85.2018 %
DWT1LH+NB+ SIS HLBP	79.2627 %	84.8214 %
DWT1LL+NB+ SIS HLBP	84.8624 %	86.9369 %

Tabla 17: Resultados de la aplicación de *NoBackground* y *HistEq* sobre DWT

No hace falta volver a decir lo que supone la parte baja-baja de la imagen. En cuanto a las cadenas, las mejores resultan ser las remarcadas: *HistEq* antes de la DWT y *NoBackground* con *HistEq* después de la DWT.

5.4.5.3 EXPERIMENTO 7.3: RESIZE Y SPARSE

A diferencia del sistema hLBP, que compila la información en un vector de apenas 256 elementos, DWT no es tan eficiente ni determinista. Esto se debe a que **este sistema genera imágenes con un tamaño proporcional al tamaño de la imagen** entrante, lo que implicaría una cierta variabilidad en la estructura de datos. Para solucionar esto, se propuso la cadena *Resize+DWT+sparse*.

Con *resize* se modificaba la imagen entrante para que tuviera una resolución máxima y determinista, es decir, el valor máximo para ambos ejes que tuvieran las imágenes más grandes. Dicho de otra manera, cada imagen se ajustaba al tamaño de la más grande. Así, **no se perdía información**, por lo que el sesgo permanecía intacto. Con esto se solucionaba la variabilidad de tamaños. Por otro lado, DWT generaba imágenes, que bien podrían ser interpretadas como matrices. Por eso se aplicó además *sparse*, para convertirlas en vectores. Así el clasificador podría recibir estos datos. Para comprender esto, se muestra un esquema que resume el proceso:

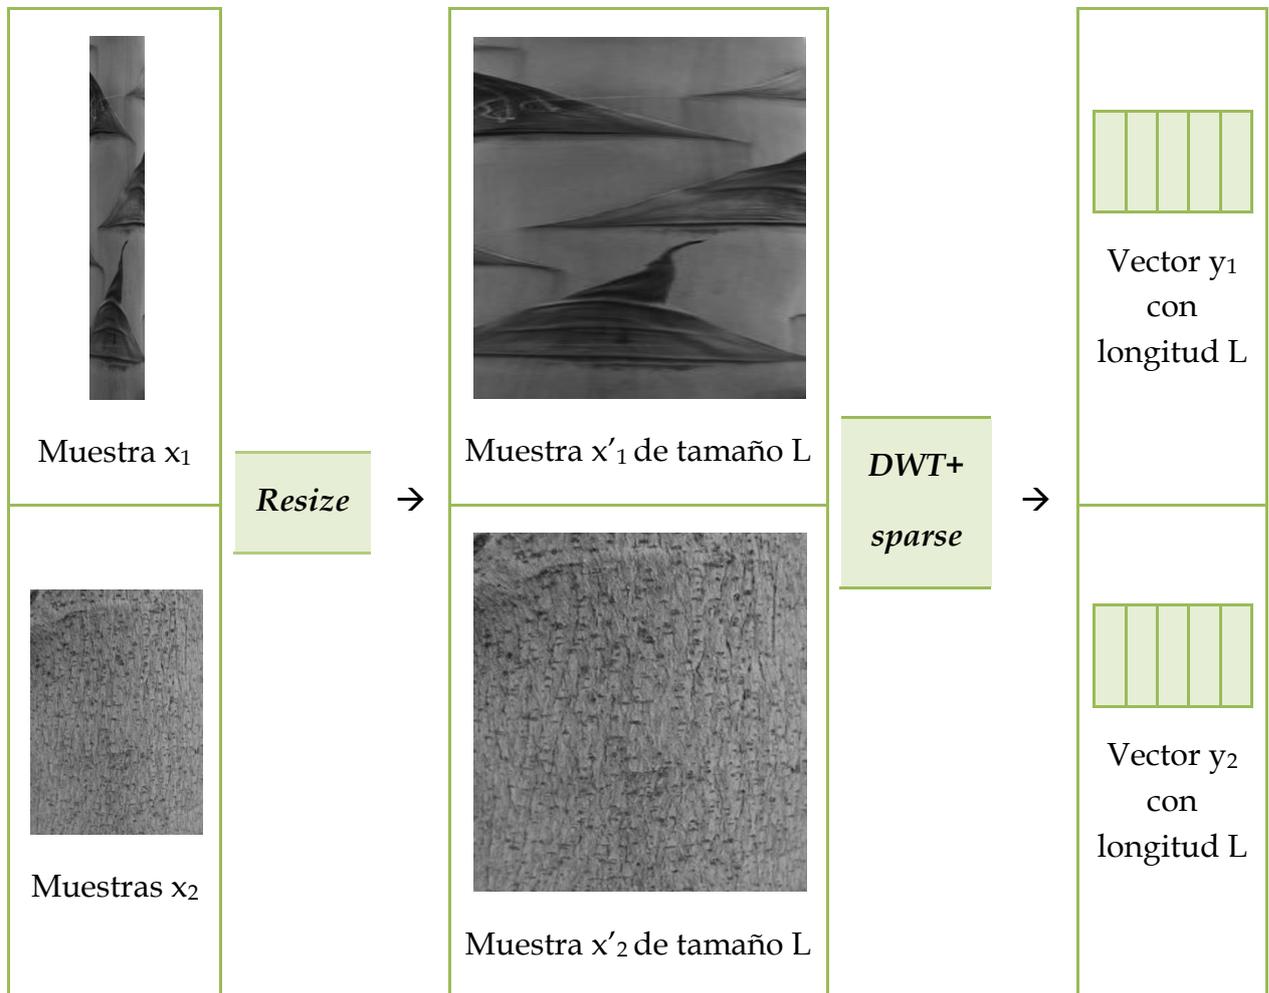


Ilustración 34: Esquema de la aplicación de resize+sparse

Desgraciadamente, el experimento no se pudo llevar a cabo porque el tamaño que suponía esta cadena era **insoportable para el disco duro**. De aquí, se puede extraer que la parametrización debe suponer una compresión de la información cuando se trabaja con imágenes en alta resolución.

Resumiendo, se ha alcanzado un **86 %** para especies y a un asombroso **92 %** para familias, por lo que los resultados del experimento 7 se consideran como **MUY BUENOS**.

5.4.6 Experimento 8: Compilación DWT

En vista a los buenos resultados que se obtuvieron en el experimento 7, se trata de ir un paso más allá. Dado que la DWT contiene gran parte de la **información** relevante, pero a su vez, está dividida, en este experimento se propone volverla a **unir**. Si los vectores resultantes de la parametrización se **envían todos juntos al clasificador**, parece obvio que se obtendrán tasas de acierto más altas, ya que hay más información para identificar. En la tabla 18 se indican las tasas de acierto de la compilación que suponen las 4 imágenes resultantes de DWT a un nivel (DWT1) y las 7 de DWT a dos niveles.

