

DEPARTAMENT D'ENGINYERIA ELECTRÒNICA

DETECCIÓN AUTOMÁTICA DE PODREDUMBRES EN  
CÍTRICOS MEDIANTE PROCESADO AVANZADO DE  
IMÁGENES HIPERESPECTRALES.

JUAN GÓMEZ SANCHIS

UNIVERSITAT DE VALÈNCIA  
Servei de Publicacions  
2010

Aquesta Tesi Doctoral va ser presentada a València el dia 8 de gener de 2010 davant un tribunal format per:

- Dr. Florentino Juste Pérez
- Dr. Filiberto Pla Bañón
- Dr. José Luis Rojo Álvarez
- Dr. José David Martín Guerrero
- Dr. Luis Gómez Chova

Va ser dirigida per:

Dr. Gustavo Camps Valls

Dr. José Blasco Ivars

©Copyright: Servei de Publicacions  
Juan Gómez Sanchis

---

Dipòsit legal: V-1066-2011

I.S.B.N.: 978-84-370-7802-1

Edita: Universitat de València

Servei de Publicacions

C/ Arts Gràfiques, 13 baix

46010 València

Spain

Telèfon:(0034)963864115

VNIVERSITAT (Ó) ESCOLA TÈCNICA SUPERIOR D'ENGINYERIA  
ED VALÈNCIA (Ó) DEPARTAMENT D'ENGINYERIA ELECTRÒNICA



centro de  
agroingeniería



INSTITUTO VALENCIANO DE INVESTIGACIONES AGRARIAS

TESIS DOCTORAL

Detección automática de podredumbres en cítricos  
mediante procesamiento avanzado de imágenes  
hiperespectrales

Autor

Juan Gómez Sanchis

Directores

Dr. José Blasco Ivars

Dr. Gustavo Camps Valls

Departamento de Ingeniería Electrónica  
UNIVERSIDAD DE VALENCIA – ESTUDIO GENERAL  
Valencia – NOVIEMBRE, 2009.

Detección automática de podredumbres en cítricos mediante procesado avanzado de imágenes hiperespectrales

Juan Gómez Sanchis, 2009

Dpt. Ingeniería Electrónica.  
Escuela Técnica Superior de Ingeniería.

D. JOSÉ BLASCO IVARS, doctor en Informática por la Universidad Politécnica de Valencia. Trabaja desde 1996 en el IVIA, donde actualmente es el responsable del área de Automatización y Procesos del Centro de Agroingeniería. Su campo de investigación es la visión por computador, el procesado de imágenes y los sistemas de inspección en tiempo real.

D. GUSTAVO CAMPS VALLS, doctor en Física por la Universidad de Valencia. Actualmente es profesor titular de la Universidad de Valencia. Su campo de investigación es el aprendizaje máquina y el procesado de señales en imágenes.

HACEN CONSTAR QUE:

el Ingeniero en Electrónica D. Juan Gómez Sanchis ha realizado bajo nuestra dirección la Tesis Doctoral titulada “Detección automática de podredumbres en cítricos mediante procesado avanzado de imágenes hiperespectrales”, que se presenta en esta memoria en calidad de TESIS DOCTORAL, correspondiente al programa de doctorado de Ingeniería Electrónica.

Y para que así conste a los efectos oportunos, firmamos el presente certificado, en Valencia, a 6 de Noviembre de 2009.

---

Dr. José Blasco Ivars  
Director

---

Dr. Gustavo Camps Valls  
Co-Director

---

Dr. Diego Ramírez  
Director del Departamento

---

Tesis Doctoral: DETECCIÓN AUTOMÁTICA DE PODREDUMBRES  
EN CÍTRICOS MEDIANTE PROCESADO AVANZADO  
DE IMÁGENES HIPERESPECTRALES

Autor: JUAN GÓMEZ SANCHIS

Directores: Dr. JOSÉ BLASCO IVARS  
Dr. GUSTAVO CAMPS VALLS

---

El tribunal nombrado para juzgar la Tesis Doctoral arriba citada, compuesto por los señores:

Presidente: \_\_\_\_\_

Vocales: \_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_

Secretario: \_\_\_\_\_

Acuerda otorgarle la calificación de \_\_\_\_\_

Y para que así conste a los efectos oportunos, firmamos el presente certificado.

Valencia, a \_\_\_\_\_

# Agradecimientos

Ya hace mucho tiempo que empezó mi andadura en esto de la investigación... ya casi ni recuerdo. No obstante no olvido las innumerables ayudas recibidas por el camino, y como soy bien nacido no puedo dejar de agradecer la ayuda prestada.

En primer lugar recordar a la persona que lea estas líneas que la investigación es un asunto que cuesta mucho dinero, por ello quiero agradecer al Instituto Valenciano de Investigaciones Agrarias (IVIA) la beca de predoctoral que ha permitido llevar a cabo esta Tesis Doctoral.

Tal vez la persona que más culpa tiene de que este trabajo haya salido adelante ha sido el Dr. José Blasco Ivars, compañero de trabajo del IVIA, referente a quien tratar de imitar por su buen hacer investigador y ante todo un buen amigo. Su infinita paciencia ha sido y es, el complemento perfecto para solventar mi tozudez y marcar el camino adecuado en un sinfín de ocasiones. Tantas cosas que agradecer... su confianza en mi para colaborar en su amplia actividad investigadora, su paciencia y mano izquierda pero sobre todo la flexible pero firme dirección de esta Tesis Doctoral. No puedo olvidar al Dr. Gustavo Camps i Valls, gracias por haber accedido a codirigir esta Tesis Doctoral aportando su amplia experiencia en el tratamiento de imágenes hiperespectrales y por estar ahí siempre ofreciendome su comprensión cuando la he necesitado.

Gracias a todo los compañeros del Centro de Agroingeniería, por aceptarme desde el primer día que llegue al IVIA, consiguiendo mi rápida integración en el grupo y haciendo que los cuatro años que compartí con ellos fueran muy productivos. Dedicar un agradecimiento especial a todos los miembros del grupo de visión, Sergio, los hermanos Alegre (Santi y Vicente), Emilio y Manu gracias por vuestra constante y permanente ayuda para llevar a cabo los experimentos de esta Tesis y cualquier proyecto en el que me embarcase. Por supuesto agradecer a Luis Palou y a Clara Montesinos (Dpto. de Poscosecha), la ayuda prestada con los experimentos de inoculación con hongos llevados a cabo en esta Tesis Doctoral.

No puedo dejar de mencionar a mis actuales compañeros del GPDS del Departamento de Ingeniería Electrónica de la Universidad de Valencia (Alfredo, Jovi, Jordi, Javi, Juan, Manolo, Emma, Luis, Julia y Joan) trabajar con vosotros a diario es un verdadero lujo. Agradecer especialmente al Dr. Luis Gómez Chova, su constante interés (propio del amigo que es) y la total e inestimable ayuda prestada. Sin sus geniales sugerencias e ideas sobre el análisis de imágenes hiperespectrales este trabajo no sería el que es, estoy completamente seguro de ello.

Tal vez a las personas que más tengo que agradecer en los meses finales del desarrollo de esta Tesis es a mis compañeros y amigos del laboratorio de análisis inteligente de datos (IDAL), Emilio, Marcelino, Rafa, Antonio y Jose. Gracias por el ánimo permanente para que escribiese esta Tesis y por haber sufrido y soportado con la mejor de las sonrisas incrementos importantes en vuestras

cargas de trabajo para que yo pudiese concluir esta Tesis sin pedir nada a cambio..... Gracias por ser como sois, trabajar a diario con un grupo de buenos amigos es una suerte reservada a muy pocos....

Quiero dar las gracias a las empresas que han colaborado de un modo interesado o desinteresado en este trabajo. Gracias a RODA IBERICA por el esfuerzo económico invertido en desarrollar sistemas automáticos para la detección de podredumbres. Agradecer a la empresa FONTESTAD, la total colaboración prestada para disponer de cítricos para realizar este trabajo. Gracias Antonio por la visita a las instalaciones de la empresa distribuidora de cítricos ANTONIO CARDO S.L. para conocer de primera mano como funcionan las “discotecas” en las que se detectan podredumbres manualmente.

Gracias a los doctores Luis Sabater y María Jose Terol sin su moderna alquimia y su corazón... esta Tesis Doctoral jamás se hubiera escrito, por lo menos por este autor....

Finalmente quiero dar las gracias muy especialmente a las personas que han “sufrido” a diario esta Tesis Doctoral durante unos cuantos años. Mis hermanos Miguel, Rafa y Gema. Mis padres Miguel, Isabel y Encarni. Y por supuesto a la gente que ya no está..... y que han marcado mi vida. Por último gracias brujita..... piensa, siente y no dejes nunca de hechizarme....

Juan Gómez Sanchis, 2009



Physics is not a job...  
it is a way of thought  
*J. Hopfield*

A Gema, Pepa  
y los demás....

# Índice general

Índice general	IX
Resumen	XII
<b>1. Introducción y objetivos generales</b>	<b>1</b>
1.1. Introducción . . . . .	1
1.1.1. Daños en cítricos . . . . .	2
1.1.2. Sistemas de visión convencionales . . . . .	5
1.1.3. Sistemas de visión hiperespectrales . . . . .	6
1.1.4. Cadena de preprocesado de imágenes hiperespectrales . . . . .	8
1.2. Organización de la Tesis Doctoral . . . . .	10
1.3. Objetivos de la Tesis Doctoral . . . . .	11
<b>2. Sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido</b>	<b>15</b>
2.1. Introducción . . . . .	15
2.2. Objetivos en la implementación del sistema de visión . . . . .	18
2.3. Materiales y métodos . . . . .	18
2.3.1. Campana de inspección . . . . .	18
2.3.2. Sistema de iluminación . . . . .	24
2.3.3. <i>Hardware</i> de adquisición . . . . .	30
2.3.4. Filtros sintonizables de cristal líquido . . . . .	32
2.3.5. <i>Software</i> específico de control . . . . .	33

2.3.6.	Parámetros de funcionamiento del sistema . . . . .	35
2.4.	Resultados . . . . .	38
2.4.1.	Caracterización espectral de los LCTF . . . . .	38
2.4.2.	Tiempo de precalentamiento de las lámparas halógenas . . . . .	39
2.4.3.	Tiempos de integración del CCD . . . . .	39
2.4.4.	Metodología de adquisición VIS+NIR . . . . .	41
2.5.	Conclusiones . . . . .	42
<b>3.</b>	<b>Preprocesado de imágenes hiperespectrales</b>	<b>45</b>
3.1.	Introducción . . . . .	45
3.2.	Objetivos . . . . .	47
3.3.	Materiales y métodos . . . . .	48
3.3.1.	Particularidades del sistema de visión hiperespectral . . . . .	48
3.3.2.	Corrección de las variaciones espaciales del iluminante . . . . .	49
3.3.3.	Corrección geométrica . . . . .	53
3.3.4.	Ensayos de evaluación de la técnica de preprocesado . . . . .	59
3.4.	Resultados . . . . .	61
3.5.	Conclusiones . . . . .	64
<b>4.</b>	<b>Detección hiperespectral de podredumbres</b>	<b>67</b>
4.1.	Introducción . . . . .	67
4.2.	Objetivos . . . . .	68
4.3.	Materiales y métodos . . . . .	69
4.3.1.	Sistema de adquisición de imagen y material vegetal . . . . .	69
4.3.2.	Preprocesado de imágenes hiperespectrales . . . . .	70
4.3.3.	Conjunto de datos etiquetado . . . . .	71
4.3.4.	Reducción de la dimensionalidad . . . . .	73
4.3.5.	Segmentación de las imágenes . . . . .	77
4.3.6.	Clasificación de la fruta . . . . .	85
4.4.	Resultados . . . . .	85

4.5. Conclusiones . . . . .	93
<b>5. Clasificación de podredumbres producidas por <i>P. digitatum</i> y <i>P. italicum</i></b>	<b>95</b>
5.1. Introducción . . . . .	95
5.2. Objetivos . . . . .	97
5.3. Materiales y métodos . . . . .	98
5.3.1. Sistema hiperespectral de adquisición de imagen . . . . .	98
5.3.2. Material vegetal . . . . .	99
5.3.3. Conjunto de datos etiquetado . . . . .	101
5.3.4. Selección de características . . . . .	104
5.3.5. Técnicas de segmentación no lineales . . . . .	107
5.3.6. Clasificación de frutas . . . . .	114
5.4. Resultados . . . . .	115
5.4.1. Selección de bandas . . . . .	115
5.4.2. Segmentación no lineal con árboles de decisión y redes neuronales . . . . .	119
5.4.3. Clasificación de fruta con CART . . . . .	127
5.5. Conclusiones . . . . .	129
<b>6. Conclusiones generales, proyección futura y logros alcanzados</b>	<b>131</b>
6.1. Aportaciones de la Tesis Doctoral y conclusiones generales . . . . .	131
6.2. Conclusiones específicas . . . . .	133
6.2.1. Sistemas de visión hiperespectral . . . . .	133
6.2.2. Preprocesado de imágenes hiperespectrales . . . . .	135
6.2.3. Detección hiperespectral de podredumbres producidas por <i>Penicillium digitatum</i> . . . . .	135
6.2.4. Segmentación de podredumbres producidas por <i>P. digitatum</i> y <i>P. italicum</i>	136
6.3. Proyección futura . . . . .	138
6.4. Logros científicos obtenidos relacionados con la Tesis Doctoral . . . . .	139
6.4.1. Publicaciones en revistas internacionales indexadas y capítulos en libro . . . . .	139
6.4.2. Transferencia tecnológica y patentes . . . . .	140

6.4.3. Proyectos de investigación . . . . .	140
<b>Apéndices</b>	<b>141</b>
<b>A. Acrónimos</b>	<b>143</b>
<b>B. Lista de símbolos</b>	<b>147</b>
<b>Bibliografía</b>	<b>151</b>

# Resumen

La citricultura constituye actualmente una parte importantísima de la economía en la Comunidad Valenciana. Uno de los principales problemas presentes en la industria citrícola son las podredumbres producidas por los hongos *Penicillium digitatum* y *Penicillium italicum*. La detección temprana del daño producido por los hongos en los cítricos es especialmente importante para la industria distribuidora de cítricos, ya que un reducido número de frutas infectadas puede diseminar la infección a toda una partida de cítricos, produciendo grandes pérdidas económicas. Actualmente en la industria citrícola la inspección y eliminación de cítricos dañados por podredumbres se realiza de manera manual por operarios, ya que en etapas tempranas el daño producido por el hongo es difícilmente detectable por sistemas de inspección automáticos. En esta Tesis Doctoral se va a desarrollar un sistema de visión hiperspectral basado en filtros de cristal líquido sintonizables y se van a estudiar técnicas para procesar las imágenes proporcionadas por el mismo de forma automática. La finalidad de dichas técnicas será obtener un grupo reducido y lo suficientemente informativo de bandas espectrales mediante métodos de selección de características que permita detectar los frutos afectados por podredumbres tempranas mediante algoritmos automáticos de clasificación.

---

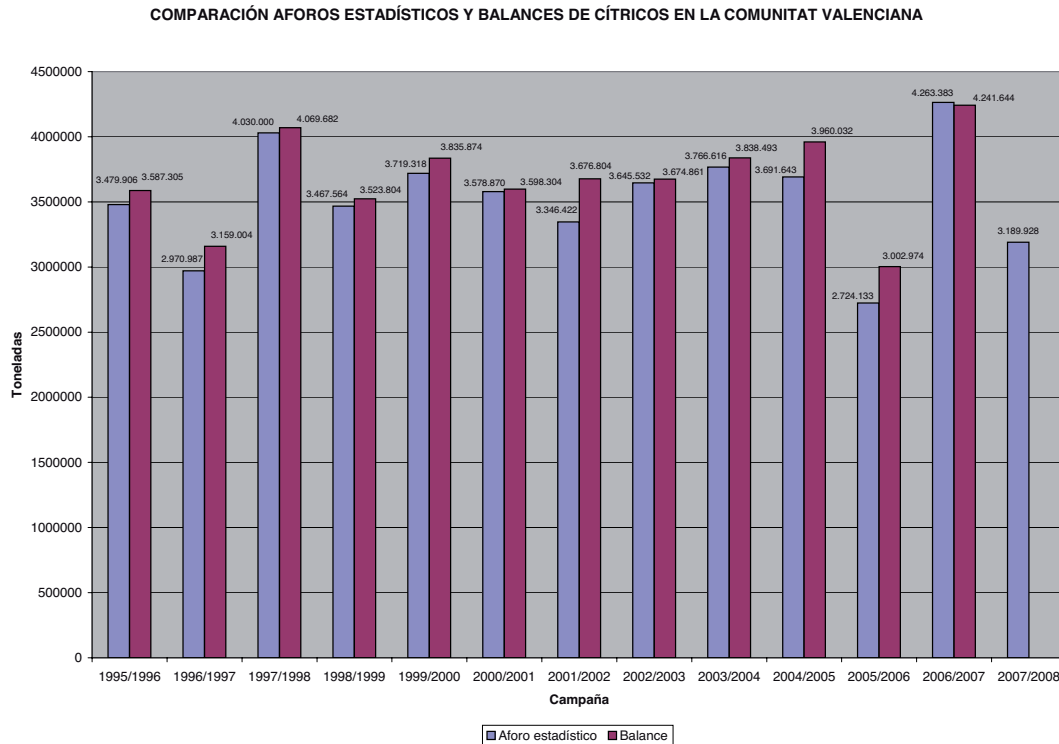


# Capítulo 1

## Introducción y objetivos generales

### 1.1. Introducción

El sector citrícola, con algo más de 89 millones de toneladas de producción anual, es la primera producción de frutas en el mundo, lo que da una idea de la importancia que tiene dentro de la economía mundial este sector. También lo es en la Unión Europea, donde su producción alcanza cifras cercanas a los 10 millones de toneladas, de las que aproximadamente el 35 % corresponden a la producción de la Comunidad Valenciana. España es el primer país exportador mundial de cítricos en fresco, acaparando el 34 % del comercio mundial, y el cuarto en cuanto a producción se refiere. Según la Generalitat Valenciana, durante la campaña 2006-2007, la producción valenciana de cítricos ascendió a 4.241.644 toneladas (figura 1.1), lo que representa aproximadamente el 80 % del total de los cítricos españoles. Si nos atenemos únicamente a los datos de los cítricos más importantes, tenemos que la Comunidad Valenciana exportó el 88,7 % de las naranjas y el 97,1 % de mandarinas españolas. De la parte de la producción valenciana que se consume fuera del mercado español, aproximadamente el 82 % se destina a países de la Unión Europea, mientras que el resto se exporta a países tan dispares como Japón o Canadá, donde los cítricos valencianos tienen un mercado cada vez más importante. Cabe citar el ejemplo de las exportaciones de cítricos valencianos a Estados Unidos, que han pasado de 4.200 a 80.000 toneladas en los últimos 10 años, debido al esfuerzo de los productores por ofrecer productos de gran calidad. Para mantener este nivel de comercio se ha realizado un gran esfuerzo por elevar la calidad del producto, asegurando, entre otras características de calidad, la ausencia total de daños en la piel de las frutas.



**Figura 1.1:** Evolución del balance (producción real) y aforo estadístico (previsión) de la producción de cítricos en la Comunidad Valenciana. (Generalitat Valenciana, 2008)


### 1.1.1. Daños en cítricos

Atendiendo a los daños económicos que de ellos se pueden derivar, los defectos que se encuentran en la piel de los cítricos se pueden clasificar en dos categorías: defectos que siguen evolucionando una vez que la fruta ha sido recolectada y defectos que no evolucionan. A continuación se detallan los defectos más importantes agrupados según esta clasificación.

- Entre los defectos que no evolucionan, cabe citar: daños producidos por fenómenos meteorológicos, como las heladas, granizos o lluvias persistentes, daños que se derivan de alteraciones bioquímicas debidas al incorrecto abonado, riego y tratamientos fitosanitarios, daños causados por plagas de insectos que colonizan la superficie del fruto, produciendo un deterioro de su aspecto exterior, pero sin afectar a sus cualidades internas.
- Entre los defectos que evolucionan, se encuentran todos los daños producidos por hongos causantes de diversas podredumbres. Estos hongos penetran en la fruta aprovechando cualquier herida o magulladura de la fruta que presente una rotura de su piel. Las causas de estos daños pueden ser:
  - La recolección a destajo, que suele originar heridas, golpes y magulladuras, o produce

oleocelosis que deriva en otros daños, sobre todo en las frutas tempranas, cuando se lleva a cabo una recolección antes de tiempo.

- La recolección mediante tirón, que ocasiona la ausencia del pedúnculo en la fruta, lo cual permite a los hongos atacar a la fruta por esta zona, o que deja pedúnculos excesivamente largos que pueden pinchar a otras frutas, ocasionándoles heridas por punzamientos.
- Las picaduras de insectos como por ejemplo la mosca blanca del Mediterráneo. La mosca, al picar la fruta, deposita huevos, lo que provoca que las larvas, al eclosionar los huevos, se alimenten de ella, deteriorándola totalmente.



**Figura 1.2:** Defectos comunes producidos en cítricos producidos por: rameados (a), pérdida de pedúnculo (b), punción por pedúnculo (c), fitotoxicidad (d), *trips* (e), serpetas (f), negrilla (g), daño por frío (h), oleocelosis (i), *Penicillium digitatum* (j), antracnosis (k), y picadura de mosca (l).

La figura 1.2 muestra ejemplos de algunos daños comunes en cítricos. Los defectos que no evolucionan deprecian el fruto e impiden la exportación. Sin embargo, en muchas ocasiones, estos frutos pueden ser destinados al mercado interior, como es en el caso de la fruta afectada por

negrilla, rameados ligeros, fitotoxicidad o daños causados por pedrisco. Otros daños, como rameados severos, fuertes golpes o ataque severo de *trips*, impiden el consumo en fresco, debido al mal aspecto que presenta la fruta, pero no afectan a sus cualidades organolépticas, lo que permite aprovechar esta fruta en la industria de transformación. Sin embargo, la fruta infectada por hongos tampoco puede ser aprovechada por la industria de transformación ya que, habitualmente, estos daños afectan negativamente al sabor o el aroma.

Dentro de las podredumbres destaca la podredumbre verde y la podredumbre azul, originada por los hongos *Penicillium digitatum* y *Penicillium italicum* respectivamente, y que afectan a los agrios en su post-recolección, incluido el proceso de comercialización. Las pérdidas económicas causadas por estos hongos son muy importantes, calculándose en términos genéricos que suponen del 10 al 15% del valor total del producto (Eckert and Eaks, 1989). A este problema se suma el hecho de que un reducido número de frutas infectadas puede diseminar la infección a una remesa entera de cítricos, produciendo grandes pérdidas económicas. Este problema presenta serios inconvenientes para el almacenaje de la fruta por largos periodos de tiempo o en la exportación de cítricos al extranjero (Wills et al., 1998), poniendo en peligro asegurar la calidad de los frutos destinados a comercio y en última instancia al consumo.



**Figura 1.3:** Sala de inspección UV de podredumbres en la industria citrícola.

En cuanto a la identificación y eliminación de frutas que presentan estas podredumbres, no existen en el mercado sistemas que permitan su detección automática. Esta labor se lleva a cabo de manera manual aprovechando el fenómeno de la fluorescencia de los aceites esenciales de la piel de los cítricos, liberados debido a la podredumbre, al aplicar luz ultravioleta (UV). Esta inspección



**Figura 1.4:** Líneas de inspección capaces de analizar varias frutas por segundo.

se realiza en unas cámaras de especiales, conocidas popularmente como “discotecas” (ver figura 1.3), utilizando el efecto de fluorescencia que produce la radiación ultravioleta sobre los tejidos afectados. El problema más grave de este modo de inspección se deriva del empleo de la luz UV que es dañina para la piel de las personas, por lo que los operarios no pueden permanecer por un tiempo superior a las dos horas en el interior de la cámara de inspección. En este sentido, la automatización de esta labor mejoraría la calidad del trabajo de estos operarios al realizarse de forma automática, limitándose la tarea del operario a supervisar el correcto funcionamiento de la tecnología a través de unos monitores de control. Una solución general al problema de los daños producidos por *Penicillium digitatum* y *Penicillium italicum* puede venir de la automatización del proceso de detección de frutos afectados por el hongo, y en particular del uso de la visión por computador.

### 1.1.2. Sistemas de visión convencionales

Los sistemas de visión por computador son una parte cada vez más importante en la automatización de los procesos en la agricultura (Kim et al., 2005a; Cho et al., 2002; Chen et al., 2002) y un elemento absolutamente necesario en las tareas de inspección de la fruta en fresco (Blasco et al., 2003; Leemans et al., 2002; Aranda and Tomás, 1997), donde el mantenimiento de la calidad de una elevada producción exige la inspección individual de varias toneladas de fruta por hora (ver figura 1.4). Este aspecto tecnológico es el que en la actualidad puede otorgar una ventaja competitiva a nuestros productores respecto a terceros países que basan su fortaleza en bajos costes de producción. Por ello, es muy importante la constante investigación en sistemas de visión artificial aplicados a la inspección de fruta en fresco que sean cada vez más avanzados y adaptados a las necesidades de nuestros productores.