Sistema de clasificación	SIS HLBP + DWT1	SIS HLBP +DWT2
Especie	85.8447 %	87.5000 %
Familia	91.1894 %	92.5110 %

Tabla 18: DWT1 vs DWT1+2

Estos resultados merecen venir acompañados de sus correspondientes matrices de confusión:

Confusion Matrix

Output Class	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23		
1	8 3.7%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100%	
2	0	8 3.7%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	88.9%	
3	0	1	9 4.1%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	90.0%	
4	0	0	0	6 2.7%	1 0.5%	0	0	0	0	0	0	0	0	2 0.9%	0	2 0.9%	0	0	0	0	0	0	0	0	34.5%
5	0	0	0	2 0.9%	7 3.2%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10.0%	
6	0	0	0	0	0	7 3.2%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1 0.5%	1 0.5%	7.8%	
7	0	1	0	0	0	0	9 4.1%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	90.0%	
8	0	0	0	0	0	0	0	8 3.7%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100%	
9	0	0	0	0	0	0	0	0	9 4.1%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100%	
10	0	0	0	0	0	0	0	0	0	8 3.7%	0	0	0	0	0	0	0	0	0	0	0	0	0	100%	
11	0	0	0	0	0	0	0	0	0	0	9 4.1%	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	90.0%	
12	0	0	0	0	0	0	0	0	0	0	0	1 0.5%	8 3.7%	0	0	0	0	0	0	0	0	0	0	88.9%	
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7 3.2%	0	0	0	0	0	0	0	100%	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10 4.6%	1 0.5%	1 0.5%	0	0	0	0	83.3%	
15	0	0	0	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	0	0	5 2.3%	1 0.5%	0	0	0	0	71.4%	
16	0	0	0	0	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	0	2 0.9%	8 3.7%	0	0	0	0	87.7%	
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9 4.1%	0	0	0	0	100%	
18	0	0	0	0	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	7 3.2%	0	0	87.5%	
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9 4.1%	0	0	100%	
20	0	0	0	0	0	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10 4.6%	0	90.9%	
21	1 0.5%	0	0	1 0.5%	0	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8 3.7%	1 0.5%	66.7%	
22	1 0.5%	0	0	0	0	0	0	0	0	1 0.5%	0	0	0	0	0	0	0	0	0	0	0	1 0.5%	9 4.1%	75.0%	
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10 4.6%	100%	
	80.0%	80.0%	100%	60.0%	10.0%	7.8%	100%	100%	100%	80.0%	80.0%	88.9%	10.0%	100%	80.0%	100%	100%	80.0%	100%	80.0%	100%	80.0%	100%	5.8%	
	20.0%	20.0%	0.0%	40.0%	90.0%	2.2%	0.0%	0.0%	0.0%	20.0%	20.0%	1.1%	90.0%	0.0%	20.0%	20.0%	0.0%	20.0%	0.0%	20.0%	0.0%	20.0%	0.0%	4.2%	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23		

Ilustración 35: Matriz de confusión de DWT1 completo para la clasificación por especies

Confusion Matrix

Output Class	1	28 12.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	1 0.4%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	90.3% 9.7%
	2	0 0.0%	14 6.2%	3 1.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	77.8% 22.2%
	3	0 0.0%	4 1.8%	56 24.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	93.3% 6.7%
	4	0 0.0%	0 0.0%	0 0.0%	19 8.4%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	95.0% 5.0%
	5	0 0.0%	0 0.0%	0 0.0%	1 0.4%	9 4.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	81.8% 18.2%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	1 0.4%	0 0.0%	0 0.0%	88.9% 11.1%
	11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	8 3.5%	0 0.0%	0 0.0%	88.9% 11.1%
	12	1 0.4%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	0 0.0%	80.0% 20.0%
	13	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	10 4.4%	83.3% 16.7%
	14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.4%	100% 0.0%
			93.3% 6.7%	73.7% 26.3%	94.9% 5.1%	95.0% 5.0%	90.0% 10.0%	90.0% 10.0%	100% 0.0%	100% 0.0%	80.0% 20.0%	80.0% 20.0%	80.0% 20.0%	88.9% 11.1%	100% 0.0%
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
		Target Class													

Ilustración 36: Matriz de confusión de DWT1 completo para la clasificación por familias

Confusion Matrix

Output Class	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	7	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	2	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	6	1	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	1	0	0
5	0	0	0	1	7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0
7	0	1	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
8	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	10	1	0	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	9	0	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	1	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	9	0	1	0	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6	1	0	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	8	0	0	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0
18	0	0	0	2	0	0	0	0	0	0	0	0	1	0	1	0	0	10	0	0	0	0	0
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	0	0	0	0	0
20	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	9	0	0	0	0
21	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0
22	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	10	0	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0
	90.0%	0.0%	100%	60.0%	7.8%	80.0%	88.9%	100%	0.0%	87.5%	100%	90.0%	70.0%	90.0%	66.7%	80.0%	100%	90.0%	90.0%	100%	100%	100%	7.5%
	4.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	0.0%	3.1%	0.0%	0.0%	0.0%	0.0%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	2.5%
	0.0%	0.9%	4.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	81.8%
	0.0%	0.0%	0.0%	2.7%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.9%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.4%	0.0%	60.0%
	0.0%	0.0%	0.0%	0.4%	3.1%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	87.5%
	0.0%	0.0%	0.0%	0.0%	0.0%	3.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.4%	0.0%	0.4%	0.0%	0.0%	80.0%
	0.0%	0.4%	0.0%	0.0%	0.0%	0.0%	3.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.4%	0.0%	0.0%	0.0%	80.0%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.5%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.5%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	3.1%	0.0%	4.5%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	90.9%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.5%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	9.1%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	100%
	0.0%	0.0%	0.0%	0.0%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	3.1%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	87.5%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.0%	0.0%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	2.5%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	90.0%
	0.0%	0.0%	0.0%	0.4%	0.0%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	83.3%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	6.7%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	100%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	4.5%
	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	2.5%

Ilustración 37: Matriz de confusión de DWT2 completo para la clasificación por especies

Confusion Matrix

1	29 12.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	1 0.4%	0 0.0%	1 0.4%	1 0.4%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	82.9% 17.1%
2	0 0.0%	17 7.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	1 0.4%	57 25.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	96.6% 3.4%
4	0 0.0%	0 0.0%	0 0.0%	20 8.8%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	88.9% 11.1%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	88.9% 11.1%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	9 4.0%	0 0.0%	0 0.0%	90.0% 10.0%
12	0 0.0%	1 0.4%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.5%	0 0.0%	0 0.0%	80.0% 20.0%
13	1 0.4%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.4%	0 0.0%	0 0.0%	0 0.0%	9 4.0%	0 0.0%	75.0% 25.0%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.4%	100% 0.0%
	96.7% 3.3%	85.0% 15.0%	100% 0.0%	100% 0.0%	80.0% 20.0%	80.0% 20.0%	90.0% 10.0%	100% 0.0%	80.0% 20.0%	80.0% 20.0%	90.0% 10.0%	80.0% 20.0%	90.0% 10.0%	100% 0.0%	92.5% 7.5%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
	Target Class														

Ilustración 38: Matriz de confusión de DWT2 completo para la clasificación por familias

Los resultados de estos experimentos son **EXCELENTES**, sobretodo, con la compilación DWT2, ya que alcanza una tasa de acierto del 87.5 % para especies y un 92.5 % para familias.

5.4.7 Experimento 9: GLCM

Por cambiar un poco, se introdujo un nuevo sistema para **comprimir** la información en apenas una matriz de 8x8, lo que hace un total de **64 escasos valores**. Aunque su eficiencia fuera buena, no se esperaba que GLCM superara a su compañero más similar el hLBP. No obstante, con GLCM se podían ejecutar sus 4 versiones que, compiladas ocuparían lo mismo que el otro sistema. En la tabla 19, se pueden observar las tasas de acierto de los cuatro ángulos en los que se trazó la GLCM. En la última fila de la tabla, se ve el resultado de la compilación de los 4 parámetros anteriores.

Cadena	Precisión Especies	Precisión Familia
GLCM0°+sparse	60.0000 %	67.1296 %
GLCM45°+sparse	62.6794 %	71.6346 %
GLCM90°+sparse	66.0194 %	68.2028 %
GLCM135°+sparse	67.7570 %	73.2394 %
GLCMtotal+sparse	68.9320 %	72.6829 %

Tabla 19: Resultados de la GLCM en las 4 direcciones

Como la GLCM de por sí sola ni siquiera alcanza a hLBP, el resultado del experimento tiene que ser calificado como **MALO**.

5.4.8 Experimento 10: DWT SOBRE GLCM

Este experimento trata de combinar la alta precisión que ha supuesto la aplicación de DWT con la compresión de la que presume GLCM. A continuación se muestran las tasas de acierto de la GLCM aplicada sobre la DWT. Debido a las conclusiones extraídas de anteriores experimentos, solo se muestran las tasas de acierto de las **compilaciones finales**, obviando los resultados parciales correspondientes a las **4 partes de GLCM por las 7 partes de DWT2**.

Cadena	Precisión Especies	Precisión Familia
DWT2+GLCM+sparse	56.2814 %	69.4836 %

Tabla 20: Resultados de la DWT con GLCM

La precisión del sistema no mejora en comparación con los anteriores experimentos. Aún así, a continuación se muestran las matrices de confusión:

Confusion Matrix

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23					
1	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	3	0	4.5%		
2	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1.5%	5.5%	
3	0	0	6	0	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4.3%	
4	0	0	0	6	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4.5%	
5	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5.5%	
6	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
7	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
8	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
9	1	0	1	1	1	0	0	1	3	0	0	1	0	1	0	0	0	0	0	0	0	0	1	0	1	0	2.5%	
10	0	1	0	0	0	0	0	0	1	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5.0%	
11	0	0	0	0	0	0	0	0	0	0	2	0	0	8	1	0	0	0	0	0	0	0	0	0	0	0	5.0%	
12	1	0	0	0	0	0	0	0	0	0	0	2	7	0	0	0	0	0	0	0	0	0	0	0	0	0	5.6%	
13	0	0	0	0	0	0	0	0	0	0	0	1	0	0	4	0	2	0	2	2	0	0	0	0	0	0	4.4%	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6.7%	
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3.3%	
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.0%	
22	1	1	0	0	1	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	1	0	1	1	4	3.3%
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6.7%	
	60	0	15	0	5.7%	6.7%	40	0	7.5	0	6.7%	0	0	7.5	0	5.6%	0	0	0	0	0	0	0	0	0	0	6.3%	
	40	0	2.5	0	4.3%	3.3%	0	0	2.5	0	3.3%	100	0	2.5	4.4	2	0	0	0	0	0	0	0	0	0	0	3.7%	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23					

Ilustración 39: Matriz de confusión de DWT y GLCM por especies

Confusion Matrix

1	24 11.3%	1 0.5%	1 0.5%	3 1.4%	1 0.5%	1 0.5%	6 2.8%	2 0.9%	2 0.9%	0 0.0%	1 0.5%	1 0.5%	6 2.8%	1 0.5%	48.0% 52.0%
2	0 0.0%	6 2.8%	2 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	60.0% 40.0%
3	1 0.5%	8 3.8%	57 26.8%	1 0.5%	0 0.0%	0 0.0%	1 0.5%	1 0.5%	3 1.4%	0 0.0%	0 0.0%	4 1.9%	0 0.0%	0 0.0%	75.0% 25.0%
4	0 0.0%	0 0.0%	0 0.0%	13 6.1%	0 0.0%	1 0.5%	1 0.5%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	81.3% 18.8%
5	0 0.0%	0 0.0%	0 0.0%	1 0.5%	6 2.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	85.7% 14.3%
6	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	7 3.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	87.5% 12.5%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
8	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	50.0% 50.0%
9	2 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	5 2.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	62.5% 37.5%
10	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	6 2.8%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	66.7% 33.3%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	7 3.3%	0 0.0%	0 0.0%	0 0.0%	77.8% 22.2%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 1.9%	0 0.0%	0 0.0%	100% 0.0%
13	0 0.0%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 1.4%	0 0.0%	75.0% 25.0%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.8%	100% 0.0%
	85.7% 14.3%	37.5% 62.5%	95.0% 5.0%	65.0% 35.0%	85.7% 14.3%	77.8% 22.2%	0.0% 100%	25.0% 75.0%	50.0% 50.0%	66.7% 33.3%	77.8% 22.2%	44.4% 55.6%	33.3% 66.7%	80.0% 20.0%	69.5% 30.5%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
															Target Class

Ilustración 40: Matriz de confusión de DWT y GLCM por familias

Con estos resultados tan mediocres, se puede extraer una conclusión sobre el sistema DWT: Funciona bien con LBP, pero no está bien combinarlo con otros sistemas, ya que disminuye su tasa de acierto. A simple vista, las matrices de confusión no muestran una gran diferencia con respecto a las anteriores. Por lo tanto, se califica el nivel de este experimento como **INSUFICIENTE**.

5.4.9 Experimento 11: DWT sobre MLBP y GLCM

Por último, se simuló el comportamiento de la **versión matricial** del sistema LBP. Teniendo en cuenta las dos restricciones que se establecieron en la elección de cadenas; y tal y como se comprobó en el experimento 7.3, la aplicación de un sistema matricial variable tiene que ir acompañado de algoritmos y sistemas. A continuación se muestran las tasas de acierto de la matriz LBP acompañada por DWT y GLCM. Debido a las conclusiones extraídas de anteriores experimentos, solo se muestran las tasas de acierto de las compilaciones finales, obviando los resultados parciales correspondientes a las 4 partes de GLCM por las 7 partes de DWT2.

Cadena	Precisión Especies	Precisión Familia
DWT2+MLBP+GLCM+sparse	84.6847 %	91.8182 %

Tabla 21: Resultados de la aplicación de los tres sistemas más relevantes

Junto con las tasas de acierto, se exponen sus matrices de confusión:

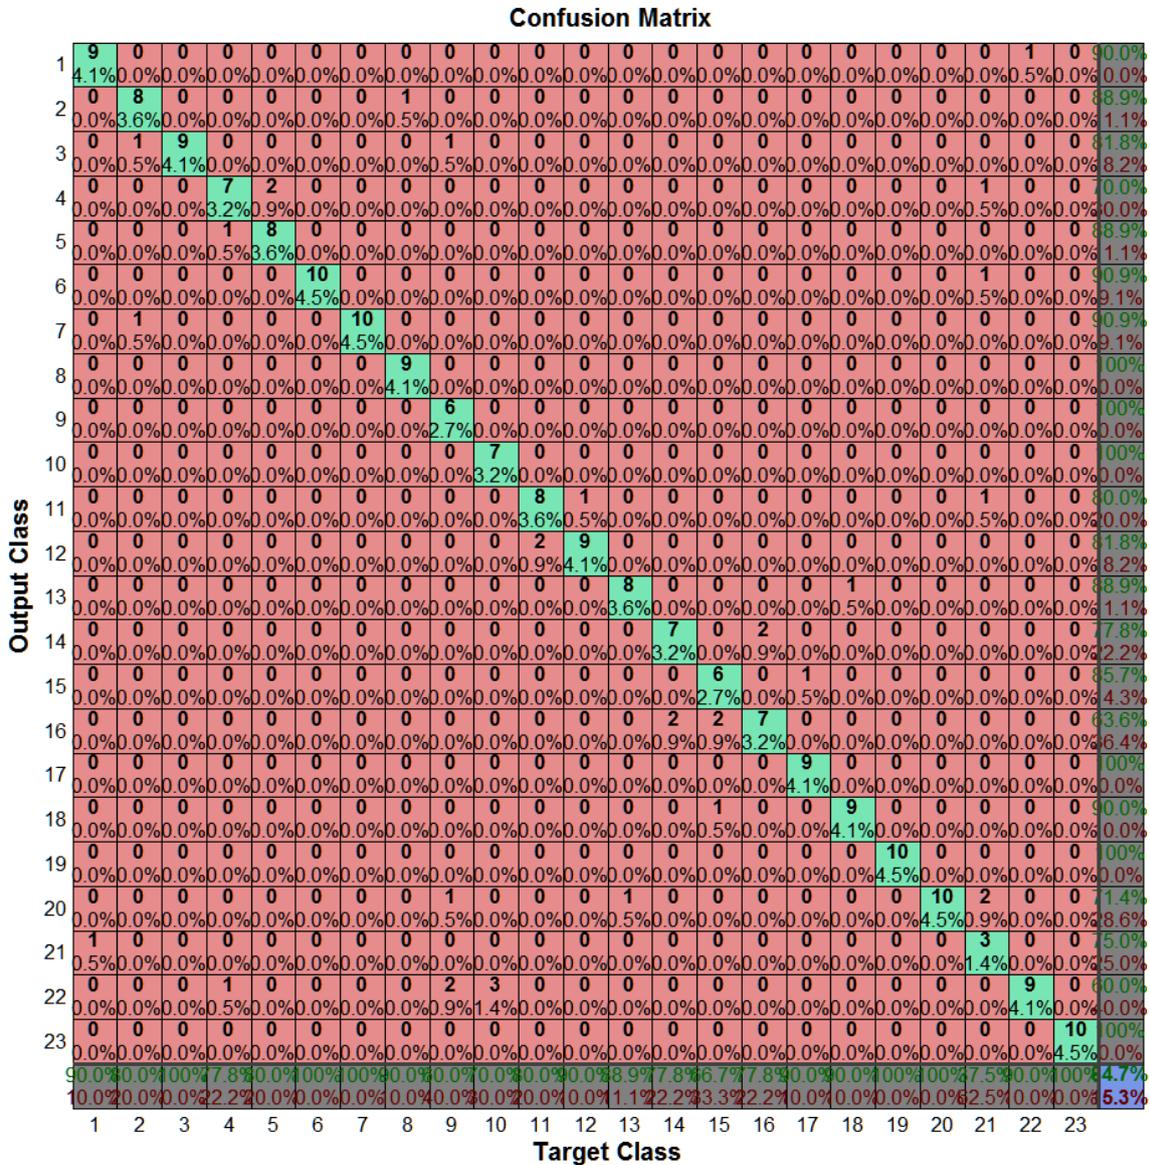


Ilustración 41: Matriz de confusión de los tres sistemas más relevantes en una clasificación por especies

Confusion Matrix

1	27 12.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	1 0.5%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.0% 10.0%
2	0 0.0%	17 7.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	3 1.4%	59 26.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%
4	0 0.0%	0 0.0%	0 0.0%	20 9.1%	1 0.5%	0 0.0%	0 0.0%	0 0.0%	95.2% 4.8%						
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.5%	0 0.0%	0 0.0%	88.9% 11.1%
6	1 0.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.0% 10.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	9 4.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 2.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	7 3.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 3.6%	1 0.5%	1 0.5%	0 0.0%	0 0.0%	80.0% 20.0%
11	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	9 4.1%	0 0.0%	0 0.0%	0 0.0%	81.8% 18.2%
12	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 2.7%	0 0.0%	0 0.0%	100% 0.0%
13	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.9%	3 1.4%	0 0.0%	0 0.0%	0 0.0%	7 3.2%	0 0.0%	58.3% 41.7%
14	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 4.5%	100% 0.0%
	96.4% 3.6%	85.0% 15.0%	100% 0.0%	100% 0.0%	88.9% 11.1%	90.0% 10.0%	90.0% 10.0%	66.7% 33.3%	70.0% 30.0%	80.0% 20.0%	90.0% 10.0%	75.0% 25.0%	100% 0.0%	100% 0.0%	91.8% 8.2%
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
	Target Class														

Ilustración 42: Matriz de confusión de los tres sistemas más relevantes en una clasificación por familias

Contrariamente a lo que ocurrió con los algoritmos LBP, el sistema ha resultado ser casi tan rápido como el hLBP, ya que su ejecución ha durado apenas unos segundos por imagen. No obstante, la DWT de por sí sola supera ambas tasas de acierto y las matrices de confusión no difieren mucho, por lo que estos resultados son **INSUFICIENTES** y, a simple vista, recurrentes.

5.5 TABLA RESUMEN

Para finalizar este capítulo, se resumen los resultados más relevantes:

Cadena	Precisión Especies	Precisión Familia
DWT2+MLBP+GLCM+sparse	84.6847 %	91.8182 %
HEQ+ SIS HLBP	82.7103 %	83.7209 %
NB+HEQ+ SIS HLBP	82.8054 %	85.2679 %
HEQ+DWT1LL+ SIS HLBP	83.1818 %	89.2857 %
DWT1LL+NB+HEQ+ SIS HLBP	86.4253 %	88.1579 %
DWT1LL+SIS HLBP	84.9765 %	89.4273 %
DWT2LL+ SIS HLBP	85.9729 %	92.3423 %
DWT3LL+ SIS HLBP	82.7434 %	87.3303 %
DWT2 + SIS HLBP	87.5000 %	92.5110 %

Tabla 22: Resumen de los resultados



CAPÍTULO 6: CONCLUSIONES Y LÍNEAS FUTURAS

Cada solución da pie a una nueva pregunta.

David Hume



6.1 INTRODUCCIÓN

En este último capítulo, se expone el grado en el que se **han cumplido los objetivos principales**. Además, se proponen diferentes formas para **mejorar las prestaciones** del reconocedor automático de plantas. Por último, se trata de mostrar **la innovación** que supone este proyecto junto con una perspectiva positiva en el futuro.

6.2 CUMPLIMIENTO DE OBJETIVOS

Considerando los objetivos que se establecieron en el capítulo introductorio, se puede decir que se han cumplido de manera satisfactoria. Con una precisión del **87,50 %** en los mejores experimentos, se ha logrado desarrollar un identificador automático de cortezas de plantas que **distingue entre 23 especies distintas**. Además, la parametrización de cada imagen dura apenas unos segundos. Esto supone un **tiempo aceptable** a la hora de introducir una nueva muestra para su identificación, reafirmando así la funcionalidad del sistema completo.

Si se presta atención al estado del arte sobre los algoritmos y sistemas aplicados en la extracción de parámetros y se compara con los resultados obtenidos (véase la tabla 23), se pueden extraer las siguientes conclusiones finales:

- El **número de clases incluidas en este trabajo es alto**, lo que hace más difícil alcanzar una alta precisión.
- Los mejores sistemas de este trabajo son el **DWT** y el **hLBP**, ya que **combinados**, y con sólo configurar la DWT a nivel 2, se alcanzan **altas tasas de acierto**.

- Comparado con el estado del arte, el **único trabajo que supera** estos resultados es el titulado como *Classification Based on Textural Features Using Artificial Neural Networks* [13], que hace uso de **metodologías caóticas** para encontrar patrones en las texturas. Le acompaña el sistema COMM o GLCM, el cual **no ha dado buenos resultados** en este proyecto.

Referencia	Algoritmos	Clasificadores	N° de clases	Tasa de éxito
[11]	Banco de filtros <i>Gabor</i>	NSM	8	51,5 %
		MNSM		96 %
[12]	ACM	SVM	9	65 %
	COMM			75 %
	HM			62 %
	DWT	RBPNN		82,26 %
	ACM			72 %
	COMM			77 %
	HM			65 %
DWT	84,68 %			
[13]	Análisis fractal+COMM	NN	24	91,7 %
[14]	LCLE+COMM	1-NN	18	87,8 %

		5-NN		84,4 %
		8-NN		21,1 %
[15]	COMM	1-NN	9	89 %
[16]	COMM+DWT	SVM	11	69,7 %
Este trabajo	DWT2+MLBP+GLCM+sparse		23	84.6847 %
			14	91.8182 %
Este trabajo	DWT1LL+NB+HEQ+ SIS HLBP	LSSVM	23	86.4253 %
			14	88.1579 %
Este trabajo	DWT2+SIS HLBP		23	87.5000 %
			14	92.5110 %

Tabla 23: Comparativa de los resultados de este trabajo con otros

6.3 MEJORA DE LAS PRESTACIONES

La manera directa de mejorar este sistema es aumentar la tasa de acierto. Idealmente, una tasa de acierto del 100 % indicaría que el sistema no se equivoca en absoluto a la hora de identificar las muestras. Para lograr mejoras se proponen varias líneas:

- **Seguir con el estudio de cadenas de algoritmos y sistemas.** Con una mayor cantidad de resultados, se puede observar si de verdad existe un procedimiento que optimice el sistema actual.