Los sistemas de visión comúnmente empleados en las tareas de inspección automática, a semejanza del ojo humano, usan la radiación emitida por los cuerpos en tres longitudes de onda concretas, centradas en los colores rojo, verde y azul, y las combinan para obtener las imágenes en color que vemos. Al adquirir y combinar imágenes únicamente de estas tres longitudes de onda se está desaprovechando gran parte de la información de la reflectancia de las frutas en el resto de las longitudes de onda del rango visible y en otras regiones del espectro electromagnético pues, en ocasiones, los defectos se aprecian mejor en otras longitudes de onda intermedias y concretas, alejadas del rojo, verde o azul. En (Gaffney, 1973) se demostró que los distintos tipos de defectos externos de los cítricos presentan una reflectancia distinta para cada longitud de onda, pudiéndose llegar a detectar de qué tipo de defecto se trata mediante métodos espectrométricos. En (Blasco, 2001) se utilizaron distintos filtros interferométricos colocados en las ópticas de diferentes cámaras sensibles al ultravioleta, visible e infrarrojo cercano, con el fin de caracterizar e identificar defectos superficiales en cítricos. El inconveniente principal de estos filtros es la dificultad para realizar barridos en frecuencia (obtener un conjunto de imágenes monocromáticas de la escena), ya que solamente permiten el paso de luz de una longitud de onda concreta y es necesario cambiar el filtro de la óptica para obtener imágenes en distintas longitudes de onda. Un avance en este sentido es el uso, en aplicaciones de inspección de productos agrícolas, de sistemas hiperespectrales como los empleados en (Xing et al., 2005; Polder et al., 2004; Ariana et al., 2006).

### 1.1.3. Sistemas de visión hiperespectrales

Los sistemas hiperespectrales de imagen surgen del campo de investigación del sensado remoto mediante sensores multi e hiperespectrales para la observación de la Tierra (Lillesand et al., 2004; Goetz et al., 1985), expandiéndose rápidamente su uso a otros campos de la ciencia de lo más diversos como la tecnología alimentaria (Park et al., 2002; Kim et al., 2001) o la agricultura de precisión (Erives and Fitzgerald, 2005; Mirick et al., 2006; Yang et al., 2002; Chen et al., 2002; Muhammed, 2005; Lawrence and Labus, 2003). El empleo de este tipo de sistemas para la detección de daños en fruta ha experimentado un importante incremento en los últimos años. En (Xing et al., 2005) los autores utilizan un sistema de visión hiperespectral para detectar golpes en manzanas. El uso de este tipo de tecnología para la detección de golpes en pepinos ha sido empleada por Ariana et al. (2006) utilizando un sistema hiperespectral en el rango infrarrojo. Kim et al. (2005b); Lee et al. (2005); Mhel et al. (2004) han empleado sistemas hiperespectrales para detectar defectos superficiales y contaminantes en manzanas. En el campo de los cítricos, el empleo de sistemas que emplean información espectral no está tan extendido y en los últimos años está experimentando un importante auge para la detección de defectos superficiales. En Qin et al. (2009) el autor emplea un sistema hiperespectral para detectar golpes en cítricos. Este tipo de sistemas también se ha utilizado con éxito para determinar parámetros relacionados con la cali-



dad como la estimación de sólidos solubles en cítricos de la cultivar cv. valencia (Cayuela, 2008) o el grado de maduración (Okamoto and Lee, 2009). A pesar de este incremento en el empleo de este tipo de técnicas en muchos problemas relacionados con los cítricos, el número de referencias bibliográficas relacionadas con la detección temprana de podredumbres en cítricos es muy escasa.

Los sistemas hiperespectrales se caracterizan por adquirir un número amplio de imágenes monocromáticas de la misma escena en diferentes longitudes de onda. El conjunto de imágenes monocromáticas adquiridas constituye una imagen hiperespectral. Estas imágenes se caracterizan por aportar información espacial de la escena (como los sistemas clásicos de visión) así como información espectral de la misma. Los sistemas hiperespectrales de visión cuentan con dos partes claramente diferenciadas: un sistema de adquisición de imagen (CCD, acrónimo de *Charge Coupled Device*) y un sistema responsable de la selección de la longitud de onda de la radiación que incide en el CCD. La característica fundamental de estos filtros es que se puede controlar la frecuencia de la radiación que transmiten los mismos. Existen varios tipos de filtros que realizan esta misión, los más destacables son: los espectrofotómetros de imagen, los AOTF (*Acoustic-Optic Tunable Filters*) y los LCTF (*Liquid Crystal Tunable Filter*) (Poger and Angelopoulou, 2001). Los espectrofotómetros basan su funcionamiento en las características de dispersión de las ondas electromagnéticas en medios materiales y suelen ser utilizados en aplicaciones en las que la adquisición de imagen de la escena se realiza línea a línea, esto es, que cada imagen capturada por la matriz CCD contiene la información espectral de una línea de la escena. El principal inconveniente de este tipo de sistema de selección de frecuencia es que requiere del movimiento relativo de la escena adquirida respecto del sistema de adquisición. Por el contrario los AOTF y los LCTF son capaces de adquirir una imagen monocromática completa de la escena, sin necesidad de realizar un barrido en frecuencias completo. Los AOTF basan su funcionamiento en las propiedades piezoeléctricas de los materiales. Se construyen uniendo transductores piezoeléctricos a un material cristalino apropiado. Excitando los transductores con la radiofrecuencia adecuada se producen perturbaciones en el material que interaccionan con los fotones, proporcionando así la capacidad de selección en frecuencia (Bei et al., 2004). Los dispositivos de selección en frecuencia empleados en este trabajo son filtros de cristal líquido sintonizable, también denominados LCTF. Éstos basan su funcionamiento en la combinación de filtros de Lyot. Estos filtros están constituidos por una estructura de *sandwich* de una lámina de cristal líquido, y una lámina de cuarzo entre dos polarizadores lineales (Hetchts, 1998) (ver figura 1.5). Las láminas de cuarzo y de cristal líquido constituyen un retardador<sup>1</sup>. El principal éxito de los filtros de Lyot es controlar electrónicamente el ángulo característico del mismo, es decir se controla el proceso de interferencia entre los haces ordinarios y extraordinarios de la radiación electromagnética incidente, consiguiendo a la salida la selectivi-


---

<sup>1</sup>Un retardador es un dispositivo óptico que es capaz de rotar el plano de vibración de la luz, que en definitiva es una onda electromagnética.

dad en frecuencia deseada en la radiación transmitida (Hetchts, 1998). Un LCTF está constituido por una serie de filtros de Lyot apilados para conseguir el rango y la selectividad en frecuencia deseada.

#### 1.1.4. Cadena de preprocesado de imágenes hiperespectrales

Las imágenes hiperespectrales constituyen una fuente de información mucho más amplia que una imagen convencional. Una imagen hiperespectral está constituida por un conjunto de imágenes monocromáticas (variando en número en función de la resolución del sistema utilizado), que se unen formando un *hipercubo*, en el que dos dimensiones constituyen las dimensiones espaciales y la tercera componente la espectral (ver figura 1.6). Este hecho, que por una parte es uno de los grandes atractivos de los sistemas hiperespectrales, puede convertirse, sin el tratamiento adecuado, en un problema, ya que en general estas imágenes presentan mucha información redundante o que no es discriminante en el problema de clasificación estudiado (Shaw and Burke, 2003).

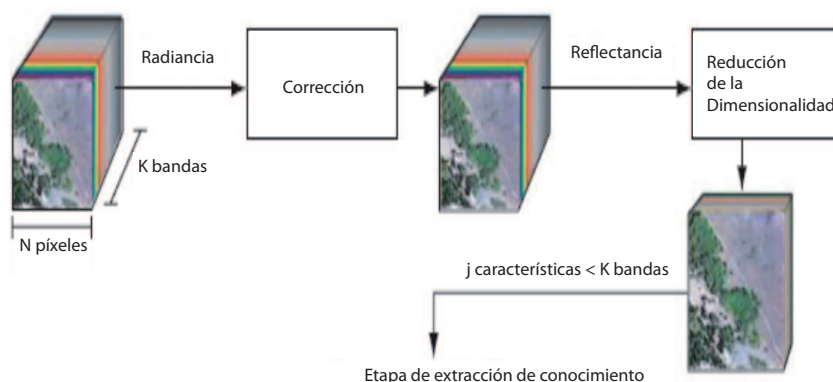


**Figura 1.5:** Esquema de un filtro de Lyot de una sola etapa.

Otro detalle a tener en cuenta es que cuando se analizan imágenes hiperespectrales en bruto, se está analizando la radiancia de la escena, cuando en general, se desea conocer la reflectancia de la misma. Por estas dos razones, cuando se adquiere una imagen hiperespectral, es necesario en primer lugar realizar las compensaciones oportunas (en la medida de lo posible en cada problema) para determinar la reflectancia de la escena a partir de la radiancia y aplicar técnicas para reducir la cantidad de información que aporta una imagen hiperespectral. En la figura 1.6 se muestra un protocolo general para el pretratamiento de imágenes hiperespectrales.

La naturaleza de la compensación para obtener la reflectancia variará dependiendo del modo de adquisición de las mismas. Si la imagen hiperespectral se adquiere desde un satélite se tendrá en





**Figura 1.6:** Esquema del tratamiento previo de una imagen hiperespectral antes de su análisis (Shaw and Burke, 2003).

cuenta los efectos dispersivos de la atmósfera (Shaw and Burke, 2003). Si por el contrario la iluminación de la escena se realiza de modo controlado (en una campana de inspección como la que se ha desarrollado en este trabajo) y se conoce la forma del objeto presente en la escena, la compensación se realizará mediante el uso de un *blanco de referencia* y el *modelo de elevación digital* correspondiente a la forma del objeto.

En cuanto a la reducción de la dimensionalidad del problema, existen técnicas estadísticas para conseguir este propósito. Estas técnicas pueden ser de tipo no supervisado como el análisis de componentes principales (PCA) (Jolliffe, 1986), o de tipo supervisado como el análisis discriminante lineal (LDA) (Cheng et al., 2004). El uso de un tipo de técnicas u otras estará condicionado a la información disponible sobre las clases presentes en el problema.

Otro punto de vista a la hora de definir los métodos de reducción de la dimensionalidad, consiste en clasificarlos desde el punto de vista del modo en que realizan su propósito. La dimensionalidad del problema se puede reducir de dos maneras, mediante la selección de características (Kohavi and John, 1997; Blum and Langley, 1998; John et al., 1994) o la extracción de características (Liu and Motoda, 1998a). La extracción de características consiste en obtener un espacio vectorial transformado, que mantenga la estructura de los datos, cuya dimensión sea menor que la del espacio original. El inconveniente de estos métodos es que se necesita disponer de todas las características del espacio original para su cálculo y posterior empleo. La selección de características consiste en obtener un número reducido de características del espacio vectorial original que contengan la máxima información acerca del problema estudiado. La selección de características constituye un problema abierto en el entrenamiento y construcción de clasificadores. Es imprescindible, antes de construir un clasificador, encontrar las características más significativas. De no

ser así las características no significativas pueden introducir ruido en la clasificación produciendo resultados sin sentido. Esto se ve acentuado en problemas en los que el número de características es muy elevado y está directamente relacionado con el fenómeno conocido en la bibliografía como *curse of dimensionality* (Hughes, 1968), por el cual, un número elevado de características produce modelos subóptimos. Además, en este trabajo se emplearán estas técnicas con otra finalidad, determinar un número reducido de bandas que permita caracterizar el problema de la detección de podredumbres en cítricos. La implementación de un sistema en línea es imposible sin una reducción considerable del número de bandas que proporciona un sistema hiperespectral. Por tanto, el sistema final debe ser compacto en número de bandas y en acierto de clasificación. Estos dos condicionantes, y el equilibrio entre ambos, se deben tener siempre en mente con el fin de desarrollar un sistema realizable y útil.

## 1.2. Organización de la Tesis Doctoral

Esta Tesis Doctoral se ha organizado en 6 capítulos. El capítulo 1 realiza una introducción general al problema tratado. El capítulo 2 describe profundamente el sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido desarrollado en el ámbito de esta Tesis Doctoral. A pesar de ello, en la sección de materiales y métodos de cada uno de los siguientes capítulos, se ha incluido unos párrafos describiendo brevemente el sistema de visión hiperespectral y las peculiaridades de configuración del mismo para los ensayos realizados en cada capítulo con el fin de que el lector conozca en cada ensayo los elementos del sistema que intervienen y sus características.

En el capítulo 3 se propone una metodología novedosa de preprocesado de imágenes hiperespectrales para minimizar los efectos adversos que introduce la curvatura esférica del cítrico. En el capítulo 4 se han planteado una serie de ensayos de detección de podredumbres producidas por el hongo *Penicillium digitatum* con el fin de evaluar el comportamiento general del sistema y sondear la naturaleza del problema a tratar. El capítulo 5 muestra una revisión y ampliación del problema tratado en el capítulo anterior en cuanto al número de defectos empleados (*trips* y *rameados*), los hongos que producen la podredumbre (*Penicillium digitatum* y *Penicillium italicum*), la inclusión de información espacial del píxel a clasificar, las técnicas de aprendizaje automático empleadas y el clasificador de fruta desarrollado. Por último en el capítulo 6 se exponen las principales contribuciones del trabajo, las conclusiones particulares y generales extraídas tras los ensayos realizados así como la proyección futura de la Tesis Doctoral y los hitos científicos y tecnológicos alcanzados en forma de artículos en revista internacionales y patentes en explotación.

Cada uno de los capítulos de esta Tesis Doctoral excepto el primero (Introducción general) y el último (Conclusiones) es autocontenido en el sentido de que contiene cada una de las secciones

habituales que se puede encontrar en un artículo científico (introducción, materiales y métodos, resultados y conclusiones). Esta división del trabajo realizado atiende únicamente a criterios de claridad en la exposición global del trabajo realizado. Los contenidos de esta Tesis Doctoral tratan aspectos tan diversos como el *hardware* y puesta a punto del sistema de visión hiperespectral, el preprocesado de imágenes hiperespectrales o el análisis de imágenes de frutos cítricos dañados por podredumbres. Los capítulos presentados por separado muestran los ensayos y resultados parciales de las diferentes etapas naturales por las que ha transcurrido la investigación desarrollada en el ámbito de esta Tesis Doctoral y, analizados globalmente ponen de manifiesto la completitud del trabajo de investigación realizado en esta Tesis Doctoral.

### 1.3. Objetivos de la Tesis Doctoral

En el Centro de AgroIngeniería del Instituto Valenciano de Investigaciones Agrarias (IVIA), se ha trabajado y continúa trabajando, a través de distintos proyectos de investigación (FEDER-CICYT DPI-2003-09173-C02-0 y FEDER-MEC (DPI2007-66596-C02-02), en el desarrollo de técnicas avanzadas de visión por computador para la identificación de los defectos externos de los cítricos. Esta Tesis Doctoral está enmarcada en el ámbito de esos proyectos y se ha centrado en el desarrollo de un sistema de adquisición de imágenes hiperespectrales, basado en filtros sintonizables de cristal líquido (LCTF) y las técnicas necesarias para el posterior análisis de las mismas, como herramienta para identificar automáticamente los daños producidos por podredumbres comunes (*Penicillium digitatum* y *Penicillium italicum*) .

Además, parte del trabajo se enmarca en la colaboración que el centro de AgroIngeniería del IVIA mantiene con diversos investigadores del Grupo de Procesado Digital de Señales (GPDS) del departamento de Ingeniería Electrónica de la Universidad de Valencia. En concreto en el programa de "Grups Emergents" de la Generalitat Valenciana HYPERCLASS/GV05/011 en el que se establece, como aplicación fundamental, el control de la calidad fitosanitaria de frutos en centrales postcosecha mediante el empleo de técnicas de selección de características y clasificadores avanzados.

El principal objetivo de este trabajo es identificar daños producidos por podredumbres comunes en cítricos utilizando un sistema multispectral automático y un conjunto de técnicas derivadas del aprendizaje automático. Para ello, se ha implementado un sistema de visión hiperespectral basado en filtros de cristal líquido sintonizables con el fin de adquirir las imágenes hiperespectrales que serán utilizadas para evaluar las técnicas empleadas y evaluar el rendimiento de las diferentes metodologías propuestas en esta Tesis Doctoral. Este objetivo general se puede dividir en los siguientes hitos:

- 1. Desarrollar un sistema de visión hiperespectral basado en LCTF.** En este trabajo se construirá un sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido, a partir de sus elementos fundamentales. Se diseñarán todos los elementos *hardware* necesarios para albergar el sistema de adquisición, los filtros sintonizables de cristal líquido, y el sistema de iluminación. Se desarrollará el *software* para el control del sistema de visión hiperespectral completo a través de una aplicación informática con interfaz gráfica de fácil manejo. Asimismo, se caracterizará el sistema de visión hiperespectral con el fin de conocer las posibles limitaciones de funcionamiento que ofrece el mismo. A partir del análisis del sistema, se determinarán los parámetros de funcionamiento del mismo.
- 2. Desarrollar métodos de preprocesado de imágenes hiperespectrales de cítricos.** Se desarrollarán técnicas para obtener la reflectancia de los cítricos a partir de la radiancia captada por el sistema de visión hiperespectral. Estas técnicas se centrarán principalmente en corregir las variaciones espaciales que introduce el sistema de iluminación en la adquisición de imagen. Para ello se desarrollará un novedoso modelo de elevación digital (DEM) para preprocesar las imágenes hiperespectrales. A partir de este modelo se estudiará el modo de tener en cuenta la geometría de cada cítrico para obtener las propiedades reflectivas del mismo.
- 3. Desarrollar técnicas de análisis de imágenes hiperespectrales para detectar daños producidos por podredumbres en cítricos.** Estos ensayos se realizarán sobre varias variedades de mandarinas y el objetivo de los mismos será detectar podredumbres producidas por *Penicillium digitatum* en diferentes momentos de la infección (podrido temprano y podrido esporulado). En estos ensayos se utilizarán frutas con un único estado de maduración y sin presencia de otros defectos superficiales. Asimismo, estos ensayos se emplearán para evaluar la idoneidad de los sistemas de iluminación desarrollados. En el ámbito de estos ensayos se utilizarán un número amplio de técnicas de selección de bandas y de clasificación de carácter no supervisado y supervisado. Se determinará, con el montaje realizado, cuál es el número óptimo de bandas para maximizar el éxito en la segmentación de imagen. Finalmente, se elaborará un modelo de segmentación de imágenes hiperespectrales de mandarinas con el mejor método de selección y con el mejor clasificador de entre todos los estudiados. Con las imágenes segmentadas se elaborará un sistema automático para la detección de daños producidos por *Penicillium digitatum* en mandarinas.
- 4. Desarrollar un sistema de clasificación de cítricos con daños comunes y producidos por *Penicillium digitatum* y *Penicillium italicum*.** Con las conclusiones extraídas en los ensayos previos, se focalizarán los esfuerzos hacia mejorar la capacidad del sistema para detectar podridos producidos *Penicillium digitatum* y ampliar el rango de

defectos detectables (daños producidos por *trips*, rameados y *Penicillium italicum*) y clasificarlos en frutos con diferentes estados de maduración. Para ello se trabajará en mejorar el sistema de iluminación así como evaluar otras técnicas de selección y clasificación. El estudio de selección de bandas se utilizará para determinar las regiones del espectro que contienen conocimiento sobre el problema de clasificación propuesto. Los clasificadores se utilizarán para elaborar modelos de segmentación de imagen y evaluar los grupos de bandas obtenidos. La finalidad última es proponer un protocolo de clasificación de podredumbres (selección, segmentación y clasificación) y estudiar la viabilidad de implementarlo en un sistema de visión multispectral a medida basado en el conocimiento extraído.



## Capítulo 2

# Sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido

### 2.1. Introducción

El uso de la visión por computador en la región visible del espectro electromagnético para la evaluación de la calidad y la detección de daños en cítricos está ampliamente extendida (Blasco et al., 2007b; Pydipati and Lee, 2006; Blasco et al., 2003, 2009a). No obstante, determinadas características organolépticas y algunos tipos de defectos no son fácilmente caracterizables utilizando sistemas de visión RGB como por ejemplo los podridos en estadíos tempranos de la infección. Una manera de mejorar la eficacia de los sistemas de clasificación y la detección de todo tipo de defectos se ha encaminado hacia la ampliación de la región del espectro en la que se observa utilizando sistemas multiespectrales (Aleixos et al., 2002; Blasco et al., 2007a, 2009b). Este tipo de sistemas se caracteriza por emplear más bandas que las habituales RGB, pero no están indicados para realizar ensayos espectrométricos ya que no permiten explorar de manera sistemática una región amplia del espectro.

Las técnicas espectrométricas se han mostrado eficaces para caracterizar defectos superficiales en cítricos (Gaffney, 1973). Este tipo de técnicas se pueden clasificar en tres tipos: fluorescencia, absorción y reflexión. Las técnicas espectrométricas basadas en fluorescencia se caracterizan por estudiar la luz emitida por objeto bajo estudio, cuando la superficie del mismo ha sido excitada con una radiación externa. Este tipo de técnicas se ha mostrado eficaz para determinar características intrínsecas de los cítricos (Latza and Ernes, 1978; García-Reyes et al., 2006), no

obstante los equipos empleados son muy caros y presentan poca versatilidad para su uso intensivo. Las técnicas espectrométricas basadas en absorción se basan en estudiar la radiación transmitida por una muestra al ser iluminada, no obstante el uso de este tipo de técnicas está limitado por la opacidad de la muestra cuando se trata de un objeto como un cítrico y es ampliamente utilizada en su aplicación sobre muestras líquidas como por ejemplo zumos de naranja (Sun, 2009). Las técnicas espectrométricas basadas en propiedades reflectivas son más utilizadas para evaluar parámetros de calidad en cítricos (Qin et al., 2009; Cayuela, 2008; Okamoto and Lee, 2009; Gómez-Sanchis et al., 2008b). Este tipo de técnicas se caracteriza por estudiar la reflectancia obtenida a partir de instrumentos espectrométricos. Estos instrumentos pueden ser de dos tipos: espectrómetros de laboratorio y espectrómetros de imagen. Los primeros se caracterizan por presentar resoluciones espectrales muy elevadas (resoluciones menores al nanómetro), no obstante, estos instrumentos generalmente no pueden analizar regiones extensas de una muestra y su uso se restringe al de laboratorio. Los segundos son los denominados espectrómetros de imagen, estos presentan resoluciones espectrales mucho menores (mayores o iguales a 10 nm) y presentan la capacidad de analizar muestras extensas como por ejemplo la superficie de un cítrico.

Los primeros sistemas de este tipo utilizados para el análisis de las propiedades reflectivas de fruta se podían considerar como sistemas multispectrales de adquisición de imagen. Estos sistemas consistían en una serie de filtros interferométricos acoplados en una rueda montada entre una cámara monocromática y la escena que, mediante un sistema mecánico, giraba permitiendo la adquisición de imágenes monocromáticas en diferentes bandas. Este tipo de sistemas presentaba inconvenientes como la baja velocidad de adquisición de la imagen multispectral y el bajo número de bandas espectrales adquiridas. En los últimos años, la tecnología de los espectrómetros de imagen ha experimentado grandes avances, este hecho ha permitido grandes avances en campos como el sensado remoto por satélite o las aplicaciones de la visión por computador hiperespectral. Actualmente se emplean tres tipos sistemas para construir un sistema de visión hiperespectral en la inspección de fruta: los espectrofotómetros de imagen, los AOTF y los LCTF . Los primeros basan su funcionamiento en las características de dispersión de las ondas electromagnéticas en medios materiales y se caracterizan por adquirir las características espectrales de la escena línea a línea mediante el movimiento relativo de la escena respecto al instrumento. Estos sistemas presentan una buena resolución espectral, pero no permiten adquirir la imagen completa sin sincronizar adecuadamente la adquisición de imagen con el movimiento de la muestra mediante un *encoder*. Los sistemas basados en AOTF se caracterizan por presentar buenos tiempos de sintonización (en torno a 50 ms) y una buena selectividad en frecuencia. El principal inconveniente que presentan este tipo de sistemas radica en que el campo de visión de los mismos es reducido debido al pequeño tamaño del cristal utilizado en este tipo de filtros. La principal ventaja de los sistemas basados en LCTF frente a los anteriores es que son más compactos y ofrecen un campo de visión más amplio.



No obstante como principal inconveniente destacar que el tiempo de sintonización es más elevado (en torno a 250 ms).

Los ensayos realizados en esta Tesis Doctoral se han realizado utilizando un sistema de visión hiperespectral basado en LCTF, la principal razón que ha motivado la elección de estos filtros es que son más compactos y ofrecen un campo de visión mayor que los AOTF, esto es necesario ya que una campana de inspección típica presenta distancias cortas entre la cámara y la escena. Para llevar a cabo los experimentos realizados en esta Tesis Doctoral, se ha diseñado y desarrollado un sistema de visión por computador hiperespectral a partir de sus componentes fundamentales, tales como cámara de adquisición, filtros sintonizables de cristal líquido y sistema de iluminación. La adquisición de imágenes hiperespectrales con un sistema como el presentado en este capítulo presenta una serie de problemas inherentes a la propia estructura del sistema. Estos problemas están relacionados con cuestiones tales como el empleo de dos filtros y la sincronización de la adquisición de imagen con la sintonización de los filtros. La adquisición de todo el rango espectral que proporcionan los dos filtros sintonizables, uno para la región visible y otro para el infrarrojo cercano, requiere de un montaje que permita utilizar los dos filtros simultáneamente sin necesidad de montar y desmontar cada uno de los filtros en cada adquisición, cosa que imposibilitaría la adquisición sistemática de imágenes hiperespectrales. Por otra parte, es necesario sintonizar los filtros en cada una de las bandas de interés y que en ese momento se realice una captura del sistema de adquisición para adquirir la correspondiente imagen monocromática. Las aplicaciones *software* proporcionadas por los fabricantes de los filtros y la cámara no permiten la sincronización de ambos elementos ni la adquisición de una imagen hiperespectral completa (conjunto de imágenes monocromáticas en el rango espectral definido).