- **Hacer un estudio correlativo de las matrices de confusión.** Las matrices de confusión no sólo informan sobre la precisión global del sistema, sino que también puntualiza cuales son las clases, ya sean familias o especies, en las que la cadena no atina. Una **comparación entre matrices** de confusión mediante una operación correlativa, informaría sobre cuáles son los algoritmos y sistemas que generan resultados parecidos o, por el contrario, diferentes. Si dos cadenas son muy parecidas, se puede omitir la ejecución de una de ellas en el sistema completo. Por otro lado, si dos cadenas se diferencian, una podría complementar a la otra.
- **Gestionar el almacenamiento.** Cuando el programa escaló, apareció la problemática de que algunas cadenas ocupaban demasiado espacio en disco, por lo que se entorpecía la ejecución de cadenas de parametrización que no comprimían la información. Con un aumento de los recursos de almacenamiento o una correcta gestión de los mismos, se podrían aplicar aquellas cadenas que antes no se podían.
- **Extracción de metadatos.** La captura de una imagen en formato digital genera un archivo que guarda la propia imagen. No obstante, según con qué cámara o con qué software se capture una imagen digital, se almacenan otros datos, como la fecha, la resolución o la posición global con **GPS**, esto podría ser una información útil para realizar la identificación.

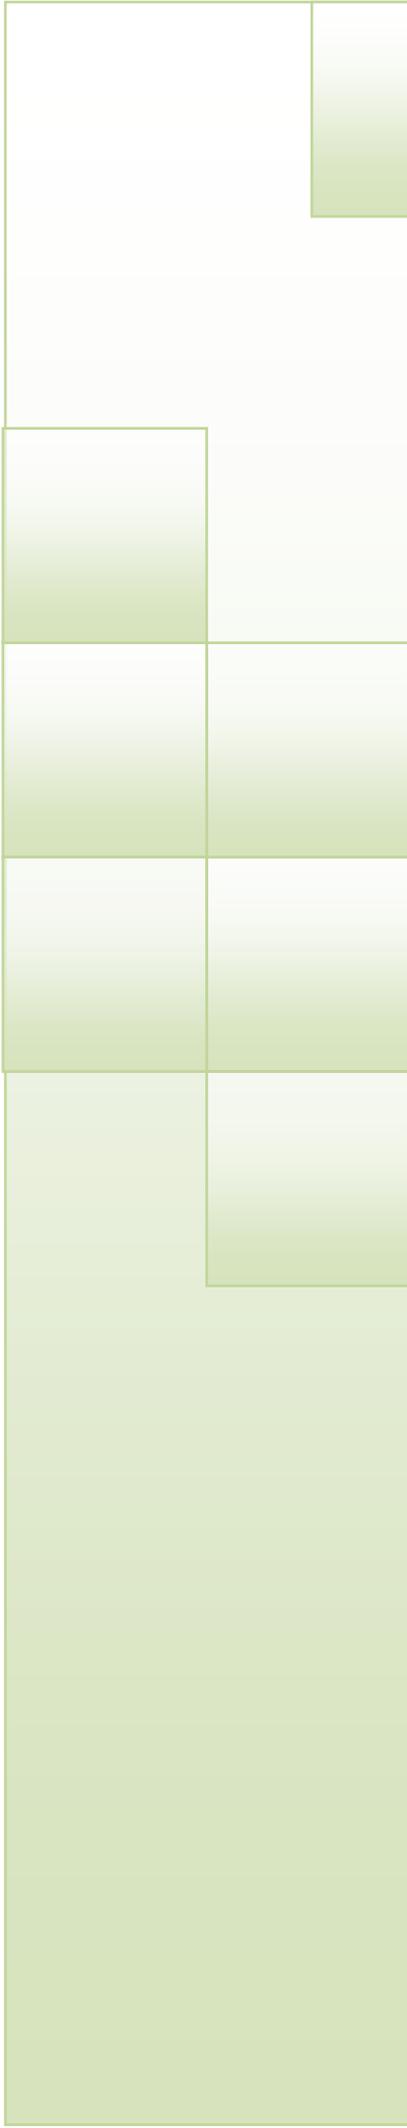
6.4 INNOVACIÓN

Como se vio en el capítulo introductorio, la idea de este proyecto ha surgido a partir de la división de un proyecto mayor sobre el desarrollo de una aplicación móvil para la detección de plantas invasoras cercanas a rutas de

senderismo. Con la idea de controlar el impacto ambiental, se pretende componer un sistema que controle la propagación de las especies sobre ecosistemas ajenos.

Con la integración que han tenido los *smartphones* en la vida cotidiana, un sistema como el que se ha desarrollado e implementado a lo largo de este proyecto, sobre una **aplicación móvil**, podría ser **utilizada por la mayoría de la población**. Es más, si la aplicación se focaliza en cuanto a los hábitos de vida saludables y la naturaleza, se podría tener una mayor integración en la población local y extranjera. El reciente éxito de la aplicación *Pokemon Go* podría ser un modelo a imitar en lo que se refiere a **potenciar su utilización mediante la realidad aumentada**, ya que ha conseguido afiliar a clientes a locales en todo el mundo [27]. En lo que respecta a la base de datos, un éxito similar sobre este proyecto podría completarla en cuestión de días.

Además, con el reconocimiento y la activación del GPS se podría obtener la **posición exacta del espécimen fotografiado**. Junto con la ventaja tecnológica que supone la conectividad a internet, esto otorgaría a una hipotética estación de control plagas, la detección de determinados entornos de propagación. Incluyendo **un experto en biología**, se podría hacer un **seguimiento de la funcionalidad del reconocedor automático de plantas**, abriendo nuevas opciones para **perfeccionar** el sistema.



REFERENCIAS BIBLIOGRÁFICAS



- [1] Organización de las Naciones Unidas. (2015, Mayo) Día Internacional de la Diversidad Biológica. [Online]. <http://www.un.org/es/events/biodiversityday/biodiversity.shtml>
- [2] Gobierno de México. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. [Online]. <http://www.biodiversidad.gob.mx/biodiversidad/porque.html>
- [3] Gobierno de Canarias. Sistema de Información Medioambiental de Canarias. [Online]. <http://www.gobiernodecanarias.org/medioambiente/piac/temas/biodiversidad/>
- [4] Federico Aguilera, *Canarias, economía, ecología y medio ambiente*. La Laguna: Lemus, 1994.
- [5] Gobierno de Canarias. [Online]. <http://www.gobiernodecanarias.org/opencmsweb/export/sites/medioambiente/piac/galerias>
- [6] Gobierno de Canarias. (2014) Listado de especies introducidas en Canarias. [Online]. <http://www.interreg-bionatura.com/especies/index.php?opt=verDatos#>
- [7] (a) mobiThinking. (2015, Mayo) mobiForge. [Online]. <https://mobiforge.com/research-analysis/global-mobile-statistics-2014-part-a-mobile-subscribers-handset-market-share-mobile-operators>
- [8] <http://www.scidev.net/global/environment/biodiversity/>. [Online]. <http://www.scidev.net/global/environment/biodiversity/>
- [9] Ernest García. Junta de Andalucía. [Online]. http://www.juntadeandalucia.es/medioambiente/web/Bloques_Tematicos/Publicaciones_Divulgacion_Y_Noticias/Documentos_Tecnicos/personas_sociedad_y_ma/cap3.pdf
- [10] Secretariado de la Red de Autoridades Ambientales. LanzaRed. [Online]. <http://www.datosdelanzarote.com/uploads/doc/2007090213283212turismo.pdf>
- [11] L. Houqiang y W. Chao Z. Chi, "Plant species recognition based on bark patterns using novel Gabor filter banks," in *International Conference on Neural Networks and Signal Processing*, vol. 2, 2003, pp. 1035-1038.
- [12] Z.-K. Huang, "Bark Classification Using RBPNN Based on Both Color and Texture Feature," in

International Journal of Computer Science and Network Security, vol. 6, 2006, pp. 100-103.