Además, es necesario realizar una adecuada selección de determinadas partes del sistema como la óptica de la cámara, la fuente de iluminación empleada o el sistema de alimentación eléctrico utilizado para alimentar el sistema de iluminación. Las labores realizadas van encaminadas a solventar estos problemas y engloban tareas como el diseño y montaje de la campana de inspección,<sup>1</sup> el montaje del *hardware* de adquisición y LCTF, el desarrollo de *software* específico de manejo, el control y sincronismo de los diferentes elementos del sistema y la determinación de los parámetros de funcionamiento del sistema de visión hiperespectral tales como el tiempo de precalentamiento del sistema de iluminación o los tiempos de integración del CCD en la adquisición de cada banda.

---

<sup>1</sup>La campana de inspección está constituida por la propia campana de inspección, sistemas de guiado de la cámara y los filtros LCTF, un sistema difusor lumínico, así como el sistema de alimentación eléctrica.

## 2.2. Objetivos en la implementación del sistema de visión

El propósito de este capítulo de la Tesis Doctoral es describir las especificaciones de diseño y funcionamiento del sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido desarrollado, así como caracterizar la respuesta espectral de los mismos. Este objetivo engloba aspectos relativos al diseño y las características del sistema y se puede dividir en una serie de objetivos específicos.


1. **Sistema de posicionamiento de la cámara y filtros.** Se diseñará e implementará un sistema de posicionamiento para la cámara y los filtros sintonizables. Este sistema facilitará la adquisición sistemática de imágenes hiperespectrales.
2. **Sistemas de iluminación.** Se evaluarán diferentes tipos de sistemas de iluminación (variando la geometría de los mismos) con el objetivo de determinar el que más se adecua a la adquisición de imágenes de cítricos.
3. **Caracterización del sistema de visión hiperespectral.** Se caracterizará la respuesta espectral de cada uno de los elementos del sistema, así como la respuesta global del sistema completo, con el objetivo de determinar el rango óptimo de trabajo del sistema.
4. **Desarrollo de una aplicación informática.** Otro objetivo fundamental para la adquisición sistemática de imágenes hiperespectrales será el desarrollo de una aplicación informática y un *software* para el control del sistema de visión hiperespectral. Este *software* se encargará de labores de sincronización, selección de parámetros de funcionamiento e interfaz con el usuario.
5. **Determinación de los parámetros de funcionamiento del sistema.** Mediante una serie de ensayos se obtendrán los parámetros de funcionamiento del sistema de visión hiperespectral tales como el tiempo de precalentamiento del sistema de iluminación o los tiempos de integración del sistema en cada banda. Finalmente, se propondrá una metodología para la adquisición de imágenes hiperespectrales con el sistema implementado.

## 2.3. Materiales y métodos

### 2.3.1. Campana de inspección

La primera tarea consiste en diseñar una campana de inspección que sea lo más versátil posible, en el sentido de albergar varios tipos de iluminación, poder incluir diferentes tipos de cámaras y que se adecúe a un transportador de fruta de rodillos bicónicos propiedad del IVIA.

La campana de inspección se ha realizado en acero inoxidable (ver figura 2.1a) con dos puertas laterales para facilitar el montaje y desmontaje de los sistemas de adquisición e iluminación. La movilidad de la campana se ha conseguido mediante cuatro ruedas y un sistema de anclaje al transportador. Otro detalle a tener en cuenta en el diseño de la campana es el probable calentamiento producido por el sistema de iluminación. El aumento de temperatura debido a la falta de ventilación de la campana cuando estuviera cerrada podría dañar los elementos del sistema de visión hiperspectral (LCTF, cámara o el propio sistema de iluminación). Se han instalado cuatro ventiladores de 20W 220/AC (figura 2.1b) situados en la parte superior de la campana que permiten la extracción del aire caliente acumulado.



**Figura 2.1:** a) Detalle de la campana de inspección antes de ser instalada en el transportador de rodillos. b) Dos de los cuatro ventiladores instalados en la campana de inspección para refrigerar la misma. c) Campana de inspección ya acoplada al transportador de rodillos.

Una vez construida la campana de inspección e instalada en el transportador de rodillos biconicos (ver figura 2.1c) se ha estudiado la instalación física de los elementos del sistema de visión hiperspectral (cámara y LCTF) mediante soportes de sustentación y guiado. Dichos elementos de soporte deben cubrir las siguientes funcionalidades:

- El soporte de la cámara debe permitir cualquier desplazamiento de la misma en el plano de la escena, con el fin de centrar la cámara en la región de interés. Para ello se ha diseñado un sistema de guías que permite desplazar la cámara para ajustar su posición, además de un sistema de fijación para evitar desplazamientos no deseados.
- La campana de inspección se ha diseñado para albergar dos filtros LCTF, cada uno de ellos sensible en una región del espectro electromagnético. Se debe de poder adquirir una imagen hiperspectral de la misma escena en el rango espectral proporcionado por cada uno de los

filtros sin variar la geometría de la escena. Para ello se ha diseñado un sistema de guiado que permite emplear cualquiera de los dos filtros en una adquisición, sin necesidad de complejos montajes para intercambiar los filtros cada vez que se quiera utilizar uno de ellos (ya que imposibilitaría la adquisición sistemática de imágenes hiperespectrales). Es necesario que su manipulación no afecte a la cámara para evitar cambios en la escena adquirida.

- La iluminación utilizada está compuesta por lámparas halógenas que producen una iluminación puntual y, por tanto, puede producir brillos indeseados en la superficie del fruto (esta decisión está justificada en la sección 2.3.2). Por lo tanto es necesario diseñar, montar y probar una serie de campanas de iluminación con diferente geometría para minimizar los efectos indeseados producidos por este tipo de iluminación.

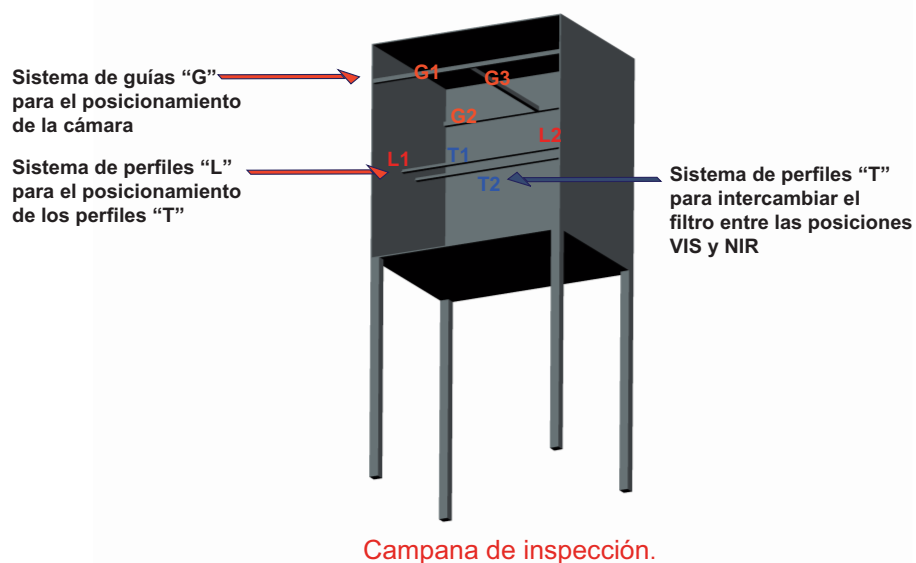
Cada una de las especificaciones descritas anteriormente, se ha cubierto mediante una serie de subsistemas diseñados a medida. La descripción de los mismos se detalla en las siguientes secciones.

### **Sistema de posicionamiento de la cámara**

Siguiendo las especificaciones de diseño de la campana de inspección, la cámara debe poder ubicarse en cualquier posición del plano de la escena con el fin de realizar ajustes de la posición de la región de interés que se desea adquirir. Con esta finalidad, se diseñó un sistema de guías ubicado en la parte superior de la campana de inspección. El esquema completo del sistema de guiado se muestra en la figura 2.2.

El sistema de guías consta de cuatro tubos de acero galvanizado de  $20 \times 20$  mm, dos de ellos (G1 y G2) ubicados de manera longitudinal en la parte superior de la campana. El tercer tubo (G3) se ha colocado transversalmente mediante dos correderas sobre los dos tubos anteriores, de esta manera la cámara se puede desplazar a lo largo de la dirección longitudinal de la campana de inspección. El cuarto tubo (G4) se ha colocado, a modo de soporte de la cámara, sobre el tubo G3 mediante una corredera que permite el movimiento de la cámara en la dirección transversal de la campana de inspección. Finalmente, en el tubo (G4) se ha colocado un perfil (P1) de 200 mm de longitud, con una guía en su parte central que permite el movimiento de la cámara en la dirección perpendicular al plano de la escena para aumentar o disminuir el campo de visión de la cámara.

En la figura 2.3 se observa el sistema de guiado ya montado sobre la campana de inspección, como se puede observar en la misma figura el mismo sistema sirve además como soporte para los módulos de control de los LCTF.



**Figura 2.2:** Esquema del sistema de posicionamiento de la cámara en el interior de la campana.




**Figura 2.3:** a) Guías G1 y G2 responsable del movimiento en la dirección longitudinal a la campana. b) Guías G3 y G4 responsables del movimiento de la cámara en la dirección transversal a la campana de inspección. La guía del perfil P1 permite variar la altura de la cámara sobre la escena.

### Sistema de guiado de los LCTF

Una vez colocado en la campana de inspección el sistema de guiado de la cámara, se ha diseñado un sistema para albergar los LCTF en la campana de inspección. Cada uno de los filtros

sintonizables ha sido diseñado por el fabricante para que se acople a una cámara y funcione de manera individual, limitándose el rango espectral de adquisición. El uso de cada filtro por separado (como sugiere el fabricante) incapacitaría al usuario del sistema para adquirir imágenes hiperespectrales de la misma escena de manera sistemática. Así pues, es necesario que el sistema portafiltros pueda ser capaz de alojar los dos LCTF que van a ser utilizados y permita un rápido intercambio de un filtro a otro mediante un sencillo movimiento, sin alterar la geometría de adquisición de la escena.


Para conseguir este objetivo se ha diseñado un caja portafiltros realizada en metacrilato que aloja los dos filtros. Dicha caja puede desplazarse por dos guías de aluminio entre dos finales de carrera que delimitan la posición exacta de cada filtro justo debajo de la óptica. Así pues se puede cambiar de un filtro a otro simplemente desplazando el portafiltros de un final de carrera a otro.



**Figura 2.4:** Diseño 3D de la caja portafiltros.


Primero se realizó el modelado 3D de la caja portafiltros (figura 2.4). En dicho diseño se tuvieron en cuenta detalles como la creación de salidas de cables de control de cada uno de los filtros en los laterales de la caja, que además permiten una correcta refrigeración de los filtros (ver figura 2.5b). También se observa en la misma figura la creación de dos celdas de sujeción para cada filtro en el interior del portafiltros, que junto con la cubierta superior, evita cualquier tipo de movimiento de los filtros (figura 2.5a).





**Figura 2.5:** a) Portafiltros con los dos LCTF instalados y cubierta superior. b) Detalle de apertura lateral para salida de cables, así como celdas de sujeción de ambos filtros.

El sistema de guiado del portafiltros consta de dos perfiles con forma de T (T1 y T2) de aluminio de  $20 \times 20$  mm. Los perfiles de aluminio descansan sobre dos perfiles con forma de L (L1 y L2) de acero galvanizado de  $20 \times 20$  mm colocados transversalmente en los extremos de la campana de inspección (figura 2.6a), a la altura necesaria para que, cuando esté colocado el portafiltros, éste se encuentre al nivel de la cámara.



**Figura 2.6:** a) Detalle de las guías en T (T1 y T2) y el soporte de las mismas (L1). b) Sistema de guiado y portafiltros ya colocados en la campana de inspección. c) Ajuste final de la cámara con el portafiltros.


La distancia de separación de los perfiles de aluminio coincide con el ancho del portafiltros. De este modo se puede desplazar por los mismos entre dos finales de carrera, que delimitarán las posiciones de alineación de ambos filtros con la vertical de la cámara. En la figuras 2.6b) y 2.6c) se muestra el sistema de guiado junto con el portafiltros ya montado y la alineación entre el portafiltros y la cámara una vez ajustados todos los sistemas de posicionamiento.

### 2.3.2. Sistema de iluminación

Con el fin de evaluar cuál es el sistema de iluminación más adecuado desde el punto de vista espectral y geométrico, se han instalado tres sistemas de iluminación diferentes en la campana de inspección; uno basado en tubos fluorescentes, otro basado en iluminación halógena con un sistema difusor cilíndrico y, por último, otro basado en iluminación halógena con difusor semiesférico. En los ensayos de esta Tesis Doctoral se han utilizado los dos últimos, descartando el primero en ensayos preliminares, por su baja eficiencia espectral en el infrarrojo. La implementación final de estos dos sistemas de iluminación ha sido fruto de una evolución gradual, en base a la experiencia obtenida en los diferentes ensayos de obtención de imágenes hiperespectrales de esta Tesis Doctoral. Las imágenes adquiridas para los ensayos de los capítulos 3 y 4 se han adquirido utilizando el sistema de iluminación con difusor cilíndrico. A partir de la experiencia adquirida, se diseñó el sistema de iluminación con difusor semiesférico que se empleó para adquirir las imágenes del ensayo planteado en el capítulo 5.

#### Sistema de iluminación basado en tubos fluorescentes

Este tipo de iluminación fue el primero en ser montado en la campana de inspección debido a que proporciona iluminación uniforme desde el punto de vista espacial, y además es un sistema de iluminación ampliamente utilizado en los sistemas de visión por computador utilizados por la industria. La implementación de este sistema de iluminación se realizó mediante dos paneles colocados en cada una de las puertas de la campana de inspección. En cada panel se ubican 8 tubos fluorescentes Osram Biolux 18 W para iluminar la escena de manera uniforme (figura 2.7). Los tubos fluorescentes están alimentados por reactancias electrónicas de alta frecuencia (3.5 KHz) para evitar parpadeos en la adquisición de las imágenes hiperespectrales.



**Diseño 3D del sistema de iluminación basado en tubos fluorescentes.**

**Figura 2.7:** Esquema de la campana de iluminación con tubos.



Tras una serie de ensayos preliminares se descartó el empleo del mismo por la pobre eficiencia espectral que proporciona en la región infrarroja del espectro electromagnético. Con el fin de no modificar el diseño de la campana de inspección se decidió dejar instalado este sistema de iluminación para futuros experimentos de fluorescencia basados en el empleo de luz ultravioleta. En la figura 2.11b), se puede observar el detalle los tubos de luz UV colocados para ensayos preliminares de obtención de fluorescencia.

### Campana de iluminación con difusor cilíndrico


Esta campana de iluminación se utilizó en los experimentos planteados en los capítulos 3 y 4 de este trabajo. Para implementar este tipo de iluminación, se diseñó un soporte sobre el que se instalaron 8 lámparas halógenas para iluminar la escena de manera semidirecta. Los focos halógenos son alimentados a 12 V DC mediante una fuente de alimentación estabilizada, con el fin de conseguir una iluminación uniforme en el tiempo.

El soporte consiste en un anillo de acero inoxidable de 240 mm de diámetro sobre el que se ha colocado 8 portalámparas del tipo G4 equiespaciados. El soporte se ubicó debajo del sistema de guiado de los filtros, y está sujeto por 4 tirantes de acero inoxidable roscados al sistema de guías de los LCTF, que permiten variar la altura del sistema de iluminación (figura 2.8). En el soporte se han instalado dos ventiladores para refrigerar la parte inferior de los filtros de cristal líquido sintonizables, para evitar daños debidos al elevado flujo de calor que proporcionan las lámparas halógenas utilizadas en el sistema de iluminación.




**Figura 2.8:** A la izquierda se muestra el diseño CAD del soporte del sistema de iluminación con difusor cilíndrico. A la derecha implementación física del soporte de la iluminación (con focos y ventiladores de refrigeración) ya instalada en la campana de inspección.


Corte a 1/4 de la campana de inspección cilíndrica



Corte a 1/4 de la campana de inspección cilíndrica (vista inferior)



Campana de Iluminación cilíndrica montada en la campana de inspección



Detalle de la zona interior de la campana de inspección cilíndrica




Figura 2.9: Diseño de la campana de iluminación cilíndrica y su alojamiento en la campana de inspección.

El soporte suministra luz directa sobre la escena de adquisición. Este tipo de iluminación proporciona brillos indeseados sobre la escena, además de poca homogeneidad en la iluminación de objetos con un pronunciado relieve. Con el fin de evitar los brillos y homogeneizar la iluminación,

se ha diseñado un sistema de difusión lumínica, mediante una campana difusora cilíndrica (figura 2.9). Para su implementación se empleó un tubo de fibra de 250 mm de diámetro interior, forrado con aluminio estucado para maximizar las reflexiones multidireccionales en su interior y homogeneizar la difusión de la iluminación. Se practicó una abertura de 150 x 150 mm en la campana para poder introducir objetos en la misma. Con el fin de no perder reflectividad en la zona de la abertura, se construyó una puerta abisagrada, realizada en el mismo material que el cuerpo de la subcampana, respetando la curvatura del cuerpo de la misma. Por último, se incluyeron unos deflectores de luz directa, que consisten en 8 pletinas de aluminio, plegadas a 135 grados, para evitar que la luz halógena incida directamente sobre el objeto iluminado. Para ello se colocó cada uno de estos deflectores sobre la parte superior del cuerpo de la campana, justo debajo de cada foco halógeno. En la figura 2.11a) se observa el montaje completo de esta campana de iluminación, con todos los soportes ya instalados.

Tras realizar varios ensayos de adquisición de imágenes hiperespectrales con esta campana de iluminación, se determinó que era necesario seguir trabajando en un sistema de iluminación que proporcionara luz de más calidad (en lo que se refiere al grado de difusión de la luz proporcionada). Se comprobó que la campana de iluminación cilíndrica reducía considerablemente los brillos en la escena respecto a la iluminación directa con halógenos. No obstante, en determinadas ocasiones seguían apareciendo brillos indeseados. En la siguiente sección se plantea el diseño de un sistema de iluminación basado en el empleo de una campana de iluminación semiesférica.

### **Campana de iluminación con difusor semiesférico**

Esta campana de iluminación ha sido la aproximación definitiva para resolver el problema de la iluminación del sistema hiperespectral empleado y se ha utilizado en los experimentos planteados en el capítulo 5. Para implementar este tipo de iluminación, se ha utilizado un soporte de material aislante del calor sobre el que se instalaron 10 focos halógenos, que iluminan la escena de manera indirecta mediante la reflexión en el difusor semiesférico. Los focos halógenos, al igual que en la campana anterior, están alimentados con una fuente de alimentación de 12 V DC estabilizada, con el fin de conseguir una iluminación uniforme en el tiempo. El soporte consiste en un anillo de baquelita 500 mm de diámetro sobre el que se han colocado 10 portalámparas del tipo G4 equiespaciados. El soporte se ha ubicado en la parte inferior de una campana semiesférica con el mismo diámetro, que a su vez está apoyada sobre bases rectangulares apilables que permiten variar la altura del sistema de iluminación (figura 2.11 b). En la parte superior del difusor semiesférico se practicaron dos orificios para instalar dos ventiladores para extraer el calor acumulado en la parte alta del domo<sup>2</sup> y así refrigerar la parte baja de los filtros de cristal líquido sintonizables.

---

<sup>2</sup>Domo.- Término empleado para designar una campana de iluminación semiesférica.



**Figura 2.10:** Diseño de la campana de iluminación esférica y su alojamiento en la campana de inspección.

Con este sistema de iluminación se han evitado brillos indeseados a la vez que se ha obtenido una iluminación mucho más homogénea que con el sistema anterior. En la figura 2.10 se muestra un esquema del sistema de iluminación propuesto. La parte interior del domo de aluminio se ha revestido con una pintura blanca para maximizar la reflectividad de la superficie. Además, el mencionado revestimiento presenta una textura rugosa que minimiza las reflexiones direccionales responsables de brillos. La campana semiesférica proporciona una luz de mucha más calidad en cuanto al grado de homogeneidad geométrica que la campana cilíndrica. La principal desventaja que presenta es que la intensidad lumínica que produce es menor que en el caso de la campana anterior, produciéndose un aumento en el tiempo de adquisición de la imagen hiperespectral. Este aumento de tiempo no es crítico, puesto que el sistema empleado no se ha diseñado para funcionar en tiempo real.

La propia geometría de la campana hace que la iluminación de objetos con relieve sea más uniforme que en el caso de la campana cilíndrica. En la figura 2.11b) se observa el montaje completo de la campana de iluminación semiesférica.



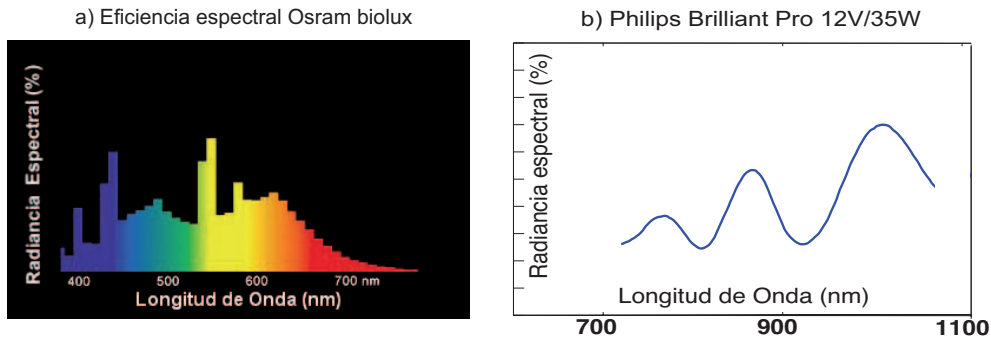
**Figura 2.11:** a) Campana de inspección montada al completo con todos los elementos ya instalados con a) la campana cilíndrica, b) la campana semiesférica.

### Respuesta espectral de los iluminantes

Un punto clave a la hora de escoger un iluminante es la respuesta espectral. Dependiendo de la aplicación y del rango espectral de trabajo es conveniente utilizar un tipo de iluminación u otro. Se descartaron varios tipos de iluminación que, *a priori*, proporcionarían un tipo de luz más uniforme como por ejemplo tubos fluorescentes tipo “luz día” por poseer bajas eficiencias en el infrarrojo cercano, como se observa en la figura 2.12a). En esta Tesis Doctoral, como ya se anticipó en la sección anterior, se ha utilizado iluminación basada en lámparas de filamento de tungsteno halógenas. En la campana cilíndrica se han utilizado diez lámparas halógenas *Philips*® Brilliantline Pro de 35W, capaces de proporcionar un haz de luz con una apertura de 30°. En la campana semiesférica se han utilizado lámparas de la misma familia de *Philips*® pero de menor potencia (20 W), incluyendo 2 lámparas más al montaje (12 lámparas en total). Estas lámparas proporcionan buenas eficiencias lumínicas, en la zona NIR del espectro electromagnético como se puede observar la eficiencia espectral en el infrarrojo proporcionada por el fabricante (figura 2.12b).

El sistema de iluminación se alimentó utilizando una fuente de alimentación 12V DC de 350W de potencia, debido a la necesidad de disponer de una alimentación estable a lo largo del tiempo. Se evaluó la posibilidad de alimentar el sistema de iluminación con reactancias convencionales de 12V

AC (las que recomienda el fabricante de las lámparas), pero dicha decisión hubiera motivado la aparición de parpadeos en la adquisición de imágenes hiperespectrales, modulados por la frecuencia de red de 50 Hz.



**Figura 2.12:** a) Caracterización espectral proporcionada por el fabricante del tubo fluorescente Osram Biolux 18W. En la figura se observa la baja eficiencia espectral al principio de la zona NIR del espectro electromagnético. b) Caracterización espectral NIR proporcionada por el fabricante de la lámpara Philips Brilliant Pro 12V/35W.

### 2.3.3. Hardware de adquisición


El *hardware* de adquisición es la parte del sistema de visión hiperespectral responsable de la captura de imágenes (cámara y óptica), y la digitalización de la señal que proviene de la cámara mediante la tarjeta de adquisición de datos. A continuación se detallará cada una de las partes del *hardware* de adquisición empleado.

Se ha empleado una cámara modelo CoolSnap ES de *Photometrics*<sup>©</sup>. La cámara Coolsnap ES, integra el CCD *Sony*<sup>©</sup> ICX285, que presenta un formato de matriz de  $1392 \times 1040$  píxeles, con un tamaño de píxel de  $6,45 \times 6,45 \mu\text{m}$ . Este CCD utiliza tecnología ITT (*Interline-Transfer Technology*), que proporciona elevadas eficiencias cuánticas tanto en el visible como en la zona NIR del espectro electromagnético<sup>3</sup>, como se observa en la figura 2.13a). No obstante, en esta figura se observa que la eficiencia cuántica del CCD decrece de manera crítica a partir de los 1030 nm. Esto impone una cota superior al rango de adquisición espectral del sistema visión hiperespectral. Por último, mencionar que la cámara posee un sistema de refrigeración termoeléctrico que mejora la sensibilidad de la misma frente al ruido térmico del CCD.

La tarjeta de adquisición de imagen utilizada es la suministrada por el fabricante junto con la cámara Coolsnap ES y es capaz de digitalizar las imágenes proporcionadas por la cámara con

<sup>3</sup>La eficiencia cuántica de los CCD de silicio en el infrarrojo cercano sin la tecnología ITT proporcionan eficiencias cuánticas mucho menores.

a) Eficiencia cuántica Coolsnap de Photometrics. b) Transmitancia Xenoplan 1.4/17 mm.



**Figura 2.13:** a) Curva de eficiencia cuántica (trazo discontinuo) en función de la longitud de onda de la cámara Coolsnap ES de *Photometrics*<sup>®</sup>, en modo alta sensibilidad. b) Transmitancia de la óptica Xenoplan 1.4/17 de *Schneider*<sup>®</sup> en función de la longitud de onda.

una resolución de 12-bits. La tarjeta de adquisición de imagen se instaló en un ordenador personal Pentium 4 2.8GHz con 512Mb de memoria RAM, junto con las librerías *software* de control de la cámara proporcionadas por el fabricante. El control del *hardware* de adquisición se realizó con *software* específico diseñado a medida para controlar y sincronizar todos los elementos del sistema de visión hiperespectral (*hardware* de adquisición y LCTF). Este aspecto será tratado en detalle en la sección 2.3.5.

En ensayos preliminares realizados con el sistema de visión hiperespectral se observó que, utilizando ópticas convencionales empleadas en visión por computador industrial, el foco de la imagen variaba considerablemente entre las bandas del visible y las del infrarrojo, obteniéndose imágenes desenfocadas en bandas alejadas de la de enfoque<sup>4</sup>. Este hecho es debido a la elevada dispersión cromática que presentan las ópticas convencionales. Para evitar este problema se utilizó una óptica Schneider modelo Xenoplan 1.4/17mm C-Mount, construida con lentes de baja dispersión para adquirir imágenes tanto en el visible como en el infrarrojo cercano (400 nm-1000 nm) sin variaciones significativas de enfoque. Además, la transmitancia de la óptica es prácticamente uniforme en todo el rango antes mencionado, como se muestra en la figura 2.13b).

<sup>4</sup>La banda de enfoque es aquella en la que se han hecho los ajustes de foco en el sistema hiperespectral y se emplea como banda de enfoque la banda central del rango de adquisición.



### 2.3.4. Filtros sintonizables de cristal líquido

La última parte del *hardware* del sistema de visión hiperespectral que queda por describir es la que atañe a los filtros de cristal líquido sintonizables. Un LCTF es un dispositivo electro-óptico constituido por una serie de polarizadores y láminas de cristal líquido. El funcionamiento de los mismos está basado en el principio físico de los filtros de Lyot, como se comentó en el capítulo de introducción. Los filtros sintonizables son la parte del sistema que permite seleccionar la frecuencia de la radiación que incide en el CCD. En este trabajo se emplearon dos filtros LCTF *Varispec*<sup>©</sup> de *Cambridge Research Institute* modelo VIS-07 y NIR-07. El primer filtro es sensible en la zona visible del espectro electromagnético (sintonizable desde 400 nm hasta 720 nm con una resolución de 7 nm @ FWHM <sup>5</sup>). El segundo LCTF trabaja en la zona del infrarrojo cercano (sintonizable desde 650 nm hasta 1100 nm con una resolución de 7 nm @ FWHM).

Antes de empezar a utilizar los filtros es importante realizar una caracterización espectral de los mismos, ya que los filtros sintonizables de cristal líquido presentan una eficiencia variable con la banda sintonizada. Se ha trabajado en la caracterización radiométrica de los filtros para obtener la transmitancia real de los dos filtros y poder definir el rango espectral óptimo en el que el sistema funciona correctamente. Para realizar la caracterización de ambos filtros se colaboró con investigadores de la Universidad de Valencia (Grupo de Procesado Digital de Señales del departamento de Ingeniería Electrónica) y de la Universidad Jaume I. La caracterización se llevó a cabo en un laboratorio de óptica de la Universidad Jaume I empleando un banco óptico de experimentación, una fuente de iluminación calibrada, un espectrómetro y elementos ópticos necesarios para focalizar el haz luminoso en toda la superficie del sensor del espectrómetro. La figura 2.14a) muestra el banco óptico utilizado para la caracterización de los filtros sintonizables, la figura 2.14b) muestra la posición del filtro de cristal líquido sintonizable en el banco óptico de trabajo, justo antes del espectrómetro.

La metodología de caracterización de cada filtro consta de una serie de pasos que se enumeran a continuación.

1. **Sintonizar el filtro en la banda que se desea caracterizar.** En el filtro VIS-07 se han caracterizado las bandas que van desde 400 nm hasta 720 nm con  $\Delta\lambda = 10$  nm. En el caso del filtro NIR-07 la caracterización se ha realizado desde 650 nm hasta 1030 nm con  $\Delta\lambda = 10$  nm. La razón por la que se caracterizó el filtro NIR-07 hasta 1030 nm fue que no se van a adquirir imágenes más allá de 1020 nm, puesto que la eficiencia cuántica del CCD utilizado decae drásticamente por encima de esa longitud de onda, como se mostró en la sección 2.3.3.

---

<sup>5</sup>FWHM: *Full Width at Half Maximum*. Este parámetro evalúa la selectividad en frecuencia del filtro.






**Figura 2.14:** a) Banco óptico con los elementos necesarios para caracterizar los filtros. b) Detalle de la colocación del filtro en el banco óptico.

2. **Adquirir el espectro de transmisión del filtro en cada banda.** De este modo se obtendrán las curvas espectrales de transmisión de los filtros (relativas al iluminante) en cada una de las bandas sintonizadas.
3. **Adquirir el espectro del iluminante utilizado.** De este modo se podrá obtener la transmitancia absoluta de cada uno de los filtros, haciendo el cociente entre los espectros obtenidos anteriormente y el espectro del iluminante.

### 2.3.5. *Software* específico de control del sistema de visión hiperespectral

Después de realizar ensayos preliminares con el sistema de visión hiperespectral utilizando el *software* proporcionado por el fabricante de la cámara y los LCTF, se concluyó que era necesario desarrollar elementos *software* de control integral y sincronismo de los principales elementos del sistema de visión hiperespectral: la cámara y los filtros sintonizables. Dichas acciones están justificadas por la necesidad de agilizar (sincronizar automáticamente los filtros y la cámara) y controlar parámetros del proceso de adquisición de las imágenes hiperespectrales (parámetros del barrido o tiempos de integración para cada banda). La estrategia empleada para corregir la variación de eficiencia por banda del sistema de visión ha sido adecuar los tiempos de integración por cada banda (sección 2.3.6). Para poder implementar todas las funcionalidades anteriores es necesario desarrollar *software* a medida, ya que los programas que proporcionan los fabricantes de filtros no las incluyen.



**Figura 2.15:** Interfaz gráfica del *software* **HyperSpectralCitrus** desarrollado, para la configuración y adquisición de imágenes hiperespectrales con el sistema de visión hiperespectral.

Todo el *software* se ha desarrollado en lenguaje de programación C, usando el entorno de programación *Microsoft*<sup>®</sup> *Visual C++ 6.0*. En primer lugar se desarrolló el *software* de control de la cámara empleando las librerías suministradas por el fabricante. Estas librerías contienen funciones de librería implementadas que proporcionan el modo de acceder a todas las funcionalidades que ofrece la cámara. Posteriormente se desarrolló el *software* de control de los filtros sintonizables de cristal líquido, a partir de las librerías proporcionadas por el fabricante. A continuación se implementó el *software* de sincronismo entre la cámara y el filtro, encargado de sincronizar la sintonización del filtro con la adquisición de la imagen monocromática en la banda sintonizada. A partir del *software* desarrollado se diseñó la aplicación informática **HyperSpectralCitrus** para el control y adquisición de imágenes con el equipo de visión hiperespectral (figura 2.15).

La principales características de la aplicación son:

- Inicialización automática de Cámara Coolsnap y filtros Varispec.
- Implementación de tres modos de adquisición y visualización: en vivo en banda única, captura de imagen en banda única y captura de imagen hiperespectral.
- Capacidad de control de dos filtros LCTF (VIS-07 y NIR-07) de Varispec.
- Implementación de cuatro modos de sintonización de los LCTF: selección de banda única, barrido configurable VIS-07, barrido configurable NIR-07 y barrido configurable mixto (VIS-07 y NIR-07).

- Posibilidad de modificar los tiempos de integración para cada longitud de onda, permitiendo programar barridos con distintos tiempos de integración para cada banda.
- Opciones de adquisición de blanco de referencia y negro de referencia para determinar la reflectancia del cítrico (utilizando el método que se discutirá en la sección 3.3.2).
- Modo de calibración para la obtención de tiempos de integración de diferentes iluminantes.
- Opción de exportación de imágenes hiperespectrales en formato `.bsq` (*band sequential*), este formato es reconocido por programas muy utilizados como ENVI o Matlab, para su posterior análisis.

La figura 2.15 muestra el interfaz gráfico del programa **HyperSpectralCitrus**. La aplicación funciona con un sencillo sistema de menú manejable por cualquier usuario con conocimientos mínimos de informática. El *software* desarrollado ha sido una pieza imprescindible para poder realizar un calibrado adecuado y obtener los parámetros de funcionamiento del sistema, además ha permitido adquirir imágenes hiperespectrales de manera sistemática y extensiva.

### 2.3.6. Parámetros de funcionamiento del sistema

Esta sección muestra la metodología empleada para determinar dos parámetros fundamentales para que el sistema funcione adecuadamente: (1) el tiempo de integración del CCD para cada banda y (2) el tiempo de precalentamiento del sistema de iluminación.

#### Metodología de determinación del tiempo de precalentamiento del sistema de iluminación

El tiempo de precalentamiento del sistema de iluminación se define como el tiempo que necesitan las lámparas halógenas para que su respuesta espectral se estabilice tras su encendido. La iluminación utilizada está basada en lámparas halógenas de filamento de tungsteno. La resistencia eléctrica del filamento de dichas lámparas varía con la temperatura y, en consecuencia, también lo hace la intensidad lumínica que emiten. Cuando las lámparas alcanzan un determinado grado de calentamiento esta variación se suaviza. Además, el sistema de alimentación también puede presentar derivas temporales en la tensión de salida de la fuente. Para evaluar si el sistema de iluminación siempre suministra la misma intensidad lumínica se realizó un experimento de estudio de repetibilidad de la radiancia del sistema de iluminación utilizando un blanco de referencia. El ensayo realizado para determinar el tiempo de precalentamiento del sistema de iluminación consistió en realizar adquisiciones de un blanco de referencia en diferentes instantes. Se adquirió una imagen hiperespectral del blanco de referencia a los 5, 10, 20, 30, 60 y 90 minutos tras el

encendido del sistema de iluminación. Los tiempos de integración por banda del sistema en este ensayo se determinaron de manera aproximada para trabajar en la zona media del rango dinámico de la cámara. En el punto siguiente de esta sección se detallará el procedimiento utilizado para determinar los tiempos de integración definitivos del sistema.

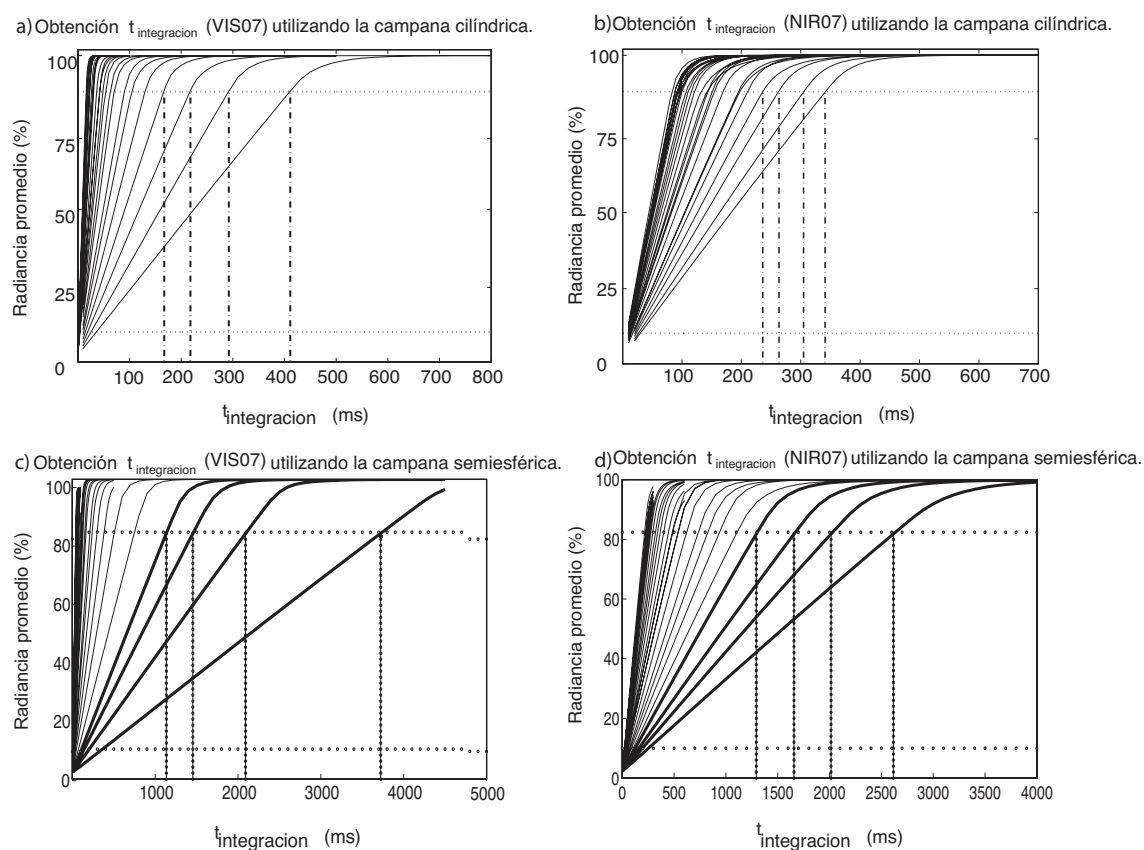
### **Metodología de determinación de los tiempos de integración del sensor**

Esta sección muestra cómo se han determinado los tiempos de integración por banda del sistema de visión hiperespectral con cada uno de los sistemas de iluminación empleados. Este tiempo se define como el tiempo que el CCD necesita para adquirir la imagen en una determinada banda. Se ha comprobado en las secciones anteriores que cada una de las partes del sistema de visión hiperespectral (sistema de iluminación, cámara, óptica y LCTF) presenta una eficiencia espectral diferente. La estrategia empleada para homogeneizar estas diferencias y que el sistema completo presente una eficiencia espectral lo más uniforme posible consistió en asignar un tiempo de integración distinto para cada banda puesto que la radiancia captada por el CCD presenta un comportamiento lineal con el tiempo de integración. De este modo, aquellas bandas que presenten una baja eficiencia serán adquiridas durante más tiempo y viceversa para las bandas que presenten una eficiencia elevada. No obstante, este proceso solamente se puede llevar a cabo si se conoce el comportamiento del CCD en todo su rango dinámico en función del tiempo de integración (figura 2.16). En esta sección se estudiará este comportamiento y se obtendrán los tiempos de integración en cada una de las bandas.

Para determinar la respuesta del CCD con el tiempo de integración, se realizó un ensayo utilizando un blanco de referencia (99 % reflectancia promedio) que consistió en sintonizar el filtro en cada una de las bandas de funcionamiento del sistema y, en cada banda, realizar adquisiciones del blanco de referencia con diferentes tiempos de integración en intervalos de 0.1 ms, desde 0 s hasta que se satura el sensor. Una vez adquiridas las imágenes hiperespectrales se obtuvo el promedio de todos los píxeles de la referencia blanca en cada adquisición. En la figura 2.16 se muestran las curvas obtenidas para cada una de las bandas en los dos filtros empleados.

La metodología empleada para determinar los tiempos de integración de cada banda consistió en realizar un ajuste lineal por mínimos cuadrados de cada una de las curvas en su zona lineal entre el 10 % y el 90 % del rango dinámico. El tiempo de integración elegido para cada banda fue el que proporcionaba el valor de nivel de gris correspondiente al 90 % del rango dinámico de la cámara en la curva ajustada en el caso de la campana cilíndrica. De este modo se consigue que no se alcance la zona de saturación del sensor. En el caso de la campana semiesférica se decidió cambiar que el criterio para elegir el tiempo de integración, en este caso, el tiempo coincidiría con el correspondiente al 82 % del rango dinámico de la cámara en la recta ajustada. Esta decisión estuvo

motivada por el hecho de observar que, en un número reducido de las imágenes hiperespectrales adquiridas para los ensayos realizados con la campana cilíndrica, se apreciaban zonas de algunos frutos en las que aparecían algunos píxeles al borde de la saturación, tras desechar las imágenes en la que ocurría este fenómeno se decidió tomar esta medida de salvaguarda con la obtención de tiempos de integración en la campana semiesférica. En la figura 2.16 se muestran las curvas de la respuesta del sistema con el tiempo de integración para cada banda, empleando los dos sistemas de iluminación estudiados. Se observa que, en general, las pendientes de las curvas obtenidas para la campana cilíndrica son significativamente mayores que en el caso de la campana semiesférica. Esto se debe a que la intensidad lumínica que proporciona la primera es mayor que en el caso de la segunda campana, saturándose el sensor con un tiempo de integración mucho menor.

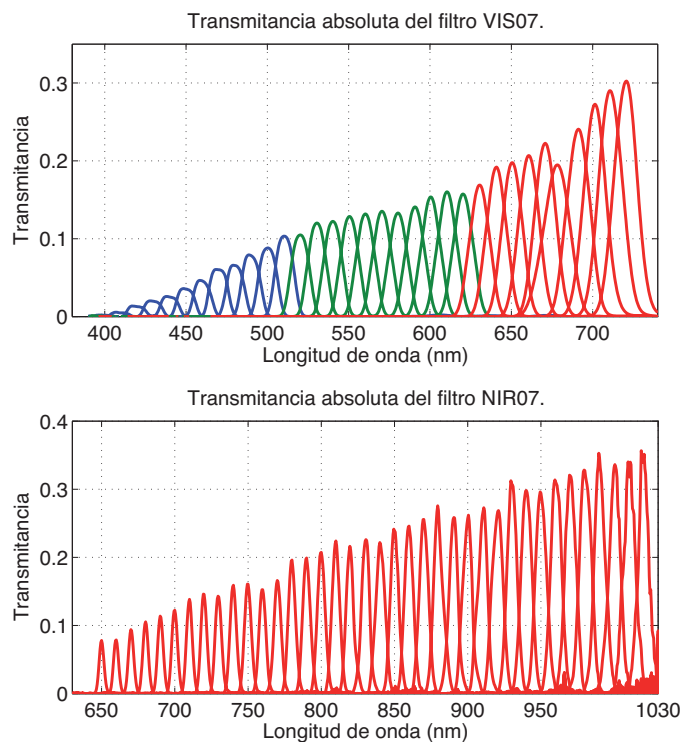


**Figura 2.16:** Evolución de nivel de gris promedio de la referencia blanca en función del tiempo de integración utilizando el filtro VIS-07 en a) la campana cilíndrica b) la campana semiesférica y el filtro NIR-07 en c) la campana cilíndrica d) la campana semiesférica.

## 2.4. Resultados

### 2.4.1. Caracterización espectral de los LCTF

La caracterización radiométrica de los filtros LCTF propuesta en la sección 2.3.4 se muestra en la figura 2.17. La principal conclusión de la caracterización espectral de los filtros es que el filtro VIS-07 (figura 2.17a) impone una cota inferior en el rango de adquisición de imágenes hiperespectrales del sistema desarrollado. Dicha cota se fijó en 460 nm puesto que el filtro VIS-07 presenta una transmitancia inferior al 5% en las bandas por debajo de esta cota. Además, en longitudes de onda inferiores a 460 nm, el filtro presenta poca selectividad en frecuencia permitiendo el paso de una pequeña cantidad (comparable a la recibida en la banda sintonizada) de radiación en otras zonas del espectro no sintonizadas. Después de estudiar las características espectrales de las diferentes partes del sistema de visión hiperespectral se ha concluido que el rango óptimo de adquisición espectral del sistema desarrollado va desde 460 nm (cota impuesta por el filtro VIS-07) hasta 1020 nm (cota impuesta por la cámara Coolsnap). La resolución espectral del sistema se ha fijado en 10 nm, esta restricción viene impuesta por la resolución espectral de los filtros sintonizables utilizados (7 nm @ FWHM).



**Figura 2.17:** a) Caracterización espectral del filtro Varispec VIS-07. b) Caracterización espectral del filtro Varispec NIR-07.

### 2.4.2. Tiempo de precalentamiento de las lámparas halógenas

La figura 2.18 muestra los resultados del estudio de repetibilidad propuesto en la sección 2.3.6. En esa figura se observan diferentes curvas que muestran la evolución temporal del promedio del nivel de gris de los píxeles de la referencia blanca. Se ha constatado que la variación en la respuesta de las lámparas empleadas es inferior al 0,9%, reduciéndose por debajo 0,6% a partir de los 30 minutos tras el encendido del sistema de iluminación. Este hecho se pone de manifiesto en la figura 2.18, en la que se se observa que la variabilidad en la intensidad del iluminante es muy baja tras mantener encendido el sistema de iluminación 30 minutos. Así pues, se fijó el tiempo de precalentamiento del sistema de iluminación en 30 minutos, tanto si se empleaba la campana cilíndrica como la semiesférica ya que ambas emplean las mismas lámparas. Este estudio también sirvió para comprobar que la fuente de alimentación del sistema de alimentación no presentaba derivas temporales importantes en la tensión o la corriente de salida que afectarían al sistema de iluminación.

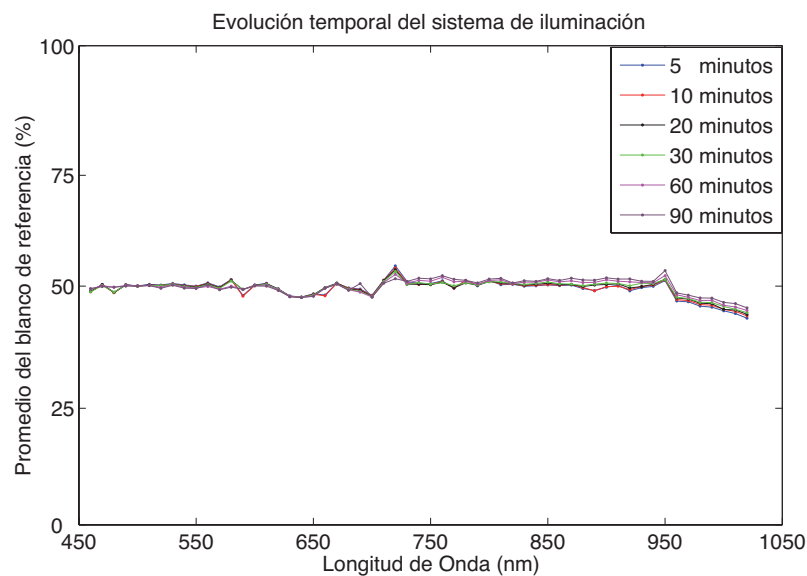


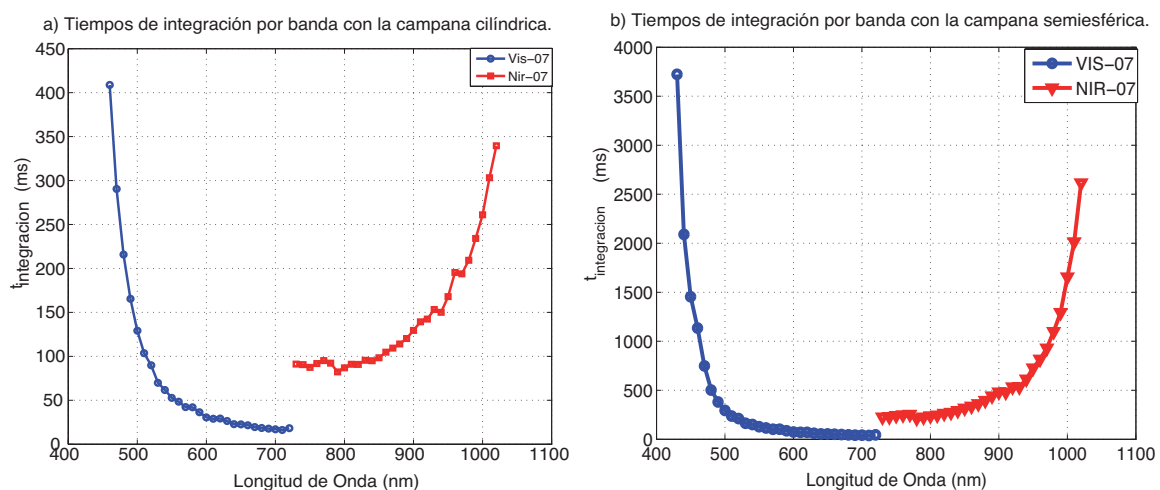
Figura 2.18: Evolución temporal del sistema de iluminación.

### 2.4.3. Tiempos de integración del CCD

En la figura 2.16a) se muestra la respuesta del sistema con el tiempo de integración, en concreto las curvas obtenidas para cada una de las bandas sintonizadas en la parte del espectro captado por el filtro VIS-07 utilizando la campana cilíndrica. En la misma se observa que las bandas del azul son las que presentan una menor pendiente, aumentando la pendiente conforme avanza la



longitud de onda hacia el rojo. Este resultado concuerda con las eficiencias que introduce en el sistema el filtro VIS-07 (y el resto de partes del sistema) mostradas en la figura 2.17a). El ensayo se repitió para la parte del espectro captada con el filtro NIR-07 como se muestra en la figura 2.16b). En este caso la respuesta del sistema es inversa a la presentada en la región del visible. Este hecho se acaba de constatar observando la figura 2.19a) en la que se muestra un gráfico con los tiempos de integración por banda determinados con el procedimiento descrito para los filtros VIS-07 y NIR-07. En la misma figura se observa que la tendencia de la curva NIR-07 es creciente, contraria a la tendencia de la curva del filtro VIS-07. Esto se debe a que conforme se avanza en la zona NIR la eficiencia global del sistema disminuye debido a la caída drástica de la eficiencia del CCD en esta zona (figura 2.13a). Este efecto predomina sobre el aumento de eficiencia que introduce el filtro NIR-07 en la parte alta del rango de adquisición. En la zona visible la mayor limitación en eficiencias la introduce el filtro VIS-07 en las bandas próximas al azul.