- [13] C.-H. Zheng, J.-X. Du y Y. Wan. Z.-K. Huang, "Classification Based on Textural Features Using Artificial Neural Networks," in *Third International Symposium on Neural Networks*, vol. 2, 2006, pp. 355-360.
- [14] Z. Chi, J. Liu y H. Fu. J. Song, "Bark classification by combining grayscale and binary texture features," in *International Symposium on Intelligent Multimedia, Video and Speech Processing*, 2004, pp. 450-453.
- [15] J.-X. Du, D.-S. Huang, Z. Chi, Y.-M. Cheung, X.-F. Wang y G.-J. Zhang Y.-Y. Wan, "Bark texture feature extraction based on statistical texture analysis," in *International Symposium on Intelligent Multimedia, Video and Speech Processing*, 2004, pp. 482-485.
- [16] S. Fiel y R. Sablatnig, "Automated identification of tree species from images of the bark, leaves and needles".
- [17] (2016, Julio) Leafsnap. [Online]. <http://leafsnap.com/>
- [18] Inria. (2014, Marzo) PI@ntNet. [Online]. <http://m.plantnet-project.org/>
- [19] "Investigación sobre el reconocimiento automático foliar de la laurisilva canaria," no. 23, 2004.
- [20] Rafael C. González, *Digital image processing: using MATLAB*. Nueva Jersey, EEUU, 2004.
- [21] Christopher M. Bishop, *Neural Networks for Pattern Recognition*. Cambridge: Oxford University Press, 2010.
- [22] Carlos García Álvarez, *Diseño de aplicación móvil para detección de plantas invasoras. Integración de framework IUMA*. Las Palmas de Gran Canaria, 2016.
- [23] ULPGC, "Reglamento de Proyectos Fin de Carrera de la EITE," , Las Palmas de Gran Canaria, 2015.
- [24] Greg Roelofs, *PNG: The Definitive Guide.*, 1999.
- [25] Nayara Rodríguez Rodríguez, *Detección e identificación de múltiples tipos de escritura en imágenes*

de texto, EITE, Ed. Las Palmas de Gran Canaria, España: ULPGC, 2015.

- [26] "Evaluation of LBP and HOG descriptors for clothing attribute description," *Acceda, ULPGC*.
- [27] Modesto Castrillón Santana, Javier Lorenzo Navarro, Enrique Ramón Balmaseda, "Improving Gender Classification Accuracy in the," *Acceda ULPGC*.
- [28] Miriam Presutti, "La Matriz de co-ocurrencia en la clasificación multiespectral: Tutorial para la enseñanza de medios exturales en cursos de grado universitario," in *4ª Jornada de Educação em Sensoriamento Remoto no Âmbito do Mercosul*, São Leopoldo, Brasil, 2004. [Online].
http://www.inpe.br/unidades/cep/atividadescep/jornada/programa/t-9_trab_27.pdf
- [29] T. Van Gestel, J. De Brabanter, B. De Moor, J. Vandewalle J.A.K. Suykens, *Least Squares Support Vector Machines*. Singapore: World Scientific, 2002.
- [30] (2016, Julio) Excite. [Online]. <http://social.excite.es/Economia-Empleo/Finanzas/Como-gana-dinero-Nintendo-con-Pokemon-Go?>
- [31] LSSVM lab. [Online]. <http://www.esat.kuleuven.be/sista/lssvmlab/>

III. PROGRAMAS



PRO.1 DISTRIBUCIÓN DE ALGORITMOS

En este apartado se presentan los programas desarrollados e implementados a lo largo de este trabajo, con sus nombres y descripciones. El código correspondiente no viene incluido en este documento, sino que se ha exportado a uno de los CDs que se entregan con esta memoria.

El programa completo consta de un módulo de ejecución principal con 3 partes, **la parametrización** de las imágenes de la base de datos, **la clasificación** de las muestras y la exposición de los **resultados**. Aparte, hay que tener en cuenta las **funciones auxiliares** que se aplican de forma más dispersa.

PRO.1.1 Módulo Principal (main.m)

En el modulo principal se definen los parámetros de lanzamiento del programa, como la ruta del propio programa, el formato de la base de datos, o incluso, la tasa de entrenamiento. Además, se separa la ejecución de las tres partes que se describieron anteriormente de manera conveniente:

- Step1_Algorithms.m
- Step2_Classifier.m
- Step3_Results.m

PRO.1.2 Módulo de Parametrización (Step1_Algorithms.m)

La primera parte del programa se encarga de la aplicación de los diferentes algoritmos y sistemas que extraen los parámetros de la base de datos. A la vez que se aplican dichos algoritmos y sistemas, **se va guardando en disco cada resultado**.

Esto sirve para cargarlo más adelante, ya sea para aplicar un nuevo algoritmo o sistema; o para introducirlo en el clasificador.

- *makeALList.m*. Elabora una estructura que contiene el conjunto de sistemas y algoritmo que se van a aplicar junto con sus correspondientes rutas de cargado y guardado.
 - *makeDWTLlist.m*. DWT es un caso especial, ya que para cada ruta de carga, se generan 4 de guardado; a la vez que el sistema sólo se ejecuta una vez.
- *loadALsave.m*. Tomando como valores de entrada una fila de la estructura que sale de la función anterior; la función carga las imágenes de una ruta, aplica un algoritmo o sistema concreto, y guarda la/s imagen/es resultante/s en otra ruta.

PRO.1.3 Módulo de Clasificación (Step2_Classifier.m)

En la segunda parte del programa, se construye una tabla con los parámetros de todas las muestras que se quieran introducir en el clasificador. Siguiendo un proceso de selección aleatorio, se divide dicha tabla para la etapa de entrenamiento y la etapa de test. Para cada modelo que se quiera trazar, se seleccionan los parámetros que se deseen introducir y una de las dos opciones de *labels*. El resultado es un conjunto de datos, en los que se encuentra la matriz de confusión o el propio modelo de clasificación. Es guardado en un directorio, definido ya en el módulo principal.

- *createStructData.m*. La ejecución de esta función sólo es necesaria una vez, ya que genera una estructura de datos con lo básico: los dos *labels* de las muestras y un vector binario para la asignación de entrenamiento

o test de cada muestra. Al final, se guarda dicha estructura en el directorio indicado en el módulo principal.

- *trainOrTest.m*. Genera un vector binario. De esta forma, a cada muestra le corresponde un 0 o un 1. Esto indica si la muestra en cuestión es una muestra de entrenamiento o de test. La proporción viene indicada por la tasa de entrenamiento. Esta es la misma para cada clase.
- *makeDataList.m*. Esta función combina la ruta del parámetro con el nombre del parámetro. Además, se puede indicar que varios parámetros pertenecen a un mismo grupo, para que, a la hora de clasificar, se introduzcan todos juntos. De esta manera, se genera una estructura con la ruta y el nombre.
- *structData.m*. Con *structData* se carga la estructura guardada en el directorio, a la vez que también se cargan los parámetros definidos por la ejecución de la función *makeDataList*. Con ello, añade a aquélla los campos facilitados por ésta. Finalmente, se vuelve a guardar la estructura. Si es la primera vez que se ejecuta esta función, la estructura será la generada por *createStructData*: sin campos, es decir, sin ningún parámetro.
- *splitData.m*. Como su propio nombre indica, genera dos estructuras de datos a partir de la anterior. El corte se hace en función del campo generado por *trainOrTest*, por lo que una de las estructuras resultantes será la de entrenamiento. En cuanto a la otra, será para testear el clasificador.
- *mySplit.m*. Es la función que interpreta el campo generado por *trainOrTest*. Divide cada parámetro de la estructura, uno a uno.
- *myLSSVM.m*. Genera un modelo de clasificador a partir de los parámetros de las muestras que se quieran introducir en la estructura de

datos de entrenamiento, con ello, también se tiene que indicar cuáles son los *labels*. Esta función no es más que una particularización del sistema *LSSVM.m* [28].