**Figura 2.19:** Tiempos de integración por banda del sistema de visión hiperespectral para los filtros VIS-07 y NIR-07 utilizando a) la campana cilíndrica b) la campana semiesférica.

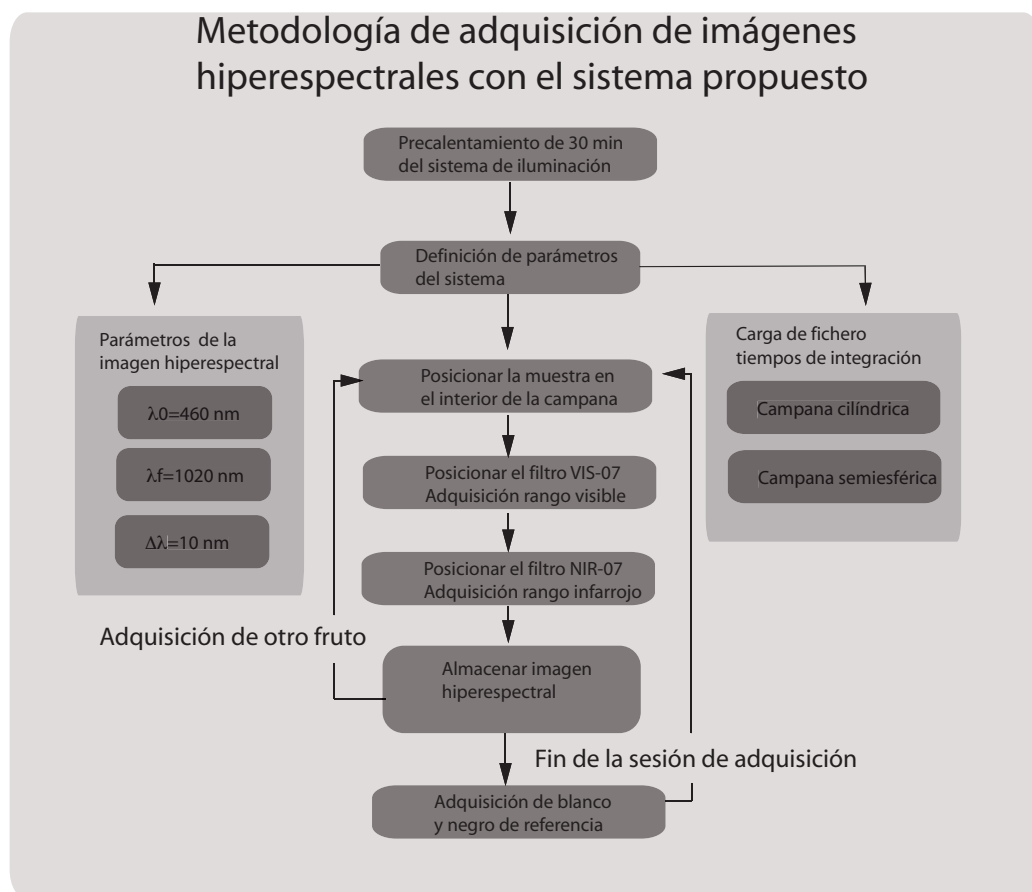
La figura 2.16b) muestra la respuesta del sistema con el tiempo de integración cuando se emplea la campana semiesférica, el comportamiento observado (en cuanto a zonas del espectro en las que el sistema es más o menos eficiente) es muy similar al que se observa con la campana cilíndrica. La principal diferencia radica en la escala de tiempos; utilizando el segundo sistema de iluminación, el tiempo necesario para que el CCD reciba la misma cantidad de radiación es de casi 10 veces más que utilizando la campana cilíndrica. No obstante, como se discutió en secciones anteriores, este detalle no es crítico y la calidad de la iluminación proporcionada por la campana semiesférica es mucho mayor que en el caso de la campana cilíndrica. Además, a esto hay que sumarle el hecho que en el caso de la campana esférica los tiempos han sido calculados para que



el CCD trabaje en el 82% de su rango dinámico, en promedio, mientras que en el caso de la campana cilíndrica se calcularon para que este valor fuera del 90%. La figura 2.19b) muestra los tiempos de integración del sistema de visión hiperespectral para cada banda utilizando la campana semiesférica. La tendencia general de los tiempos de integración utilizando la campana semiesférica es similar a la observada en el caso anterior.

#### 2.4.4. Metodología de adquisición de imágenes hiperespectrales VIS+NIR

Uno de los resultados más importantes de este capítulo es la propuesta de una metodología de adquisición (en sí misma) de imágenes hiperespectrales con un sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido, con las garantías mínimas para obtener imágenes hiperespectrales de calidad.



**Figura 2.20:** Metodología de adquisición de imágenes hiperespectrales.

En primer lugar es importante precalentar el sistema de iluminación durante 30 minutos. A continuación se definen los parámetros de la adquisición, tales como longitud de onda inicial

( $\lambda_0 = 460 \text{ nm}$ ), longitud de onda final ( $\lambda_f = 1020 \text{ nm}$ ) y el paso del barrido ( $\Delta\lambda = 10 \text{ nm}$ ). Finalmente, se definen en la aplicación desarrollada, los tiempos de integración de cada banda. Posteriormente, se posiciona el fruto a analizar en el interior de la subcampana difusora (bien sea la campana cilíndrica o semiesférica). En ese momento se inicia la adquisición en el visible con el filtro VIS-07. La imagen monocromática correspondiente a cada banda se adquiere durante el tiempo de integración necesario para obtener una respuesta espectral plana. Finalizada la adquisición en el visible el programa interrumpirá la adquisición e informará al usuario de que desplace la caja portafiltros, pasando a ser el filtro activo el NIR-07. En ese momento se continuará con la adquisición en el infrarrojo hasta concluir la misma. Terminada la adquisición, si se ha llevado a cabo con éxito se almacena la imagen hiperespectral en formato `.bsq` para su posterior análisis con programas de análisis de imágenes hiperespectrales como ENVI o Matlab. Si se desea realizar más adquisiciones se procede de manera análoga. Al concluir la sesión de adquisición de imágenes, se adquieren imágenes del blanco de referencia y del negro de referencia para realizar las correcciones oportunas. En la figura 2.20 se muestra un diagrama de flujo con las diferentes etapas en el proceso de adquisición de imágenes hiperespectrales utilizando el sistema propuesto.

## 2.5. Conclusiones

En este capítulo se han detallado los aspectos principales en el diseño de un sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido a partir de sus constituyentes básicos para un sistema de inspección de cítricos. Además se han descrito las características principales de cada una de las partes del sistema. Se han evaluado diferentes tipos de sistemas de iluminación (en cuanto a tipo de iluminante y geometría de los mismos) con el fin de disponer de una iluminación eficiente desde el punto de vista espectral, espacialmente uniforme y sin brillos.

Se han diseñado elementos auxiliares (sistema de posicionamiento y guiado de filtros) para permitir adquirir imágenes hiperespectrales de manera sistemática utilizando dos filtros LCTF (VIS-07 y NIR-07), hecho que posibilita la realización de ensayos con un número elevado de muestras. Se han enumerado los factores a tener en cuenta en la elección de elementos del sistema tales como la óptica más adecuada (que permite obtener imágenes sin variaciones significativas de enfoque), la cámara o el sistema de iluminación. En este capítulo también se ha mostrado la caracterización espectral de cada uno de los elementos del sistema, permitiendo establecer el rango espectral de trabajo óptimo del sistema propuesto (460 nm-1020 nm). Se ha justificado la necesidad de desarrollar una aplicación *software* íntegramente que ha permitido sincronizar los diferentes elementos del sistema así como realizar labores de calibrado y adquisición sistemática de imágenes hiperespectrales, que el *software* propietario de los filtros y la cámara no incluía. Se han

obtenido los parámetros óptimos de funcionamiento del sistema de visión hiperespectral (rango espectral de trabajo, resolución, tiempo de precalentamiento del sistema y tiempos de integración por banda) necesarios para obtener imágenes hiperespectrales de calidad. Se ha propuesto una metodología para uniformizar la respuesta espectral del sistema utilizando tiempos de integración variables, asumiendo una respuesta lineal con el tiempo de integración del CCD. Finalmente se ha propuesto un protocolo de adquisición de imágenes hiperespectrales con el sistema propuesto.

En definitiva el capítulo en sí mismo presenta globalmente los principales aspectos en cuestiones de diseño y calibrado que un investigador en una materia aplicada debe tener en cuenta para montar un sistema de visión hiperespectral basado en tecnología LCTF a partir de sus componentes fundamentales. La importancia de los aspectos tratados radica en que la mayoría de subsistemas comerciales hacen hincapié en su funcionamiento particular, sin hacer referencia a aspectos referentes a la integración del sistema completo.



## Capítulo 3

# Preprocesado de imágenes hiperespectrales

### 3.1. Introducción

La distribución de luz reflejada por un objeto y capturada por un sistema de adquisición de imagen depende, entre otros factores, de la posición de la fuente de iluminación y de la geometría del propio objeto. Generalmente, la calibración empleada para corregir las variaciones espaciales y espectrales introducidas por el sistema de iluminación, se basa en el empleo de una referencia blanca de reflectancia conocida. El problema de este tipo de calibración aparece cuando los objetos que se están inspeccionando no son planos. Es precisamente éste el caso que nos ocupa, la inspección de objetos con forma aproximadamente esférica. Las imágenes adquiridas de objetos de este tipo tienen una característica común, los bordes del objeto aparecen más oscuros que la parte central del objeto que aparece más brillante (Aleixos et al., 2002; Unay and Gosselin, 2007). Este problema aparece en la inspección de muchos productos hortofrutícolas con una forma más o menos esférica, como por ejemplo naranjas, melocotones, tomates, mandarinas o manzanas. El oscurecimiento gradual de los bordes con respecto al centro puede producir que una zona sana del fruto sea confundida con una zona dañada. Debido a la naturaleza biológica de los productos hortofrutícolas, éstos presentan una elevada variabilidad de colores, texturas y tamaños (Blasco et al., 2007b; Du and Sun, 2004). Este hecho pone de manifiesto la importancia de diseñar sistemas de iluminación versátiles y precisos. No obstante, diseñar un sistema de iluminación universal válido en cualquier situación es una tarea prácticamente imposible. Un sistema de iluminación ineficiente desde el punto de vista espacial, puede producir que un defecto sea confundido con una zona sana del fruto, debido a que el mismo coincida con una zona mal iluminada del fruto por exceso o por defecto de iluminación (Bennedsen et al., 2005). Los efectos positivos que produce un buen

sistema de iluminación son dos: por una parte, permite maximizar la calidad de los resultados en la etapa de análisis de imagen, por otra parte permite optimizar el rendimiento del análisis de imagen al evitarse costosas etapas de preprocesado de datos (Chen et al., 2002; Zheng et al., 2006). Algunos investigadores han abordado esta cuestión utilizando fuentes de iluminación colocadas formando un ángulo de  $45^\circ$  con la cámara (Papadakis et al., 2000). El inconveniente que presenta esta técnica es que no es adecuada para analizar objetos con geometría esférica. La inspección automática de objetos esféricos es un claro ejemplo de aplicación en la que no es sencillo obtener una iluminación difusa y uniforme desde el punto de vista espacial. Este problema, se ve acrecentado cuando existen limitaciones mecánicas, espaciales o de coste a la hora de implementar un sistema de iluminación adecuado. Precisamente, es en estos casos cuando resulta necesario añadir soluciones por *software*, tales como etapas de preprocesado para corregir los efectos adversos que introduce la curvatura del objeto o eliminar del análisis las zonas mal iluminadas de la imagen mediante, por ejemplo, técnicas de erosión. En la literatura científica aparecen varios intentos para solventar este problema, por ejemplo aplicando modelos esféricos de curvatura constante y radio variable (Tao and Wen, 1999). Sin embargo, este tipo de modelos son muy rígidos y su principal propósito es aumentar la tasa de éxito en la clasificación de fruta sana o dañada, sin realizar una corrección que permita conocer las características intrínsecas del defecto (calidades reflectivas) con detalle y así poder distinguir entre diferentes tipos de defectos. Otra solución por *software*, que tradicionalmente se utiliza para solventar este problema es erosionar el contorno de la fruta con el fin de eliminar las zonas mal iluminadas (Blasco et al., 2003). Esta solución lleva asociada una pérdida de la calidad de la inspección, ya que en ocasiones una parte importante de la superficie de la fruta no es analizada. Otra solución adoptada por algunos autores, viene de la mano de asumir que zonas centrales y periféricas pertenecen a regiones de interés distintas y son analizadas por separado. Por ejemplo en Blasco and Moltó (2002), los autores asignan tres clases para caracterizar la piel sana, dependiendo de la proximidad al centro del fruto. No obstante esta solución presenta un inconveniente importante en problemas multiclase, en los que generalmente la tasa de éxito de los clasificadores disminuye al aumentar el número de clases presentes en el problema (Duda et al., 2001). Un método de corrección muy extendido está basado en el uso de una referencia espectral de reflectancia conocida (Kleynen et al., 2005). No obstante, para realizar esta corrección se emplea un blanco de referencia plano para corregir las heterogeneidades espectrales y espaciales del sistema de iluminación, pero no se tiene en cuenta la geometría particular de objetos esféricos.

Todos los problemas antes mencionados ocurren tanto en sistemas de visión convencionales como en sistemas hiperespectrales. Estos últimos se caracterizan por adquirir un elevado número de imágenes monocromáticas de la escena en diferentes longitudes de onda, por lo que son especialmente sensibles a la influencia del sistema de iluminación. Los sistemas de iluminación más

utilizados con este tipo de tecnología son los basados en lámparas halógenas (Ariana et al., 2006; Polder et al., 2003), ya que ofrecen una buena eficiencia tanto en el visible como, en el infrarrojo cercano. No obstante, la iluminación ofrecida por este tipo de lámparas no es muy homogénea desde el punto de vista espacial. Por lo que los ensayos en los que se utilizan estas lámparas son candidatos perfectos para evaluar las técnicas de corrección antes mencionadas.

En algunas ocasiones, cuando se utilizan sistemas hiperespectrales de imagen, el objetivo es realizar estudios sobre las características reflectivas intrínsecas del objeto inspeccionado en diferentes longitudes de onda. Por ejemplo, esta tarea es muy importante en la inspección de productos hortofrutícolas, ya que diferentes daños en la superficie del fruto pueden presentar distintas características reflectivas en diferentes zonas del espectro electromagnético (Gaffney, 1973). Por tanto, y con el fin de detectar correctamente diferentes tipos de defectos, es esencial eliminar o corregir cualquier influencia negativa producida por el sistema de iluminación o por cualquier parte del sistema de visión.

En este capítulo se va a proponer una metodología para tener en cuenta la geometría de los cítricos (aunque sería válida para otros frutos con forma esférica) con el fin de corregir la influencia negativa que introduce la reflexión de la luz al incidir sobre frutos esféricos. Esta metodología está basada en el desarrollo de un modelo de elevación digital (DEM) de la forma del fruto y considerar el fruto como una superficie Lambertiana. El correcto comportamiento de la metodología aquí propuesta se ha probado utilizando imágenes hiperespectrales adquiridas por el sistema de visión hiperespectral ensamblado en este trabajo. La técnica propuesta se ha mostrado eficaz para minimizar los efectos adversos producidos por la curvatura de los cítricos en la intensidad de la radiación recibida por la cámara hiperespectral. Asimismo, los experimentos que se expondrán a lo largo de este capítulo mostrarán que al aplicar la metodología propuesta, el nivel de gris de los píxeles pertenecientes a la misma clase se uniformiza independientemente de la región del fruto a la que pertenezca el píxel, facilitando posteriores procesos de segmentación y clasificación.

## 3.2. Objetivos

El objetivo de este capítulo de la Tesis Doctoral es desarrollar y validar una metodología para preprocesar las imágenes hiperespectrales de frutos con forma esférica proporcionadas por el sistema de visión hiperespectral basado en LCTF e iluminación halógena. Para llevar cabo este objetivo se deberán alcanzar una serie de hitos:

1. **Correcciones espaciales.** Se va a desarrollar una metodología para preprocesar imágenes hiperespectrales de objetos esféricos, con el fin de obtener la reflectancia del cítrico a partir de la imagen hiperespectral adquirida. Para conseguir este propósito se realizarán dos

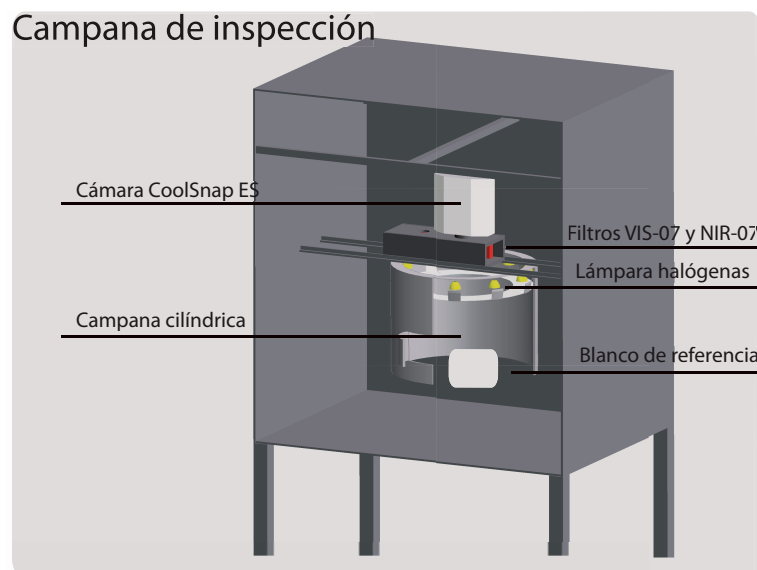
correcciones: 1) corrección de las variaciones espaciales del iluminante utilizando un blanco de referencia, y 2) corrección de los efectos negativos que produce la reflexión de la luz al incidir sobre frutos con geometría esférica en la adquisición de imágenes hiperespectrales. Esta corrección se realiza a partir de una metodología basada en considerar el fruto como una superficie Lambertiana sobre la que se refleja luz con dos componentes, una directa y otra difusa.

2. **Elaboración de un modelo de elevación digital.** Con el fin de obtener determinados parámetros del modelo lambertiano se elaborará un modelo de elevación digital del cítrico.
3. **Validación de la metodología propuesta.** Una vez descrita la técnica de preprocesado se evaluará la efectividad de la misma a partir de una serie de ensayos con cítricos, utilizando el sistema de visión hiperespectral diseñado en este trabajo.

### 3.3. Materiales y métodos

#### 3.3.1. Particularidades del sistema de visión hiperespectral

El sistema de visión hiperespectral utilizado para adquirir las imágenes que se emplearán para realizar los ensayos planteados en este capítulo se describió de manera general en el capítulo 2. A continuación se van a resaltar las particularidades de configuración que presenta el sistema en los ensayos propuestos en este capítulo.



**Figura 3.1:** Diagrama del sistema de adquisición de imagen con campana cilíndrica.



El sistema de visión hiperespectral utilizado en esta investigación está compuesto por una cámara monocromática Photometrics Coolsnap ES, configurada para adquirir imágenes de una región de interés de la escena de  $551 \times 551$  píxeles. Las imágenes se transfieren al ordenador por medio de una tarjeta de adquisición de datos propietaria de la cámara. La etapa de selección en frecuencia se ha llevado a cabo utilizando dos filtros sintonizables de cristal líquido (Varispec VIS-07 sensible desde 400 nm hasta 720 nm y Varispec NIR-07 sensible desde 650 nm hasta 1100 nm). Debido a que las diferentes partes del sistema introducen diferentes eficiencias a lo largo del espectro de trabajo, se han programado diferentes tiempos de adquisición específicos por cada banda en el *software* de adquisición. Estos tiempos de integración se han calculado utilizando un blanco de referencia con una reflectancia certificada promedio del 99%. De este modo se ha homogeneizado la respuesta espectral del sistema y se asegura que el mismo funciona dentro del rango dinámico del sensor. La escena ha sido iluminada por medio de luz indirecta de 10 lámparas halógenas de 35 W (Philips Brilliantline Pro 35W/12V) alojadas en el interior de una campana difusora cilíndrica. Las lámparas halógenas han sido alimentadas utilizando una fuente de alimentación estabilizada de 12 V/DC con una potencia de 350W. Todo el sistema de inspección se encuentra en el interior de una cámara de inspección de acero inoxidable que evita que la escena sea iluminada con luz procedente del exterior. En la figura 3.1 se puede observar un representación del sistema de visión hiperespectral utilizado.

### 3.3.2. Corrección de las variaciones espaciales de la intensidad del iluminante con referencia blanca

En el capítulo 2 se detallaron los aspectos de diseño y caracterización del sistema de visión hiperespectral. Se dedicó un gran esfuerzo a diseñar un sistema de iluminación que fuera lo más eficiente posible (desde el punto de vista espectral) y que suministrara una iluminación uniforme (tanto espacial, como temporalmente). Sobre la estabilidad temporal del sistema de iluminación se discutió en la sección 2.3.6, concluyendo que el sistema de iluminación era lo suficientemente estable. Por tanto, a partir de ahora se considerará que la intensidad de la iluminación no depende del tiempo. No obstante, después de montar el sistema y realizar los primeros ensayos se observó que, al iluminar la escena aparecían pequeñas variaciones espaciales en la intensidad del iluminante sobre la escena (ver figura 3.2) en todas las bandas adquiridas. Estas variaciones se minimizan en la zona central de la región de interés adquirida (ver figura 3.2b). A pesar de ello, en dicha región de interés se aprecian ligeras variaciones en la intensidad del iluminante.

El carácter no ideal de la fuente de iluminación empleada (lámparas halógenas), en cuanto a la elevada direccionalidad que ofrece, introduce variaciones en la intensidad dependiendo de la posición de la escena. Va a ser necesario realizar una corrección utilizando una referencia blanca



**Figura 3.2:** Imágenes monocromáticas del blanco de referencia (99%). a) Referencia blanca adquirida a 480 nm. b) Referencia blanca adquirida a 700 nm. En esta figura se muestra la zona aproximada donde se ubica el fruto en la adquisición. c) Referencia blanca adquirida a 980 nm.

plana para suavizar el efecto de las variaciones espaciales en la escena del iluminante. En la calibración que se va a describir se están asumiendo una serie de consideraciones tales como que la distancia entre el objeto y la cámara permanece constante, o que los filtros sintonizables de cristal líquido son ideales, desde el punto de vista de la selección en frecuencia, es decir, que sólo transmiten radiación en la banda sintonizada (Gat, 2000).

En este trabajo se ha utilizado una referencia blanca calibrada (99%) de *LabSphere*<sup>®</sup> de 128 mm × 128 mm. En la figura 3.3 se muestra la curva de calibración, certificada por *LabSphere*, de la reflectancia promedio de la referencia blanca utilizada. A partir de la imagen hiperespectral que se desea corregir, de la imagen del blanco de referencia y de la del negro de referencia (como se describió en la sección 2.4.4) se puede obtener la imagen corregida por referencia blanca dividiendo la radiancia absoluta del cítrico  $R^{abs}$  entre la radiancia absoluta del blanco de referencia  $R_{blanca}^{abs}$  (Bajcsy and Kooper, 2005; Gat, 2000; Polder et al., 2000).

$$\rho_{xy}(x, y, \lambda) = \frac{R^{abs}(x, y, \lambda)}{R_{blanca}^{abs}(x, y, \lambda)} \quad (3.3.1)$$

siendo  $\rho_{xy}(x, y, \lambda)$  la reflectancia relativa<sup>1</sup> del píxel ubicado en la posición  $(x, y)$  de la imagen monocromática de la banda  $\lambda$  del cítrico, una vez corregidas las variaciones espaciales del iluminante.

No obstante, los factores de la ecuación (3.3.1) no son medibles directamente por el sistema desarrollado ya que el CCD presenta *dark currents*<sup>2</sup>. Además, la referencia blanca utilizada no

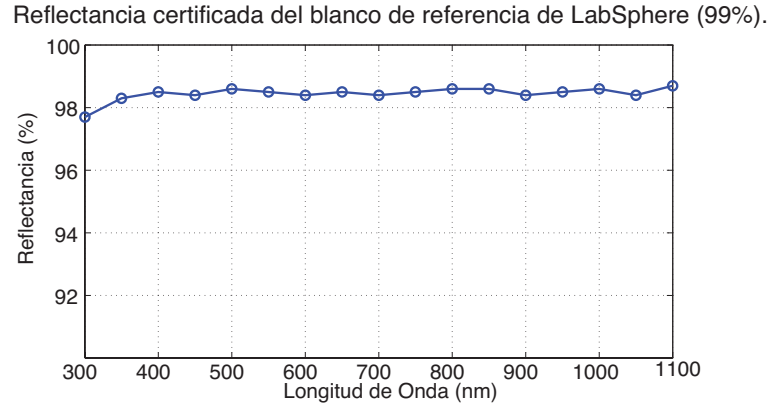
<sup>1</sup> Se denomina reflectancia relativa del fruto a la imagen corregida por referencia blanca. Paso previo a la obtención de la reflectancia absoluta del fruto cuando la imagen sea corregida por el factor geométrico del cítrico (sección 3.3.3).

<sup>2</sup>Nivel de señal que proporciona el sensor, de un cuerpo en ausencia de iluminación,  $R_{negra}$ .

tiene una reflectividad del 100%, por lo que es necesario tener en cuenta estos factores para realizar una correcta estimación de  $R^{abs}$  y  $R_{blanca}^{abs}$ . El modo de corregir los errores introducidos por los factores antes mencionados y obtener  $\rho_{xy}(x, y, \lambda)$  (Gat, 2000) se muestra en:

$$\rho_{xy}(x, y, \lambda) = \frac{R^{abs}}{R_{blanca}^{abs}} = \rho^{Ref}(\lambda) \frac{R(x, y, \lambda) - R_{negra}(x, y, \lambda)}{R_{blanca}(x, y, \lambda) - R_{negra}(x, y, \lambda)} \quad (3.3.2)$$

siendo  $\rho^{Ref}(\lambda)$  la reflectancia promedio de la referencia blanca (figura 3.3),  $R(x, y, \lambda)$  la radiancia del objeto (en nuestro caso un cítrico) captada por el CCD,  $R_{blanca}(x, y, \lambda)$  la radiancia de la referencia blanca captada por el CCD y  $R_{negra}(x, y, \lambda)$  es la radiancia captada por el CCD anulando toda fuente de iluminación y que permite cuantificar el ruido electrónico del CCD.




**Figura 3.3:** Curva de reflectancia certificada del Blanco de referencia de *Labsphere*®.

De esta manera, además de corregir las variaciones espaciales en la intensidad del iluminante, se está corrigiendo localmente (para cada uno de los píxeles de la escena) el efecto de las diferentes eficiencias de las partes del sistema de visión hiperespectral. En la figura 3.4 se muestra el efecto de corregir las bandas RGB (B=480 nm, G=550 nm y R=640 nm), extraídas de una imagen hiperespectral de una mandarina del cultivar<sup>3</sup> clemenules. Se observa que tras la corrección las imágenes no presentan inhomogeneidades en la iluminación del plano de la escena que aparecen en las imágenes sin corregir. No obstante, sigue apareciendo un efecto indeseado. De hecho, si se observan las imágenes de la figura 3.4, se aprecia un oscurecimiento gradual en la dirección que va desde el centro hasta el borde del cítrico. La geometría esférica de las mandarina introduce una importante limitación en la correcta determinación de la reflectancia de la misma. Esto es debido a que no toda la radiación que se refleja en el cítrico es captada por el CCD debido a la forma

<sup>3</sup>Se designa como cultivar (cv.) a un familia de frutos obtenida a partir de cruces y combinaciones genéticas de variedades distintas de fruta.

de la naranja y al punto de vista cenital de la cámara. En la siguiente sección se describirá una corrección desarrollada en el ámbito de este trabajo para minimizar el problema que introduce la forma del cítrico.



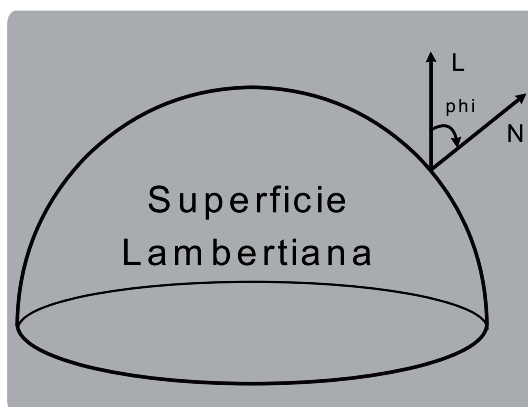
**Figura 3.4:** En la parte superior se muestran las imágenes RGB (640 nm, 550 nm y 480 nm) de dos frutos sin corregir por referencia blanca de los cultivares cv. clemenules (a) y cv. clemenvilla (b). En la parte inferior ( c) y d) ) de la figura se muestran las imágenes de los mismos frutos tras ser corregidas por referencia blanca.

### 3.3.3. Corrección geométrica

#### Modelo de iluminación

El modelo de iluminación considerado para representar el sistema de iluminación empleado aporta tanto luz directa como difusa. La luz directa produce variaciones del brillo en la imagen adquirida por el CCD del objeto iluminado que dependen del ángulo de incidencia de la luz sobre el objeto o la distancia que separa la fuente de iluminación del mismo (Foley et al., 1996). Se ha empleado un modelo matemático sencillo para describir la iluminación empleada, que considera el iluminante como la superposición de una componente de luz directa y otra de luz difusa. Supongamos que el sistema de iluminación suministra una intensidad luminosa total  $I_T$ . Se asume que dicha intensidad contiene un componente directa,  $I_D$  y una componente difusa  $I_F$ . Por otra parte se considerará la superficie del objeto como una superficie Lambertiana, caracterizada por reflejar la luz con la misma intensidad en todas las direcciones. Foley et al. (1996) describe como para este tipo de superficies, la cantidad de luz recibida por el observador es independiente de la dirección del mismo, únicamente depende del ángulo de incidencia de la luz directa  $\phi$  con la superficie (ver figura 3.5). Con estas consideraciones, se puede suponer que la iluminación empleada se puede modelizar matemáticamente mediante:

$$I_T = I_D(\lambda) \cos(\phi) + I_F(\lambda) \quad (3.3.3)$$



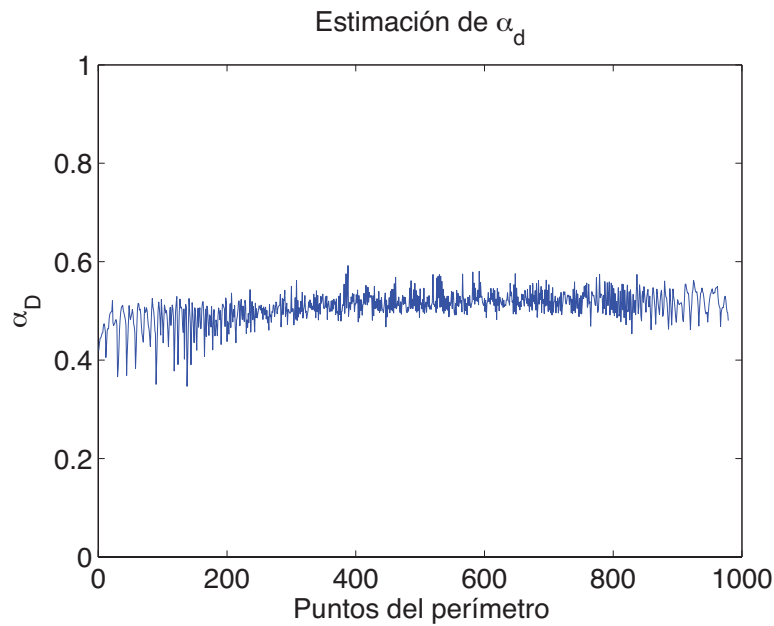
**Figura 3.5:** Superficie Lambertiana esférica.  $\mathbf{L}$  representa la dirección de la iluminación directa y  $\mathbf{N}$  la dirección normal a la superficie.

Por otra parte, se ha considerado que la cantidad de luz directa y luz difusa está cuantificada por un factor  $\alpha_D$  sobre la cantidad de luz total detectada por el CCD,  $I$ . Esto es:

$$I_D = \alpha_D I \quad (3.3.4)$$

$$I_F = (1 - \alpha_D) I \quad (3.3.5)$$

donde el parámetro  $\alpha_D$  se determina obteniendo el cociente entre el promedio (sobre todas las bandas) de luz que el CCD detectaba en los puntos que coinciden con el perímetro de la mandarina y la cantidad de luz total que recibe el CCD de todo el fruto. En los puntos del perímetro, la luz que reflejan las mandarinas es únicamente luz difusa, como se observa en la ecuación (3.3.3), ya que en dichos puntos  $\phi = \frac{\pi}{2}$ . En la figura 3.6 se muestra el valor de  $\alpha_D$  para diferentes puntos del perímetro, se observa que los valores se distribuyen en torno a un valor medio de 0.5104. Por tanto, se adoptará este valor de  $\alpha_D$  de ahora en adelante para realizar la corrección del factor geométrico del cítrico.



**Figura 3.6:** Estimación del parámetro  $\alpha_D$  para cada uno de los puntos del perímetro de una mandarina clemenules.

Por otra parte se va a considerar que la radiancia  $R^{abs}(\lambda)$  del cítrico se puede formular en función del iluminante  $I_T(x, y, \lambda)$  y de la reflectancia del fruto  $\rho(x, y, \lambda)$ :

$$R^{abs}(x, y, \lambda) = I_T(x, y, \lambda)\rho(x, y, \lambda) \implies \rho(x, y, \lambda) = \frac{R^{abs}(x, y, \lambda)}{I_T(x, y, \lambda)} \quad (3.3.6)$$

Si se introducen los resultados de las ecuaciones (3.3.4), (3.3.5) y (3.3.3) en la ecuación (3.3.6), se puede concluir que:

$$\rho(x, y, \lambda) = \frac{R^{abs}(x, y, \lambda)}{I(x, y, \lambda)} \cdot \frac{1}{[\alpha_D \cos(\phi) + (1 - \alpha_D)]} \quad (3.3.7)$$

Por último, se ha considerado que la intensidad del iluminante  $I(x, y, \lambda)$  coincide con la radiancia absoluta del blanco de referencia  $R_{blanca}^{abs}(x, y, \lambda)$ , así pues se puede reescribir la ecuación (3.3.7) de la siguiente manera:

$$\rho(x, y, \lambda) = \frac{R^{abs}(x, y, \lambda)}{R_{blanca}^{abs}(x, y, \lambda)} \cdot \frac{1}{\epsilon_g(x, y, \lambda)} \quad (3.3.8)$$

siendo

$$\epsilon_g(x, y, \lambda) = [\alpha_D \cos(\phi) + (1 - \alpha_D)] \quad (3.3.9)$$

Teniendo en cuenta el resultado de la ecuación (3.3.2) e introduciéndolo en la ecuación (3.3.8), se obtiene la reflectancia  $\rho(x, y, \lambda)$  de la mandarina en función de la reflectancia relativa  $\rho_{xy}(x, y, \lambda)$  (imagen hiperespectral corregidas las variaciones espaciales del iluminante) y del factor de corrección geométrico  $\epsilon_g(x, y, \lambda)$ .

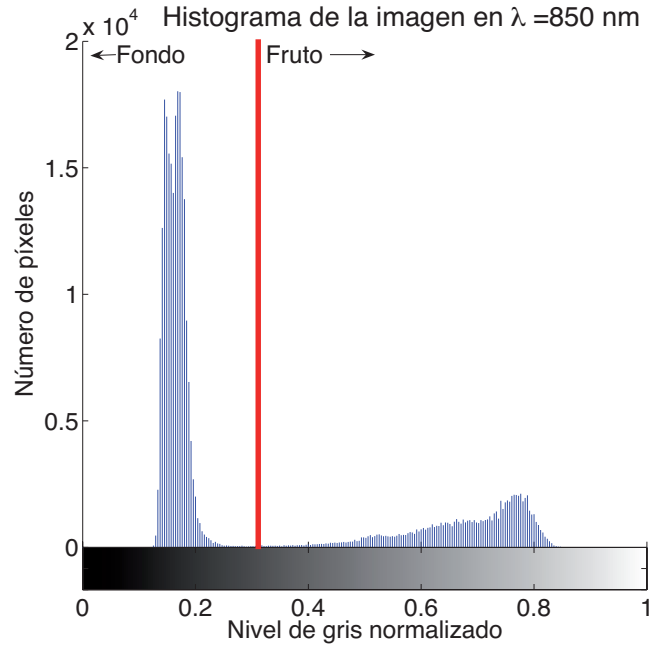
$$\rho(x, y, \lambda) = \frac{\rho_{xy}(x, y, \lambda)}{\epsilon_g} \quad (3.3.10)$$

### Modelo de elevación digital

Para aplicar la corrección arriba descrita es necesario conocer las características geométricas del cítrico a analizar. Con esta finalidad se ha desarrollado un modelo de elevación digital para caracterizar la geometría del cítrico. El modelo DEM consiste básicamente en un modelado 3D del cítrico a partir de su imagen bidimensional. El modelo desarrollado se inspira en el hecho de que todas las mandarinas presentan una forma cuasi esférica, con cierto grado de achatamiento. Este modelo permite extraer determinados parámetros necesarios para realizar la corrección del factor geométrico que se está describiendo en esta sección. La elaboración del DEM de cada cítrico consta de una serie de etapas que se enumeran a continuación:

1. **Segmentación del fruto y determinación del centro de masas del cítrico.** En esta etapa se obtiene una máscara que etiquetará los píxeles de la imagen que forman parte del cítrico. Esta máscara se ha determinado a partir de umbralizar el histograma de la imagen monocromática del cítrico correspondiente a  $\lambda = 850$  nm. Se eligió esta banda de manera empírica, ya que la mandarina presenta un buen contraste frente al fondo, como se puede observar en la figura 3.7, donde se muestra un histograma claramente bivaluado. De este modo se pueden etiquetar todos los píxeles de la imagen que pertenecen al cítrico en la imagen hiperespectral (figura 3.8). Posteriormente se determina el centro de masas del

cítrico. De esta manera se dispone del píxel con el que se corresponde el centro geométrico del cítrico  $P_g$  (figura 3.8b).

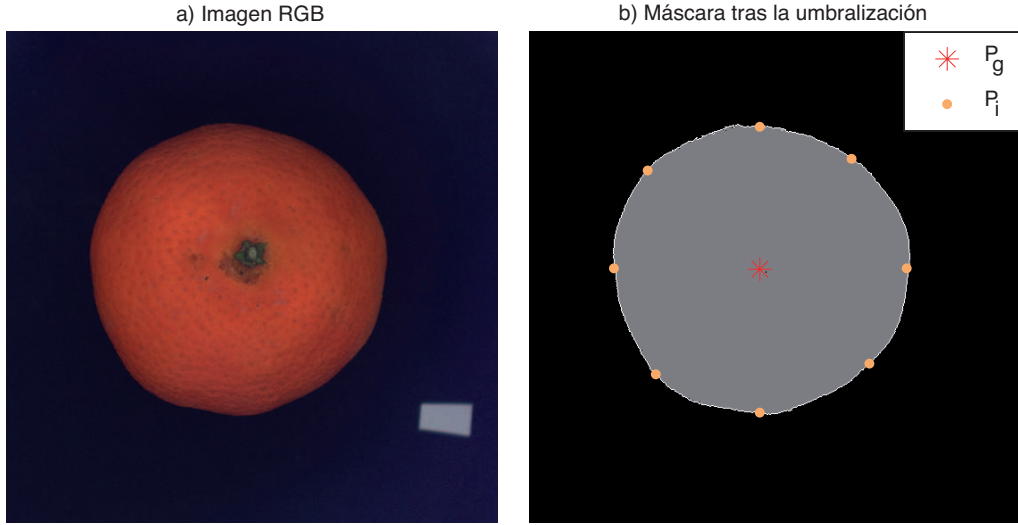


**Figura 3.7:** Histograma de niveles de gris de la imagen monocromática correspondiente a la banda  $\lambda=850\text{nm}$ . Se puede observar que el histograma es bivaluado, lo que permite diferenciar el fondo del fruto.

2. **Determinación de los puntos del perímetro del fruto.** Una vez elaborada la máscara, se determinan los píxeles pertenecientes al perímetro del cítrico. Para ello se utilizaron algunas funciones de la *toolbox* de Matlab de procesamiento de imágenes. La finalidad de esta acción es determinar una serie de puntos equiespaciados  $P_i$  del perímetro cada cuatro puntos del mismo. Estos puntos marcarán el inicio de los paralelos<sup>4</sup> de la red de interpolación necesaria para desarrollar el modelo 3-D (ver figura 3.8b).
3. **Estimación de la altura de la mandarina.** Para elaborar el modelo 3D se necesita conocer la altura del cítrico. Para ello se definió la siguiente estrategia: a) Obtener el radio promedio del cítrico, para ello se determinaron todos los radios ( $\|\overline{P_i P_g}\|$ ) obtenidos a partir de la distancia entre el centro de masas y los  $N_{P_i}$  puntos calculados anteriormente; b) Asumir que la altura del cítrico  $h_c$  es el producto del radio promedio y un factor  $\eta$  que evaluará el grado de achatamiento del cultivar analizado ( $\eta_{mules} = 0,9$  y  $\eta_{villita} = 0,8$  fijados empíricamente). De este modo:

<sup>4</sup>Los paralelos son las líneas verticales de la red de interpolación que recorren el cítrico desde la base hasta su polo.





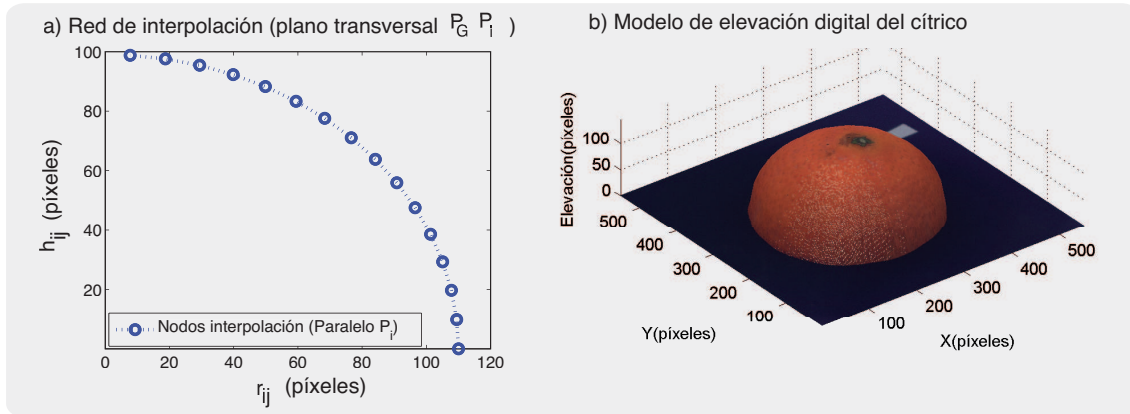
**Figura 3.8:** a) Imagen RGB de una mandarina del cultivar clemenules. b) Segmentación obtenida tras la umbralización de la imagen monocromática correspondiente a la banda de 850 nm. Además también se muestra el centro de masas del cítrico  $P_g$ , así como una muestra cualitativa de los puntos del perímetro utilizados para obtener el DEM.

$$h_c = \eta \bar{r} \quad \text{siendo} \quad \bar{r} = \frac{1}{N_{P_i}} \sum_{i=1}^{N_{P_i}} \|\overrightarrow{P_i P_g}\| \quad (3.3.11)$$

4. **Creación de la red de interpolación 3D.** A partir de los puntos  $P_i$  y la estimación de la altura del cítrico, se creará la red de interpolación 3D. Dicha red tendrá como entradas las coordenadas  $(x, y)$  de los nodos de la red y como salida la altura de dichos nodos. Los nodos de la red de interpolación se han obtenido subdividiendo cada uno de los radios  $\|\overrightarrow{P_i P_g}\|$  en 20 subradios  $r_{ij}$  (con  $j = 1, \dots, 20$ ,  $i = 1, \dots, N_{P_i}$ ) y determinando las coordenadas  $x$  e  $y$  de cada subradio. Una vez determinados los nodos de la red de interpolación se estimará la altura de los mismos. Para ello se han modelizado elipses en los  $N_{P_i}$  planos transversales a la escena, de semiejes  $a = \|\overrightarrow{P_i P_g}\|$  y  $b = h_c$ , cuya ecuación viene dada para cada radio  $\|\overrightarrow{P_i P_g}\|$  por la siguiente ecuación:

$$\frac{r_{ij}^2}{\|\overrightarrow{P_i P_g}\|^2} + \frac{h_{ij}^2}{h_c^2} = 1 \quad (3.3.12)$$

Mediante la ecuación (3.3.12) se pueden determinar las alturas  $h_{ij}$  de los nodos de la red de interpolación. En la figura 3.9 se muestran las alturas  $h_{ij}$  correspondientes al plano transversal definido por la altura y el radio  $\|\overrightarrow{P_i P_g}\|$ . Repitiendo este procedimiento para los  $N_{P_i}$  planos transversales queda perfectamente determinada la red de interpolación 3D.



**Figura 3.9:** a) Nodos del plano transversal  $\|\overrightarrow{P_i P_g}\|$  de la red de interpolación 3D. b) Resultado de aplicar el modelo DEM sobre la imagen RGB de la mandarina clemenules del ejemplo.

5. **Obtención de la elevación de cada píxel por interpolación.** A partir de la red de interpolación obtenida en la etapa anterior, se calcula la altura de cada uno de los píxeles del cítrico realizando una interpolación bilineal de todos los puntos del cítrico. De este modo se dispone de una matriz del tamaño de la imagen en la que cada elemento  $h_{uv}$  suministra la altura del píxel ubicado en  $y = u$ ,  $x = v$ . En la figura 3.9b) se muestra el resultado de corregir el DEM con la imagen RGB mostrada en la figura 3.8a).

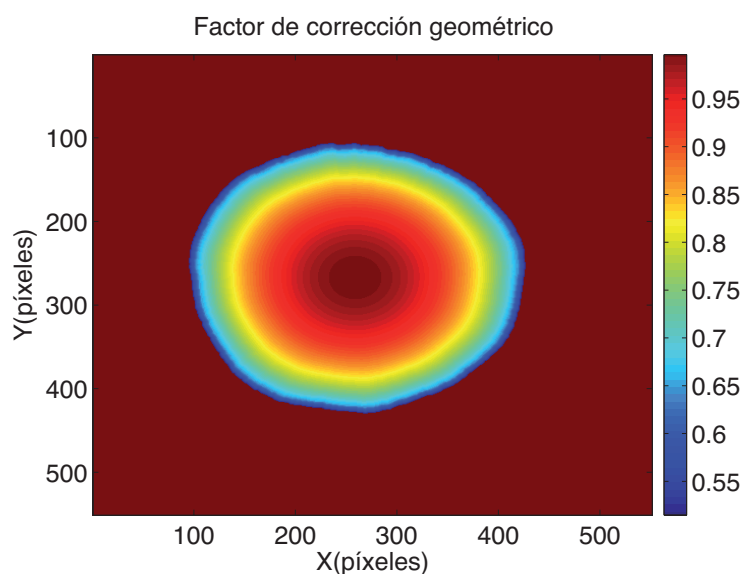
### Factor de corrección geométrico

De la expresión del factor de corrección  $\epsilon_g(x, y, \lambda)$ , (3.3.10), se deduce que es necesario conocer el valor de  $\phi$  para cada píxel de la imagen. El DEM de cada cítrico proporciona la elevación de cada píxel  $h_{xy}$ , y mediante una transformación a coordenadas esféricas se puede determinar el valor de  $\phi$  mediante:

$$\tan(\phi) = \frac{(x^2 + y^2)^{1/2}}{h_{xy}} \quad (3.3.13)$$

donde  $x, y, h_{xy}$  son las coordenadas cartesianas de cada píxel del fruto.

Siguiendo esta metodología se puede calcular el factor de corrección geométrico para todos los píxeles de una imagen. En la figura 3.10 se observa un gráfico de líneas de contorno que muestra el factor de corrección geométrico para una mandarina del cultivar clemenules. En el mismo gráfico se observa que éste es mayor en las zonas de la periferia del cítrico.




**Figura 3.10:** Factor geométrico  $\epsilon_g(x, y, \lambda)$  para una mandarina del cultivar clemenules.


### 3.3.4. Ensayos de evaluación de la técnica de preprocesado

Con el fin de evaluar la metodología de corrección propuesta se ha adquirido un conjunto de imágenes hiperespectrales de cítricos. En concreto, se han empleado 40 mandarinas, de las cuales 20 son cv. clemenvilla (que generalmente presentan una forma muy esférica) y 20 cv. clemenules (con una forma un poco más irregular que las anteriores). Se eligieron mandarinas en lugar de otras frutas con forma más esférica, como por ejemplo naranjas, con el fin de probar la metodología en las peores condiciones de trabajo. Las frutas se eligieron aleatoriamente de una línea de confección de un almacén de cítricos local, sin ningún tipo de defecto aparente. Se adquirieron dos imágenes hiperespectrales de cada fruto, desde 460 nm hasta 1020 nm con una resolución espectral de 10 nm. La diferencia entre las dos imágenes de la misma fruta radica en que en la segunda imagen el cítrico se rotó  $45^\circ$  respecto a la primera. Con esto se pretende disponer de regiones del cítrico que en una imagen estén en la zona central y en la otra en la periferia. A la conclusión se dispone de 118 imágenes monocromáticas de cada fruto, que suman un total de 4270 imágenes monocromáticas de los 40 cítricos empleados en este experimento. La figura 3.11 muestra imágenes monocromáticas de una mandarina sin corregir en diferentes bandas.

Se han diseñado una serie de experimentos con el fin de validar la metodología de preprocesado. El primero consiste en adquirir y comparar los espectros promedios de cuatro regiones diferentes de los frutos antes y después de la corrección. El propósito del primer experimento es probar que regiones pertenecientes a la misma clase (piel sana) tienen diferentes firmas espectrales



**Figura 3.11:** Imágenes monocromáticas de una mandarina cv. clemenules adquirida a 540, 640, 860 y 980 nm.



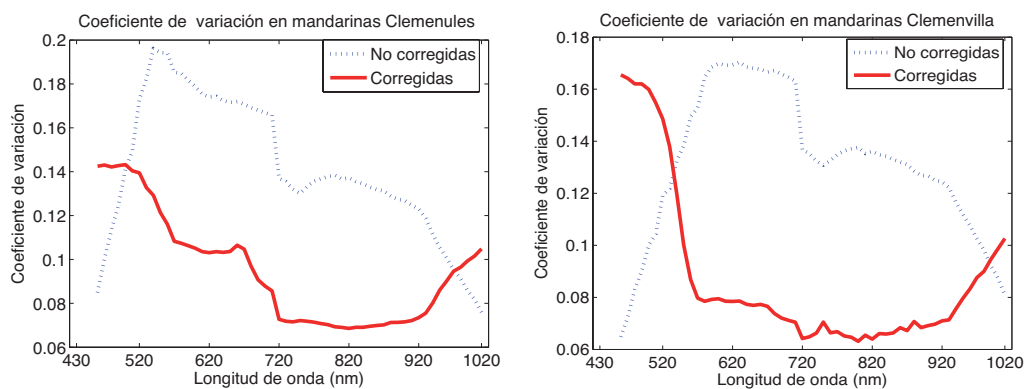
**Figura 3.12:** Regiones en las que se va a comparar la reflectancia: (Izquierda) Imagen de un fruto mostrando la región a analizar. (Derecha) El mismo fruto después de ser rotado 45°.

dependiendo de la posición que ocuparan en el cítrico.