- *myTester2.m*. Al igual que con la función anterior, se introducen los parámetros y los *labels*, pero esta vez de la estructura de datos de test. Con ello se genera una serie de resultados. El más relevante es la **matriz de confusión**. Además, se compila con el propio clasificador, para **guardarlo todo junto en un directorio**.

PRO.1.4 Módulo de Resultados y Representaciones (Step3_Results.m)

En la tercera parte del programa, se incluyen todas las maneras de representar los resultados que a uno se le puedan ocurrir. De esta manera, el código está forzado a salvaguardar todos los resultados.

- *calculateAllSR.m*. Esta función carga todas las matrices de confusión para calcular su tasa de acierto y mostrarlas en consola.
 - *calculateSR.m*. Particularizando, esta función calcula la tasa de acierto de una matriz de confusión. Lo hace a partir de la suma de su diagonal principal con respecto a la suma total de la matriz.
- *calculateAllDisc.m*. Otro de los resultados que se puede mostrar es el número de descartes ocurridos en el test para cada uno de los modelos desarrollados.
- *composicion2.m*. Esto es una manera de representar imágenes de los principales algoritmos y sistemas a modo de ejemplo.

PRO.1.5 Funciones globales auxiliares

Finalmente, se describen algunos de los algoritmos auxiliares que se utilizaron en este proyecto:

- **preguntarEjecucion.m.** La función pregunta por consola, mediante un *string* determinado, si se quiere ejecutar la sección de código en su interior. Esto sirve para asegurar la funcionalidad de dicho código sin tener que ejecutarlo todo de una vez.
- **completePath.m.** Sirve para concatenar dos secciones y formar una ruta completa.
- **mySave.m y myLoad.m.** Son funciones de guardado y cargado en disco similares a las propias de MATLAB, pero con una aplicación más intuitiva y centrada.
- **mySparseCell.m.** Convierte una *cell* de *strings* en un solo *string*. Se usa para que puedan aparecer todas juntas en consola.
- **delSlash.m.** Elimina la barra (/) de un *string* por cuestiones de representación en consola o conversión a un nombre válido.

IV. PLIEGO DE CONDICIONES



PLI.1 RECURSOS HARDWARE UTILIZADOS

Para el presente proyecto, se ha utilizado una serie de herramientas software y hardware, indicadas a continuación.

Como elementos *hardware* se empleó:

- **Un ordenador sobremesa** con microprocesador *Intel® Core™ i7*, 8 GB de memoria RAM, y 500 GB de disco duro, el cual se utilizó para demostraciones del funcionamiento del sistema y una parte de la redacción de la memoria.
- **Un ordenador sobremesa personal** modelo (*ipower G3710*) con microprocesador *Intel® Core™ i7 860* a 2,80 GHz, 8,00 GB de memoria RAM y 1 TB de disco duro, en el cual se llevaron a cabo gran parte del desarrollo y las simulaciones realizadas. Además, también se redactó en él gran parte de la memoria.
- **Un Pen Drive** de 32GB modelo *ULTRA FIT™ USB 3.0*. Con el que se intercambiaba la información entre ordenadores.

PLI.2 RECURSOS SOFTWARE UTILIZADOS

También se utilizaron las siguientes herramientas *software*:

- **MATLAB® versión r2010b**: para el desarrollo de la totalidad de los algoritmos implementados en este proyecto. Además del paquete básico se utilizaron los siguientes *toolboxes*:
 - **Image Processing Toolbox**: para el procesado de las imágenes.
 - **Neural Network Toolbox**: para la representación de matrices de confusión.

- *Wavelet Toolbox*: para la aplicación del sistema DWT.
- *Microsoft Office® 2007*: es el paquete de herramientas, en las que se incluye *Microsoft Word*, que se han utilizado para la elaboración de la memoria.
- **GIMP versión 2.8.16**: es el programa utilizado para la manipulación de algunas representaciones.
- **Windows® 7**: es el sistema operativo bajo el que se trabajó en todos los equipos.
- **Notepad++ versión 6.3.2**: editor de texto para la edición de algoritmos.
- *Dropbox*: ha sido el repositorio en el que se ha cargado el proyecto.

V. PRESUPUESTO



PRE.1 DECLARACIÓN JURADA

Don Luis José Blanco Mier, autor del presente Proyecto Fin de Carrera, declara que:

El Proyecto Fin de Carrera con título *Identificación de especies invasoras de plantas en la isla de Gran Canaria a partir de su corteza*, desarrollado en la EITE, de la ULPGC, en el período de un año, tiene un coste de desarrollo total de **DIECINUEVE MIL CUATROCIENTOS DIECIOCHO EUROS CON CINCUENTA Y CUATRO CÉNTIMOS (19.418,54 €)**. Esto se corresponde con la suma de las cantidades consignadas a los apartados considerados a continuación.

Las Palmas de Gran Canaria, a 21 de Julio de 2016

Fdo: Luis José Blanco Mier

PRE.2 DESGLOSE DEL PRESUPUESTO

El presupuesto del proyecto realizado se ha obtenido según las indicaciones del Colegio Oficial de Ingenieros de Telecomunicación (COIT) y de la Asociación Española de Ingenieros de Telecomunicación, a efectos de visado. Estos costes se dividen en:

1. Recursos materiales.
2. Trabajo tarifado por tiempo empleado.
3. Derechos de visado del COIT.
4. Gastos de tramitación y envío.
5. Aplicación de impuestos.

PRE.2.1 Recursos Materiales

Entre los recursos materiales utilizados para la realización de este proyecto se incluyen las herramientas software de desarrollo de los algoritmos del sistema, los paquetes software usados para la redacción de la memoria, y el sistema operativo bajo el que se ejecutó el trabajo. Igualmente, se incluye el hardware utilizado para dar soporte a estas herramientas.

Se estipula el coste de amortización para un período de 3 años. Para ello, se utilizará un sistema de amortización lineal o constante, en el que se supone que el inmovilizado material se deprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula usando la siguiente fórmula:

$$\text{Cuota de amortización anual} = \frac{\text{Valor de adquisición} - \text{Valor residual}}{\text{Nº de años de vida útil}} \quad \text{Eq 8}$$

El “valor residual” es el valor teórico que se supone que tendrá el elemento después de su vida útil.

PRE.2.1.1 RECURSOS SOFTWARE

Las herramientas software utilizadas en presente proyecto fueron:

- **MATLAB® versión r2010b:** para el desarrollo de la totalidad de los algoritmos implementados en este proyecto. Además del paquete básico se utilizaron los siguientes *toolboxes*:
 - *Image Processing Toolbox:* para el procesado de las imágenes.
 - *Neural Network Toolbox:* para la representación de matrices de confusión.
 - *Wavelet Toolbox:* para la aplicación del sistema DWT.
- **Microsoft Office® 2007:** es el paquete de herramientas, en las que se incluye Microsoft Word, que se han utilizado para la elaboración de la memoria.
- **GIMP versión 2.8.16:** es el programa utilizado para la manipulación de algunas representaciones.
- **Windows® 7:** es el sistema operativo bajo el que se trabajó en todos los equipos.
- **Notepad++ versión 6.3.2:** editor de texto para la edición de algoritmos.
- **Dropbox:** ha sido el repositorio en el que se ha cargado el proyecto.