Un segundo experimento se diseñó para comprobar que la misma región del fruto presenta una reflectancia similar en la imagen del fruto a 0° y la correspondiente al fruto rotado 45°. Con este experimento se prueba que la corrección se comporta de igual manera en cualquier zona de la imagen. Se midió la reflectancia de 50 píxeles de una región de interés con forma lineal en la parte central del fruto (figura 3.12 izquierda). Se identificó la misma región en la imagen del fruto rotado 45° (figura 3.12 derecha). La diferencia básica entre las dos imágenes es que, en la segunda imagen, la región de interés señalada está más próxima al borde que en la primera imagen. Se midieron los valores de reflectancia de los píxeles pertenecientes a la región de interés en las corregidas y sin corregir. Idealmente se debería observar que los valores de reflectancia son menores en la región de interés más próxima al borde en la segunda imagen, si no se ha aplicado ninguna corrección. Por el contrario, si se repite la experiencia en imágenes corregidas, los valores de reflectancia tienen que tomar valores similares. Finalmente, se estudió el grado de correlación entre ambas medidas (región de interés del centro y de la periferia), para ello se analizó la regresión lineal, para cada fruto, entre los píxeles de las dos regiones, y se promedió los resultados de media y ordenada en el origen sobre todas las bandas.

### 3.4. Resultados

La figura 3.13 muestra el coeficiente de variación (desviación típica entre la media) para los dos cultivares estudiados, utilizando imágenes corregidas y sin corregir. En la misma figura se puede observar que, en la mayor parte del rango espectral, el coeficiente de variación es menor para las imágenes corregidas, esto confirma que la variación en la reflectancia de los píxeles del borde y del centro es menor en las imágenes corregidas en comparación con las imágenes sin corregir. Este resultado no se verifica por debajo de 500 nm y por encima de 1000 nm debido a la baja eficiencia que el sistema de visión hiperespectral presenta en estas regiones del espectro.



**Figura 3.13:** Coeficiente de variación en imágenes corregidas y sin corregir: (Izquierda) cv. clemenules y (Derecha) cv. clemenvilla.

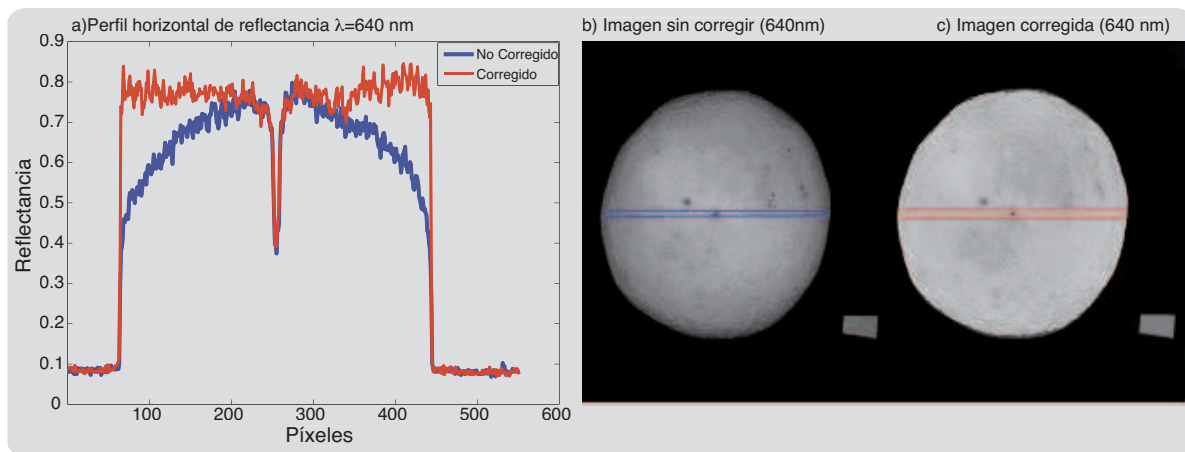
La tabla 3.1 muestra los valores promedio y la desviación típica del factor de corrección geométrico  $\epsilon_g$  para los dos cultivares de cítricos estudiadas. En la misma tabla se puede observar que  $\epsilon_g$  toma valores similares para ambos cultivares. No obstante, las mandarinas cv. clemenvilla presentan valores menores que las mandarinas cv. clemenules, lo cual es debido a que presenta una esfericidad más regular que el otro.

	Media	Desviación típica
<b>Cv. Clemenules</b>	0.8241	0.1209
<b>Cv. Clemenvilla</b>	0.7913	0.1246

**Tabla 3.1:** Media y desviación típica de  $\epsilon_g$  para mandarinas de los cultivares cv. clemenules y cv. clemenvilla.

A modo de ejemplo, las figuras 3.14b) y 3.14c) muestran dos imágenes del mismo fruto adqui-

rido a una longitud de onda de 640 nm. La primera imagen (figura 3.14b) muestra la imagen del cítrico sin corregir. En contraste con esa imagen se observa la imagen corregida (figura 3.14c) utilizando la metodología propuesta en este capítulo. Antes de aplicar la corrección se puede observar cómo las zonas de la periferia del cítrico aparecen oscurecidas respecto al centro de las misma, a pesar de presentar todo el cítrico una piel homogénea. Este hecho se debe a que la geometría esférica del cítrico provoca que la radiación que capta la cámara proveniente de la zona central del cítrico sea mayor que la de las zonas periféricas. Después de obtener el DEM del fruto y aplicar la corrección del factor geométrico se observa una imagen con unos niveles de intensidad mucho más uniformes en toda su superficie.

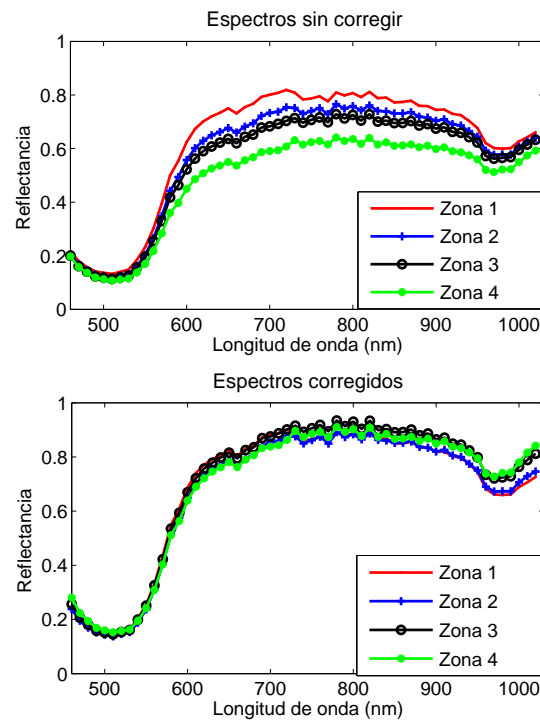


**Figura 3.14:** a) Perfil de reflectancia en la región ecuatorial. Imagen monocromática de una mandarina del cultivar cv. clemenvilla en 640 nm sin corregir b) y corregida c).

Este hecho se pone de manifiesto de una manera más visible en la figura 3.14a) que representa el nivel de reflectancia de un perfil del ecuador del cítrico mostrado en la misma figura. El perfil de la imagen sin corregir (azul) presenta una forma de campana, lo cual pone de manifiesto cómo la forma del cítrico modula la cantidad de radiación que recibe la cámara. En la misma figura se observa cómo tras aplicar la corrección (rojo) el perfil se aplana considerablemente. Este efecto se aprecia en todos los frutos estudiados, así como en los dos cultivares analizados.

La figura 3.15 (arriba) muestra el espectro promedio correspondiente a una vecindad de  $5 \times 5$  píxeles de cuatro zonas sanas de una mandarina cv. clemenules, muestreadas en una imagen hiperespectral sin corregir. En dicha figura se observa un elevado grado de variabilidad de los cuatro espectros, a pesar de pertenecer a regiones homogéneas del cítrico situadas en regiones dispersas. Esta elevada variabilidad hace que sea difícil caracterizar espectralmente una determinada clase (en este caso piel sana) y dificulta el correcto funcionamiento de un clasificador. En la figura 3.15 (abajo) se observan los espectros correspondientes a las mismas zonas, pero calculados a partir

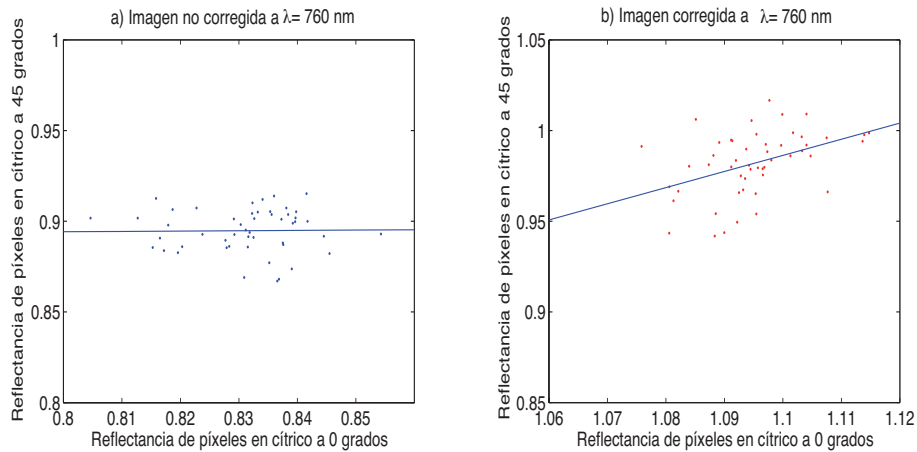
de las imágenes corregidas. En dicha figura se observa una notable reducción de la variabilidad de los espectros hasta el punto de solaparse. Este resultado se repite en los dos cultivares estudiados, sin importar que zonas del cítrico se evalúen.



**Figura 3.15:** Espectros promedio (ventana 5 píxeles  $\times$  5 píxeles) de 4 zonas de una mandarina cv. clemenules (Arriba) correspondiente a piel sana sin aplicar la corrección del factor geométrico. (Abajo) Correspondiente a piel sana aplicando la corrección del factor geométrico.

Los píxeles de las cuatro zonas seleccionadas se corresponden con regiones sanas del cítrico, y que por lo tanto pertenecerían a la misma clase en un problema de clasificación. En las imágenes no corregidas los píxeles de las zonas centrales difieren considerablemente de los que pertenecen a la periferia, contribuyendo así a aumentar la variabilidad interclase. Por el contrario, en las imágenes corregidas la variabilidad se reduce drásticamente, la desviación típica se reduce en un 41 % en las imágenes a las que se les ha aplicado la metodología propuesta. Al reducirse la variabilidad interclase se facilita considerablemente la etapa de segmentación en un sistema de inspección automática.

Los resultados del segundo ensayo, realizado para evaluar el rendimiento de la metodología propuesta, son coherentes con los obtenidos en el anterior ensayo, en cuanto a que se homogeneiza la imagen del fruto tras aplicar la corrección. En la figura 3.16 se muestran los resultados del



**Figura 3.16:** Representación de la reflectancia de una región lineal de 50 píxeles obtenidos de dos imágenes del mismo fruto rotado  $45^\circ$ : a) imágenes sin corregir, b) imágenes corregidas. El ajuste por mínimos cuadrados para la imagen sin corregir proporciona el siguiente ajuste  $y = (0,135 \pm 0,017)x - (0,784 \pm 0,013)$  y  $R^2 = 0,9891$ . Para la imagen corregida el ajuste ha sido  $y = (0,989 \pm 0,018)x - (0,097 \pm 0,017)$  y  $R^2 = 0,9921$ .

segundo ensayo en la banda de  $\lambda = 760$  nm. En el eje X de dicha figura se representa el valor de la reflectancia de una región con forma lineal de la imagen sin rotar (región localizada en la parte central del cítrico), en el eje Y se representa el valor de la reflectancia de la misma región en la imagen rotada  $45^\circ$  (ahora localizada en la periferia del cítrico). La figura 3.16a) muestra que en la imagen sin corregir la correlación entre los dos perfiles es muy baja. En este caso, la pendiente toma un valor bajo significativamente diferente de 1, y la ordenada en el origen toma un valor significativamente diferente de 0. Este efecto se minimiza en las imágenes corregidas (figura 3.16b) donde la pendiente se aproxima a 1 y la ordenada en el origen se acerca a 0.

Después de realizar este ensayo sobre cada fruto, y promediando sobre todas las bandas del espectro se obtiene, para las imágenes sin corregir, una pendiente de  $(0,342 \pm 0,019)$  y una ordenada en el origen de  $(0,537 \pm 0,012)$ . Este resultado contrasta con el obtenido para las imágenes corregidas, obteniéndose una pendiente de  $(0,951 \pm 0,019)$  y una ordenada en el origen de  $(0,123 \pm 0,017)$ . Estos resultados prueban que la metodología de corrección propuesta permite obtener la reflectancia de una región, independientemente de su localización en el cítrico.

### 3.5. Conclusiones

Las imágenes hiperespectrales de los frutos cítricos presentan un oscurecimiento gradual de los píxeles al alejarse del centro, lo cual dificulta el análisis de la imagen. En este capítulo se



ha propuesto una metodología para corregir los efectos adversos producidos por la curvatura esférica de los cítricos en la adquisición de imágenes hiperespectrales. La metodología propuesta considera la superficie del cítrico como una superficie Lambertiana elipsoidal y produce un modelo 3D del cítrico (DEM). A partir de este modelo se ha cuantificado la cantidad de radiación que debería alcanzar el CCD de la cámara, y no lo hace debido a la geometría del fruto. A partir de esta cuantificación se puede uniformizar y determinar el nivel de reflectancia del fruto en todas las regiones del mismo. Se ha llevado a cabo una serie de experimentos con el fin de evaluar el rendimiento de la metodología propuesta. Estos experimentos han puesto de manifiesto que la metodología propuesta minimiza los efectos adversos introducidos por la geometría esférica de los frutos cítricos.



## Capítulo 4

# Detección hiperespectral de podredumbres producidas por *Penicillium digitatum* en cítricos

### 4.1. Introducción

La detección temprana de infecciones por hongos en postcosecha de cítricos es especialmente importante para la industria, ya que un número reducido de frutas infectadas puede contaminar una partida completa provocando grandes pérdidas económicas. El daño postcosecha más importante en los almacenes citrícolas lo causa la familia de hongos *penicillium* (Eckert and Eaks, 1989). En la actualidad, la detección de cítricos podridos se lleva a cabo por operarios utilizando luz ultravioleta y la fruta se retira de la línea de confección manualmente. Sin embargo, este proceso no está exento de problemas ya que la exposición de las personas a este tipo de iluminación resulta dañina, hecho que motiva un elevado número de rotaciones de los turnos de trabajo de los operarios. Una posible solución a este problema puede venir del uso de los sistemas automáticos de visión por computador, como los que ya se utilizan para estimar parámetros morfológicos como tamaño, forma, color o detectar la presencia de otros daños. Existen pocos trabajos científicos que traten sobre la detección de daños en cítricos utilizando técnicas de minería de datos (Kondo et al., 2000; Miller and Drouillard, 2001; Aleixos et al., 2002). Algunos daños, como las podredumbres, son especialmente difíciles de detectar utilizando sistemas convencionales de visión por computador, ya que estos defectos son difícilmente visibles a simple vista por el ojo humano. En Blasco et al. (2007b,a) se propone una serie de técnicas de análisis de imagen para detectar daños, tanto de tipo supervisado como no supervisado, y en ningún caso, la combinación de un sis-

tema convencional RGB e iluminación visible produce tasas de acierto adecuadas en la detección de podredumbres.

El empleo de sensores hiperespectrales permite adquirir imágenes en longitudes de onda específicas, lo cual hace posible realizar análisis más complejos de la escena. A partir de una imagen hiperespectral se puede obtener la firma espectral (espectro) de un píxel y a partir de la misma se puede tratar de detectar defectos como las podredumbres de una manera más eficaz que con los sistemas RGB convencionales. Uno de los principales inconvenientes que presentan los sistemas hiperespectrales es la gran cantidad de datos que generan (Chang, 2003). Mientras que los sistemas RGB convencionales proporcionan tres imágenes correspondientes a las bandas del rojo, verde, y azul, una imagen hiperespectral está constituida por un conjunto extenso de imágenes monocromáticas. Este hecho incrementa la complejidad del análisis de este tipo de imágenes y aumenta el tiempo requerido para extraer información de las mismas por un sistema automático. Por esta razón, es importante seleccionar sólo aquellas bandas que contienen la información más relevante para el problema que se está tratando, y descartar aquéllas que no contribuyen significativamente al problema de inspección.

En la literatura científica se pueden encontrar muchos ejemplos de métodos de selección de características utilizados para seleccionar las bandas más relevantes en problemas hiperespectrales, como por ejemplo el análisis de correlaciones (CA) (Lee et al., 2005), métodos basados en análisis de la información mutua (MI) (Martínez-Sotoca and Plá, 2006), *Stepwise Regression* (SW) (Yang et al., 2004) y algoritmos genéticos (GA) (Yao and Tian, 2003).

Una vez identificadas las bandas más relevantes de la imagen hiperespectral, la detección de podredumbres se convierte en un problema de clasificación de píxeles. Existen técnicas de clasificación de propósito general ampliamente utilizadas en problemas que presentan una elevada dimensionalidad, como por ejemplo los árboles de clasificación y regresión (CART). Esta técnica se propuso para resolver problemas de clasificación y regresión de propósito general (Breiman et al., 1998), extendiéndose rápidamente en diversos campos de aplicación como la detección temprana de plagas (Lawrence and Labus, 2003) o la extracción de conocimiento de imágenes hiperespectrales de satélite (Gómez-Chova et al., 2003). Los métodos de clasificación basados en CART generalmente proporcionan mejores resultados que los clasificadores lineales, como por ejemplo el análisis discriminante lineal (LDA) (Duda et al., 2001).

## 4.2. Objetivos

En este capítulo de la Tesis Doctoral se va a estudiar la posibilidad de detectar podredumbres producidas por el hongo *Penicillium digitatum* en estados tempranos de infección en mandari-

nas, utilizando iluminación halógena convencional, un sistema de visión hiperespectral y técnicas estadísticas sin incluir información espacial del píxel.

1. Se van a emplear una serie de métodos de selección de características para reducir la dimensionalidad de las imágenes hiperespectrales, seleccionando las bandas más relevantes. En concreto los métodos evaluados serán CA, MI, SW y GA basado en LDA (GALDA).
2. En combinación con los métodos de selección de características evaluados se emplearán técnicas de clasificación lineales (LDA) y no lineales (CART) para segmentar las imágenes hiperespectrales y detectar la podredumbre con el menor número de bandas posible utilizando el sistema propuesto.
3. Elaborar un clasificador de mandarinas que discrimine fruta podrida por el hongo *Penicillium digitatum* de la que no lo está. Este clasificador utilizará como entrada el porcentaje de píxeles podridos en la piel del fruto. El sistema de decisión estará basado en comparar esta característica con un umbral fijado de manera empírica.


## 4.3. Materiales y métodos

### 4.3.1. Sistema de adquisición de imagen y material vegetal

El sistema de visión hiperespectral empleado, así como todos los parámetros de configuración (sistema de iluminación, tiempos de integración, tamaño de las imágenes, resolución espacial y rango espectral) es como el empleado en los ensayos del capítulo 3. Para realizar los experimentos desarrollados en este capítulo de la Tesis Doctoral se han empleado mandarinas cv. clemenules (*Citrus clementina Hort. ex Tanaka*) y cv. clemenvilla (*Citrus reticulata Hort. ex Tanaka*) debido a su importancia económica en España. Los cítricos se han seleccionado aleatoriamente de una línea de confección de un almacén de distribución de cítricos. Se utilizaron 200 frutos de cada cultivar, de los cuales 150 fueron inoculados con una disolución de esporas *Penicillium digitatum* en suspensión con una concentración de esporas de  $10^6$  esporas/ml. Esta concentración es más que suficiente para producir la infestación de los frutos (Palou et al., 2001). El resto de mandarinas de cada cultivar fueron inoculadas con una disolución inocua de agua, que no produce podredumbres, para fines de control. Los frutos se almacenaron durante tres días en atmósfera controlada de 25 °C y una humedad relativa del 99%. Después de este periodo, todas las mandarinas inoculadas presentaban un daño por *Penicillium digitatum* en una etapa temprana de formación, con un diámetro de entre 10 mm y 25 mm.

El color de este tipo de daños es similar al color de la piel sana alrededor del defecto. Este hecho hace que la detección visual por un operario sea especialmente difícil. Las imágenes hiperespec-


trales fueron adquiridas situando cada fruto en la cámara de inspección manualmente con la zona dañada hacia la cámara. Se adquirió una secuencia de imágenes monocromáticas desde 460 nm hasta 1020 nm con una resolución espectral de 10 nm. Las imágenes hiperespectrales adquiridas están compuestas por 57 imágenes monocromáticas de cada fruto, por lo que se obtuvieron 22800 imágenes monocromáticas. La figura 4.1 muestra imágenes monocromáticas (550 nm, 660 nm y 950 nm) y RGB de varias mandarinas cv. clemenules afectadas por el hongo. De manera análoga la figura 4.2 muestra imágenes RGB e imágenes monocromáticas (580 nm, 640 nm y 960nm) de varias mandarinas cv. clemenvilla. Como se observa en ambas figuras, en las imágenes RGB, el daño es difícilmente visible por el ojo humano.



**Figura 4.1:** Imágenes RGB y monocromáticas (550 nm, 660 nm y 950 nm) de mandarinas cv. clemenules afectadas por el hongo *Penicillium digitatum*

### 4.3.2. Preprocesado de imágenes hiperespectrales

El sistema de iluminación empleado produce ligeras variaciones espaciales en la intensidad del iluminante sobre el plano de la escena. Además la forma esférica de las mandarinas produce cambios en la reflectancia observada por el sistema de los píxeles dependiendo de la posición que




**Figura 4.2:** Imágenes RGB y monocromáticas (580 nm, 640 nm y 960 nm) de varias mandarinas cv. clemenvilla afectadas por el hongo *Penicillium digitatum*.

ocupa el píxel en la fruta. Estos fenómenos fueron discutidos en profundidad en el capítulo 3 y para minimizar su efecto se ha empleado la metodología de preprocesado descrita en el mismo capítulo. En primer lugar se ha abordado la corrección de las variaciones espaciales del iluminante, para ello se realiza el cociente entre la radiancia observada de cada píxel y la intensidad del iluminante adquirida a partir de un blanco de referencia (Gómez-Sanchis et al., 2006). Esta corrección no tiene en cuenta en ningún momento la geometría del cítrico, ya que el blanco de referencia que se ha empleado es plano. Para solventar este problema se ha realizado otra corrección basada en considerar el fruto como una superficie Lambertiana y realizar un modelo de elevación digital del cítrico (Gómez-Sanchis et al., 2008c). Estas correcciones están detalladas en la secciones 3.3.2 y 3.3.3 de esta Tesis Doctoral. La figura 4.5 muestra el resultado de aplicar el preprocesado arriba descrito sobre dos imágenes monocromáticas de mandarinas cv. clemenules.

### 4.3.3. Conjunto de datos etiquetado

La naturaleza supervisada del planteamiento del problema que se está tratando hace que sea necesario construir un conjunto compuesto por  $n$  muestras etiquetadas,  $\{x_i, y_i\}_{i=1 \dots n}$  donde  $x_i$






**Figura 4.3:** Imágenes sin preprocesar y preprocesadas de mandarinas clemenules adquiridas en 560 nm, 670 nm y 980 nm.

representa un vector de características  $m - dimensional$  perteneciente a la clase  $y_i$ . En nuestro problema  $m$  representa el número de bandas e  $y$  todas las posibles clases presentes en el problema de clasificación tratado. Sobre el conjunto de imágenes adquiridas y preprocesadas se han seleccionado manualmente  $n = 300000$  píxeles, de los cuales 150000 pertenecen a mandarinas clemenules y el resto a mandarinas clemenvilla. Cada patrón contiene 57 valores de reflectancia (uno por cada banda adquirida) y una clase que ha sido asignada por un experto. Las clases definidas para las mandarinas cv. clemenules son “piel sana” (PS), “piel podrida” (PP), “piel esporulada”<sup>1</sup> (PE) y “pedúnculo” (P). En las mandarinas cv. clemenvilla se han definido las mismas clases excepto la clase P ya que en este cultivar las imágenes de las mandarinas se adquirieron por la parte opuesta al pedúnculo. La figura 4.4 muestra los espectros promedios de cada clase en el conjunto de datos etiquetado para las mandarinas cv. clemenules (izquierda) y cv. clemenvilla (derecha).

En la misma figura se observa que, en ambos cultivares, la principal dificultad para un clasificador radica en distinguir las clases PS y PP debido al elevado solapamiento que presentan estas clases en el conjunto de datos. El conjunto etiquetado se ha dividido en dos conjuntos: un conjunto de entrenamiento compuesto por 120.000 muestras (40 % del total) y un conjunto de

<sup>1</sup>Piel podrida con esporas del hongo *Penicillium digitatum*.





**Figura 4.4:** Espectros promedio por clase en el conjunto de entrenamiento para el cultivar cv. clemenules (izquierda) y cv. clemenvilla (derecha).

validación compuesto por 180.000 muestras (60% del total). El primer conjunto se ha utilizado para elaborar los modelos de selección de características y de clasificación, y el segundo para evaluar el rendimiento de los mismos.