Teniendo en cuenta que la duración del proyecto es de aproximadamente de un año y el cálculo del coste de amortización se establece en un período de 3 años,

los costes de amortización se calcularán para el primer año. Estos costes se pueden ver en la tabla de costes de las herramientas software.

Costes de las herramientas Software			
Descripción	Coste Total	Valor Residual (3 años)	Valor Amortización (1 año)
MATLAB® versión r2010b académica	3900 €	0 €	1300 €
Microsoft Office® 2007	350 €	0 €	116,67 €
<i>Dropbox</i>	0 €	0 €	0 €
<i>Notepad++ v.6.3.2</i>	0 €	0 €	0 €
<i>Gimp v.2.8.16</i>	0 €	0 €	0 €
Windows® 7 Home Premium	44,77 €	0 €	14,92 €
Windows® 7 Profesional	135 €	0 €	45 €
Total de Costes			1.476,59 €

Tabla 24: Costes de las herramientas Software

Por lo tanto, el coste total del material software sin aplicar impuestos asciende a **MIL CUATROCIENTOS SETENTA Y SEIS EUROS CON CINCUENTA Y NUEVE CÉNTIMOS (1.476,59 €)**.

PRE.2.1.2 RECURSOS HARDWARE

Las herramientas hardware en las que se apoya el presente proyecto son:

- **Un ordenador sobremesa** con microprocesador *Intel® Core™ i7*, 8 GB de memoria RAM, y 500 GB de disco duro, el cual se utilizó para demostraciones del funcionamiento del sistema y una parte de la redacción de la memoria.
- **Un ordenador sobremesa personal** modelo (*ipower G3710*) con microprocesador *Intel® Core™ i7 860* a 2,80 GHz, 8,00 GB de memoria RAM

y 1 TB de disco duro, en el cual se llevaron a cabo gran parte del desarrollo y las simulaciones realizadas. Además, también se redactó en él gran parte de la memoria.

- **Un Pen Drive** de 32GB modelo ULTRA FIT™ USB 3.0. Con el que se intercambiaba la información entre ordenadores. Al tratarse de un dispositivo de almacenamiento, su valor residual es 0.
- Sustitución del **teclado personal** por uno modelo *Stinger FX 80K*. El anterior sufrió daños durante la realización de este proyecto, por lo que se optó por cambiar a otro.
- **Dos DVD-R de 4,7 GB** para la grabación del proyecto.

Aplicando la regla de costes anterior se tiene:

Costes de las herramientas Hardware			
Descripción	Coste Total	Valor Residual (3 años)	Valor Amortización (1 año)
Ordenador sobremesa	1200 €	200 €	333,33 €
Ordenador Personal	997,87 €	400 €	199,29 €
Teclado	19,99€	7,55€	4,15€
<i>Pen Drive</i>	12,99 €	0 €	12,99 €
DVDs	2,00€	0€	2,00€
Total de Costes			551,76€

Tabla 25: Costes de las herramientas Hardware

Por lo tanto, el coste total del material hardware libre de impuestos asciende a **QUINIENTOS CINCUENTA Y UN EUROS CON SETENTA Y SEIS CÉNTIMOS (551,76 €)**.

PRE.2.2 Trabajo Tarifado por el Tiempo Empleado

El proyectante ha invertido 12 meses en las tareas de formación, especificación, desarrollo y documentación necesarias para la elaboración del presente proyecto fin de carrera. El importe de las horas de trabajo empleadas para la realización del proyecto se calcula siguiendo las recomendaciones del COIT:

$$H = 74,88 \cdot H_N \cdot C_T + 96,72 \cdot H_E \cdot C_T \quad \text{Eq 9}$$

Siendo H (€) los honorarios totales; H_N (horas), las horas trabajadas durante la jornada laboral; H_e (horas), las horas especiales; y C_t es un factor de corrección escalable al número de horas trabajadas.

Para la realización de este proyecto han sido necesarias 300 horas, de las cuales 240 han sido normales; y las 60 restantes, especiales. Siguiendo las tabulaciones ofrecidas por el COIT (véase tabla 26), el coeficiente C_t toma los valores 0,60 para las horas normales; y 0,90 para las especiales.

Horas empleadas	Factor de corrección
Hasta 36 horas	1,00
De 36 a 72 horas	0,90
De 72 a 108 horas	0,80
De 108 a 144 horas	0,70
De 144 a 180 horas	0,65
De 180 a 360 horas	0,60
De 360 a 540 horas	0,55
De 540 a 720 horas	0,50
De 720 a 1080 horas	0,45
Más de 1080 horas	0,40

Tabla 26: Factor de corrección de los honorarios

$$H = 0,6 \cdot 74,88 \cdot 240 + 0,9 \cdot 96,72 \cdot 60 \text{ €} \quad \text{Eq 10}$$

$$\boxed{H = 16.005,60 \text{ €}}$$

En la tabla siguiente se desglosa el tiempo de trabajo invertido.

Costes por Tiempo Empleado			
Descripción	Tiempo	Coste/mes	Importe
Formación	1 mes	1333,80 €	1333,80 €
Documentación	2 meses		2667,60 €
Especificación	2 meses		2667,60 €
Desarrollo	7 meses		9336,60 €
Total de Costes			16.005,60 €

Tabla 27: Costes por tiempo empleado

Los honorarios totales por tiempo dedicado libres de impuestos ascienden a **QUINCE MIL CUATROCIENTOS VEINTICINCO EUROS CON VEINTIOCHO CÉNTIMOS (15.425,28 €)**.

PRE.2.3 Derechos de visado del COIT

Los gastos de visado del COIT se tarifican mediante la siguiente expresión:

$$V = 0,006 \times P \times C \quad \text{Eq 11}$$

Donde P es el presupuesto del proyecto; C es el coeficiente reductor en función del presupuesto del proyecto. El presupuesto hasta ahora asciende a los 18.031,95€ (Véase la tabla 28).

Descripción	Costes
Recursos Software	1.476,59 €
Recursos Hardware	549,76 €
Trabajo Tarifado por Tiempo Empleado	16.005,60 €
Total de Costes	18.031,95€

Tabla 28: Coste de las herramientas y el tiempo empleado

Como el coeficiente C para presupuestos de menos de 30.050 € viene definido por el COIT con un valor de 1 se tiene:

$$V = 0,006 \times P \times C \quad \text{Eq 12}$$

Por tanto el coste de los derechos de visado del proyecto asciende a **CIENTO OCHO EUROS CON VEINTE CÉNTIMOS (108,20€)**.

PRE.2.4 Gastos de tramitación y envío

Los gastos de tramitación y envío están fijados en **6,01 €**.

PRE.2.5 Aplicación de impuestos

El coste total del proyecto, antes de aplicarle los correspondientes impuestos, asciende a **18.148,16 €** (véase la tabla 29), a lo que hay que sumarle el 7 % de IGIC.

Costes Totales del Proyecto	
Descripción	Total
Recursos Software	1.476,59 €
Recursos Hardware	551,76€
Coste del ingeniero	16.005,60 €
Derechos de Visado	108.20 €
Tramitación y Envío	6,01 €
Subtotal:	18.148,16€
Aplicación de Impuestos (7 % I.G.I.C)	1270,38€
Total de Costes	19.418,54€

Tabla 29: Cálculo del coste total del proyecto

El presupuesto total asciende a la cantidad de **DIECINUEVE MIL CUATROCIENTOS DIECIOCHO EUROS CON CINCUENTA Y CUATRO CÉNTIMOS (19.418,54 €)**.

Las Palmas de Gran Canaria, a 21 de Julio de 2016

Fdo: Luis José Blanco Mier