#### 4.3.4. Reducción de la dimensionalidad

En esta parte del capítulo se van a describir las técnicas de selección de características empleadas en el problema de clasificación planteado con el fin de reducir la dimensionalidad del mismo. La selección de características consiste en elegir el subconjunto de características más relevantes en el problema de clasificación. Los métodos de selección de características se pueden agrupar en dos grandes categorías (Guyon and Elissee, 2003): *filter* (Blum and Langley, 1998) y *wrapper* (Kohavi and John, 1997). Los primeros utilizan una medida indirecta para evaluar la calidad de la selección realizada. Un ejemplo de este tipo de medida es el cálculo de la correlación entre cada característica y la variable dependiente (clase) del problema de clasificación. Esta familia de métodos se caracterizan por su rápida convergencia. Por otra parte, los métodos *wrapper* se caracterizan por utilizar la calidad del ajuste realizado entre las entradas y las salidas de un clasificador (como por ejemplo una red neuronal) como criterio a optimizar para realizar la selección. En este capítulo se va a evaluar el rendimiento de cuatro métodos de selección de características pertenecientes a las aproximaciones citadas con el fin de determinar las bandas más relevantes para discriminar las clases anteriormente descritas.

Los ensayos realizados se han encaminado a seleccionar el número mínimo de bandas que maximiza la tasa de éxito en el problema de clasificación de píxeles. Para ello se ha estudiado la evolución de la tasa de éxito en la clasificación con el número de bandas seleccionadas empleando

dos clasificadores: en concreto un análisis discriminante lineal y un árbol de clasificación y regresión. Los cuatro métodos de selección empleados han sido: CA, MI, SW y GALDA. Tanto los métodos de selección como los de clasificación se han implementado utilizando Matlab 7.0. Todas las variables presentes en el conjunto de entrenamiento han sido normalizadas, se les ha eliminado la media y dividido por la desviación estándar de cada variable con el fin de uniformizar los rangos de variación de todas las variables. Los cuatro métodos de selección se programaron para incrementar iterativamente el número de bandas seleccionadas ( $k$ ) de 4 a 57. Las bandas obtenidas en cada iteración se utilizaron para clasificar los píxeles del conjunto etiquetado con los dos clasificadores antes mencionados (LDA y CART) y obtener la tasa de éxito promedio para cada número de bandas seleccionadas utilizando el conjunto de entrenamiento. A continuación se va a realizar una breve descripción de cada uno de los cuatro métodos de selección de características.

### Análisis de correlaciones

Una forma ampliamente utilizada para descubrir las posibles relaciones (lineales) entre las variables de entrada y salida de un problema de clasificación es mediante el uso de la función de correlación (Hair et al., 1995). Además, CA es una técnica muy extendida para detectar y eliminar información redundante en imágenes hiperespectrales (Gómez-Chova et al., 2003; Lillesand et al., 2004; Swain, 1978). Dicho análisis también se ha utilizado previamente para eliminar información redundante en imágenes hiperespectrales de cítricos (Gómez-Sanchis et al., 2005). Esta técnica proporciona un método sencillo, a la vez que potente, para seleccionar bandas próximas entre sí altamente correlacionadas debido a la elevada resolución espectral del sistema de adquisición.

Se define la correlación lineal  $r_{x_j y}$  entre dos variables aleatorias  $x_j$  e  $y$  definidas por dos conjuntos de datos  $x_j = [x_{j1} \cdots x_{jn}]$  y  $y = [y_1 \cdots y_n]$  como:

$$r_{x_j y} = \frac{\sum_{i=1}^n (x_{ji} - \bar{x}_j) \cdot (y_i - \bar{y})}{(\sum_{i=1}^n (x_{ji} - \bar{x}_j)^2 \sum_{i=1}^n (y_i - \bar{y})^2)^{1/2}} \quad (4.3.1)$$

siendo  $\bar{x}_j$  y  $\bar{y}$  los valores medios de las variables mencionadas.

El valor absoluto de  $r_{x_j y}$  toma valores comprendidos entre 0 y 1: el valor 0 indica que dos variables no están correlacionadas, y 1 que sí están correlacionadas. El principal inconveniente que presenta el uso de esta técnica es el bajo rendimiento de la misma si el número de muestras es reducido o si la relación entre las variable no es lineal. Se ha utilizado este método como punto de partida para compararlo con métodos más complejos de selección de características. El procedimiento utilizado para utilizar la correlación como método de selección de características fue calcular los coeficientes de correlación de cada banda con la variable clase. El siguiente paso consiste en seleccionar las  $k$  bandas que tienen una mayor correlación.

### Función de información mutua

Los métodos que exploran relaciones lineales entre los datos, como CA, no son capaces de captar relaciones no lineales entre diferentes conjuntos de características y la clase a la que pertenecen los datos. La función de información mutua proporciona una forma de medir la relación general existente entre variables, en lugar de la relación lineal entre las mismas (como en el caso de CA). Cuando los datos son resultado de un proceso aleatorio es posible evaluar la relevancia de cada variable con respecto a las demás por medio de una función de información mutua (Batiti, 1994). La selección de características basada en MI se utiliza con frecuencia en problemas en los que se pretende buscar relaciones complejas entre las características de los datos y el análisis de correlaciones es propenso a ocasionar problemas.

La función de información mutua entre dos variables aleatorias  $x_j$  (correspondiente a una característica del conjunto de datos) e  $y$  (correspondiente al conjunto de todas las  $N_c$  posibles clases  $c$  presentes en el problema de clasificación), de las que disponemos de  $n$  muestras, se puede definir a partir de la función de entropía,

$$J(y) = - \sum_{c=1}^{N_c} P(c) \log P(c) \quad (4.3.2)$$

y la función de entropía condicional

$$J(y|x_j) = - \sum_{i=1}^n P(x_{ji}) \sum_{c=1}^{N_c} P(c|x_j) \log P(c|x_j) \quad (4.3.3)$$

Teniendo en cuenta que MI se define como la cantidad que se reduce la entropía al introducir información sobre las características de un patrón, se puede expresar la información mutua entre dos variables  $x_j$  e  $y$  como

$$MI(y, x_j) = J(y) - J(y|x_j) \quad (4.3.4)$$

de donde, sustituyendo (4.3.2) y (4.3.3) se obtiene:

$$MI(y, x_j) = - \sum_{i=1}^n \sum_{c=1}^{N_c} P(c|x_j) \log \frac{P(c|x_j)}{P(c)P(x_j)} \quad (4.3.5)$$

La forma de utilizar este método para seleccionar características en esta Tesis Doctoral ha sido calcular la función de información mutua (MI, mostrada en la ecuación (4.3.5)) entre cada banda y la variable clase. Para ello se ha tenido que discretizar el rango de variación de cada variable para poder calcular las probabilidades presentes en la ecuación (4.3.5). El rango de variación de

cada variable se ha dividido, de manera empírica en 20 celdas. A continuación se seleccionaron las  $k$  bandas con mayor valor de MI. Analizando la ecuación (4.3.5) se verifica que MI cumple las premisas de iniciales en cuanto a que dicho método evalúa la interdependencia entre las variables desde un punto vista probabilístico sin exigir linealidad entre las variables implicadas.

### ***Stepwise multivariate regression***

SW es un método de selección de características cuyo criterio para seleccionar variables es construir un modelo de regresión multivariada óptimo (Hair et al., 1995). Esta técnica se caracteriza por seguir un proceso iterativo de inclusión y exclusión de características con el fin de evaluar el impacto que ello produce en la exactitud y la significancia estadística. La premisa en la que se basa este método es que si un grupo de características de entrada del modelo no presenta una manifiesta dependencia lineal con la salida, su presencia hace que empeore la significancia estadística del mismo. La forma de evaluar la significancia estadística del modelo es construir un modelo inicial simple y otro en el que se ha variado el número de variables de entrada. En cuanto a la inclusión o exclusión de variables, en cada iteración se evalúa el *p-value* del estadístico  $F$ . Si una variable no resulta estadísticamente significativa, al incluirla en el modelo, su correspondiente coeficiente debería ser cero, de este modo se confirmaría la hipótesis nula desde el punto de vista estadístico. Utilizando como indicador el coeficiente *p-value* se puede rechazar la hipótesis nula y así incluir dicha variable en el modelo. En concreto, en este trabajo se ha considerado que si una variable no está en el modelo y tiene un valor de *p-value* menor que 0.05, es probable que se pueda rechazar la hipótesis nula y se añadirá dicha variable al modelo. Por el contrario, si una variable está en el modelo y su *p-value* es mayor que 0.1, no es probable que se pueda rechazar la hipótesis nula. Por tanto, dicha variable se elimina del modelo. El método SW ofrece dos variantes dependiendo del número de variables de las que parte el modelo, se puede partir del conjunto completo de variables e ir eliminando las innecesarias o, por el contrario se puede partir de un conjunto vacío de variables e ir incluyendo las necesarias. En este trabajo se ha supuesto que inicialmente no hay variables en el modelo y se han ido añadiendo posteriormente. La búsqueda concluye cuando no hay mejoras de un paso de inclusión/exclusión de variables a otro.

### **Algoritmos genéticos basado en LDA**

Los algoritmos genéticos constituyen un tipo de técnicas de aprendizaje automático cuya filosofía se basa en la teoría de la variación genética a partir de “la selección natural”. Los algoritmos genéticos se caracterizan por ser una familia de algoritmos de búsqueda exhaustiva que opera sobre poblaciones de individuos (palabras binarias) para producir poblaciones mejor adaptadas utilizando una serie de operadores matemáticos en base a optimizar algún tipo de función de

coste (Goldberg, 1989). En este trabajo las poblaciones de individuos están formadas por vectores binarios con tantas componentes como bandas presentes en el problema de clasificación, en las que cada  $1$  se corresponde con una banda seleccionada, y cada  $0$  con una que no se utilizará en el modelo. El uso de algoritmos genéticos para seleccionar características está especialmente indicado en problemas de clasificación en los que el número de características es muy elevado (Ma et al., 2003). Ésta precisamente es la situación que se presenta en el problema de la detección de podredumbres utilizando imágenes hiperespectrales. Cualquier algoritmo genético utiliza una función de coste con el fin de evaluar los grupos de bandas obtenidos en cada generación (iteración). Los individuos (o grupos de bandas) con mayor valor de la función de coste son los que presentarán una mayor probabilidad de ser propagados a la siguiente generación. Se ha utilizado como función de coste el acierto global proporcionado por un análisis discriminante lineal, de este modo se denominará de ahora en adelante a este método de selección GALDA. La implementación del algoritmo genético que se ha utilizado es la presente en Matlab 7.0, en concreto en la *toolbox* “Genetic Algorithms and Direct Search”. El fundamento teórico del algoritmo genético de optimización utilizado se detalla en (Conn et al., 1997). El algoritmo genético presenta una serie de peculiaridades que se enumeran a continuación.

- Emplea una función de cruce aleatoria entre los genes de la generación predecesora. La función de cruce es la responsable de indicar cómo se recombinan las diferentes generaciones para producir las generaciones hijas. En concreto dicha función de cruce genera un vector binario en los que cada  $1$  se corresponde con los genes del primer predecesor y cada  $0$  se corresponde con los genes del segundo predecesor.
- La fracción de individuos creados en cada generación por la función de cruce es del 80%, donde este valor ha sido elegido de manera empírica.
- Para introducir mutaciones esporádicas en el transcurso de convergencia del algoritmo se ha empleado la función de mutación uniforme proporcionada por la misma *toolbox*.
- El número de individuos presentes en cada generación ha sido 100, donde este valor se ha elegido empíricamente para controlar la velocidad de convergencia del algoritmo.
- El algoritmo genético detiene el proceso iterativo en el momento en que no se mejora sustancialmente la función a optimizar durante 10 iteraciones.

#### 4.3.5. Segmentación de las imágenes

Se han empleado dos métodos de clasificación para segmentar las imágenes hiperespectrales de este experimento. La forma de segmentar estas imágenes parte de la asignación, mediante un

clasificador, de una de las cuatro clases descritas anteriormente en el conjunto de entrenamiento etiquetado a cada pixel de la imagen. Así pues, una vez clasificados todos los píxeles de una imagen se dispondrá del mapa de clasificación donde se podrán detectar las podredumbres. Para conseguir este propósito se han utilizado dos clasificadores: uno de tipo lineal (LDA) y otro de tipo no lineal (CART) con el fin comparar los resultados proporcionados por ambos y conocer la naturaleza del problema de clasificación que se está tratando. Tanto LDA como CART son clasificadores ampliamente utilizados en aplicaciones de análisis de imagen hiperespectral (Clark et al., 2005; Tatzert et al., 2005; Goel et al., 2003). Los modelos de clasificación se han construido utilizando el conjunto de entrenamiento etiquetado y las bandas proporcionadas por los métodos de selección anteriormente descritos. La validación de los modelos se ha realizado comparando los resultados proporcionados por ambos clasificadores sobre el conjunto de validación etiquetado. Para evaluar el rendimiento global de los clasificadores se ha empleado la tasa de acierto promedio y la kappa de Cohen ( $\kappa$ ) en ambos clasificadores (Fleiss, 1981) para cada una de las selecciones obtenidas en los ensayos de este capítulo de la Tesis Doctoral.


### Análisis discriminante lineal

LDA es una técnica estadística clásica utilizada habitualmente en problemas de clasificación. Se basa en obtener una transformación lineal  $G$  que maximiza la varianza entre clases  $S_e$  y minimiza la varianza entre los elementos de cada clase  $S_i$  de manera simultánea. La transformación del espacio vectorial original de características (dimensión  $N_f$ ) a través de  $G$ , constituye un nuevo espacio vectorial de menor dimensión (dimensión  $N_T \leq N_f$ ). LDA es una técnica de aprendizaje supervisada que se caracteriza por obtener un espacio vectorial transformado en el que las clases están máximamente separadas desde el punto de vista lineal. La diferencia con respecto a otro tipo de transformaciones como, por ejemplo, el PCA, es que esta técnica tiene en cuenta información supervisada del problema y no únicamente información sobre la distribución de los datos. Esta diferencia se ilustra en la figura 4.5.

A continuación se va describir formalmente los fundamentos de LDA. Sea un conjunto de datos  $X \in \mathfrak{R}^{N_f \times n}$  con  $n$  muestras y  $N_f$  características por muestra (cada patrón  $x_i$  distribuidas en las columnas de  $X$ ). LDA proporciona la transformación lineal  $G \in \mathfrak{R}^{N_f \times N_T}$  que, proyecta los patrones del conjunto de datos sobre un espacio vectorial de menor dimensionalidad.

$$G : x_i \in \mathfrak{R}^{N_f} \implies x_i^{LDA} = G^T x_i \in \mathfrak{R}^{N_T} \quad (4.3.6)$$

El algoritmo LDA proporciona el modo de obtener la transformación  $G$ , que mantiene la estructura y las relaciones topológicas de los datos originales en un espacio de dimensión reducida



**Figura 4.5:** En el gráfico se observa un conjunto de datos en los que la dirección de máxima varianza obtenida a partir de PCA no coincide con la dirección en los que las clases son separables, LDA.

(Fukunaga, 1990). Se asume que la clase a la que pertenece cada muestra es conocida y por tanto se puede subdividir el conjunto de datos original en  $N_C$  subconjuntos constituidos por las  $n_i$  muestras de cada clase, y caracterizado por un centroide  $c_i$ .

$$X = \left\{ x_1, x_2 \cdots x_n / x_i \in \mathbb{R}^{N_f} \quad ; \quad \sum_{i=1}^{N_C} n_i = n \right\} \quad (4.3.7)$$

La obtención de la transformación lineal  $G$  se puede formular como la solución de un problema de autovectores y autovalores (Ye, 2005). Sean  $S_i$ ,  $S_e$  y  $S_t$  las matrices de covarianzas interclase, entre clases y total respectivamente, definidas a continuación:

$$S_i = \frac{1}{N_C} \sum_{k=1}^{N_C} \sum_{x \in X_i} (x - c_k)(x - c_k)^T \quad (4.3.8)$$

$$S_e = \frac{1}{N_C} \sum_{k=1}^{N_C} n_i (c_k - c)(c_k - c)^T \quad (4.3.9)$$

$$S_t = \frac{1}{n} \sum_{i=1}^n (x_i - c)(x_i - c)^T \quad (4.3.10)$$

siendo  $c$  el centroide del conjunto de datos. Estas matrices dan información de la cohesión del grupo de muestras dentro de una clase ( $S_i$ ), de lo separadas que están las clases ( $S_e$ ) y del grado de dispersión de todas las muestras respecto al centroide de la distribución de datos ( $S_t$ ).

Se puede obtener la matriz  $G$  a partir de los autovectores  $\eta_i$  que satisfacen:

$$S_e \eta_i = \lambda_i S_t \eta_i \implies S_t^{-1} S_e \eta_i = \lambda_i \eta_i \quad (4.3.11)$$

Atendiendo a la definición de  $S_e$ ,  $S_i$  y  $S_t$  se observa que, a partir de la diagonalización de la matriz  $S_t^{-1} S_e$ , se está maximizando la varianza entre las diferentes clases ( $S_e$ ) a la vez que se minimiza la varianza entre los elementos de una clase ( $S_i$ ). Es fácil comprobar que  $S_t = S_i + S_e$ , por tanto cuando  $S_i$  sea mínimo también lo será  $S_t$  (Fukunaga, 1990).

Tras la resolución del problema de diagonalización, se obtienen como máximo  $N_C - 1$  autovectores con autovalor no nulo, esto es debido a que el rango máximo de  $S_e$  puede ser  $N_C - 1$  (Duda et al., 2001). Puesto que la matriz de transformación  $G$  se obtiene a partir de los autovectores no nulos del problema de diagonalización planteado, la dimensionalidad del espacio transformado estará limitada a  $N_C - 1$ .

El análisis discriminante lineal clásico presenta solución (se puede obtener  $G$ ) siempre y cuando  $S_t$  no sea una matriz singular, es decir, exista su inversa. A efectos prácticos esto ocurre en problemas en los que la dimensionalidad del problema es mucho más elevada que el número de muestras de las que se dispone en el conjunto de entrenamiento. En este trabajo se ha utilizado una variante más moderna del algoritmo LDA clásico, conocida en la bibliografía como ULDA (Uncorrelated Linear Discriminant Analysis) (Jin et al., 2001b). Esta variante de LDA se caracteriza porque las características de clasificación en el espacio transformado no están correlacionadas y además, esta variante de LDA está debidamente regularizada (es aplicable en problemas en los que  $S_t$  es singular). Esto produce una mejora del rendimiento respecto el LDA clásico en diferentes problemas de clasificación (Jin et al., 2001a; Ye, 2005), además de mostrarse más robustos frente al ruido.

Clasificar un determinado patrón utilizando LDA consiste en calcular la distancia del patrón al centroide de cada clase en el espacio transformado (mediante la matriz de transformación  $G$ ), y asignarle la clase cuya distancia es mínima. En efecto, un patrón  $x_i$  pertenecerá a la clase  $R$  si se verifica que:

$$\operatorname{argmin} \{ \|G^T(x_i - c_R)\|^2 \} \quad \forall i = 1, \dots, N_C \quad (4.3.12)$$

La clasificación que realiza LDA, en base al criterio mostrado en (4.3.12), es equivalente a la clasificación basada en la máxima verosimilitud (Hastie and Tibshirani, 1996) realizada por un clasificador Bayesiano bajo ciertas condiciones iniciales (clases distribuidas de manera Gaussiana con varianzas idénticas para cada clase).



### Árboles de clasificación y regresión

Los árboles de clasificación y regresión constituyen un método estadístico no paramétrico utilizado tanto para clasificación como para regresión (Breiman et al., 1984). Si la variable dependiente del problema es continua, CART produce un árbol de regresión. Por el contrario, si la variable es categórica, CART producirá un árbol de clasificación. En este trabajo, CART se ha utilizado para producir árboles de decisión con el fin de clasificar patrones. Los árboles de decisión proporcionan conocimiento sobre las interacciones entre las variables del problema y los fenómenos que explican la relación entre dichas variables (Yohannes and Webb, 1999). A continuación se enumerarán las principales características de CART:

- Es independiente de la distribución estadística de las variables independientes y de las dependientes.
- Las variables independientes pueden ser tanto continuas como categóricas.
- El éxito de la clasificación no está especialmente afectado por *outliers*<sup>2</sup>. Los patrones anómalos son aislados en un nodo del árbol. De este modo CART se muestra robusto ante la presencia de datos anómalos.
- Proporciona un modo de descubrir relaciones ocultas entre las variables presentes en el problema de clasificación analizando las divisiones que produce cada nodo.
- Proporciona modelos completamente interpretables, es decir, en problemas en los que no hay teoría al respecto CART se puede utilizar como una herramienta analítica.
- Puede proporcionar árboles de decisión en problemas de clasificación en los que los patrones contengan un elevado número de variables. A partir de estos modelos, se puede extraer conocimiento para elaborar modelos con un número reducido de características (selección de características).
- La principal debilidad de CART es que no está basado en ningún modelo probabilístico. Esto implica que no existe intervalo de confianza en las predicciones realizadas. El experto únicamente se puede basar en el historial de predicciones que ha hecho el árbol en problemas anteriores con características similares.

Para la construcción de un árbol de decisión se necesitan una serie de elementos tales como un conjunto de cuestiones para realizar la división de patrones en cada nodo, un conjunto de reglas que gobiernen dichas cuestiones, reglas para la asignación de clases a cada nodo y un criterio de

---

<sup>2</sup>Datos anómalos presentes en la distribución.

poda del árbol construido. Estos elementos se pueden agrupar en cinco grupos que se enumeran a continuación:

- **Determinar las cuestiones que se deben plantear en los nodos.** Esto significa decidir en base a qué variables hay que realizar las divisiones de los patrones en los nodos. Estas cuestiones serán del tipo  $\rho(\lambda) \leq \rho(\lambda)_{umbral}$ , donde si la respuesta a esa cuestión es afirmativa, el patrón pasará a un nodo de decisión u otro.
- **Un criterio para la obtención de reglas.** Este criterio será una medida de impureza de cada nodo y cuantificará su heterogeneidad. Se define heterogeneidad como la variedad de clases que hay en el subconjunto de datos a dividir. Por ejemplo, en el nodo raíz de cualquier árbol la heterogeneidad es muy elevada, ya que dicho nodo tiene que dividir el conjunto de patrones original con un número elevado de clases.

En efecto, si se supone que en el problema existen  $j$  clases ( $k = 1 \dots j$ ) y que la probabilidad de que un patrón pertenezca a la clase  $k$  condicionada a que esté en el nodo  $t$  es  $p(k|t)$  y, se verifica que  $\sum_{k=1}^j p(k|t) = 1$ . Así pues, se puede definir la impureza  $i(t)$  del nodo  $t$  como:

$$i(t) = \psi(p(1|t), p(2|t), \dots, p(j|t)) \quad (4.3.13)$$

siendo  $\psi$  una función de las probabilidades antes citadas. Existen varias formas de definir la función  $\psi$ , y por consiguiente  $i(t)$ , no obstante en este trabajo se va a emplear la medida de impureza *Gini* (Breiman et al., 1984; Steingberg and Colla, 1997), cuya forma funcional es:

$$i(t) = 1 - \sum_{k=1}^j p^2(k|t) \quad k = 1, \dots, j \quad (4.3.14)$$

La función de impureza presentará un máximo en el nodo  $t$  si todas las clases presentes en dicho nodo tienen la misma probabilidad, es decir  $p(1|t) = p(2|t) = \dots = p(j|t)$ . Por el contrario, dicha función presentará un mínimo si todas las muestras que terminan en dicho nodo tienen la misma clase,  $i(t) = 0$ .

- **Un criterio para evaluar la bondad de la división realizada en cada nodo.** Para cuantificar la bondad de una división realizada en un nodo se evaluará la variación de impureza al realizar la mencionada división. En efecto se puede definir esa variación de impureza,  $\Delta i(d, t)$ , al realizar la división  $d$  en el nodo  $t$ , como

$$\Delta i(d, t) = i(t) - (p_i i(t_i) - p_d i(t_d)), \quad (4.3.15)$$

siendo  $p_i$  y  $p_d$  la proporción de patrones del nodo  $t$  que van al nodo hijo izquierdo y derecho respectivamente,  $i(t_i)$  y  $i(t_d)$  las impurezas de los dos nodos hijos.  $\Delta i(d, t)$  mide la variación de impureza, al realizar una división.

- **Una regla de asignación de clases a cada nodo.** Existen varias reglas para este propósito (Steingberg and Colla, 1997). No obstante, en este trabajo se va a emplear la regla que CART implementa por defecto, conocida en la bibliografía como *The Plurality Rule* (Yohannes and Webb, 1999). Dicha regla asigna a un nodo terminal<sup>3</sup>  $t$  la clase  $k$ , cuya probabilidad  $p(k|t)$  es la más alta. Dicha regla asume que si la mayoría de casos que acaban en un nodo terminal  $t$  pertenecen a la clase  $k$ , entonces dicho nodo es asignado a la clase  $k$ .
- **Un criterio para podar el árbol de decisión.** Durante la construcción de un árbol de decisión, se hace crecer el mismo hasta que se minimiza la impureza de los nodos, lo que puede conducir a árboles que sobreajusten los datos de entrenamiento, consiguiendo así clasificadores con una capacidad de generalización muy baja. Así pues es necesario realizar una poda de las ramas del árbol de decisión para conseguir una solución de compromiso entre la complejidad del árbol y su capacidad de generalización ante patrones no utilizados en el entrenamiento. Para ello, se define una medida conocida en la bibliografía como CC (*“Complexity Cost”*). Esta medida cuantifica el compromiso entre error en la clasificación y la complejidad del árbol, y se define como:

$$CC = \epsilon_c + \beta N_n, \quad (4.3.16)$$

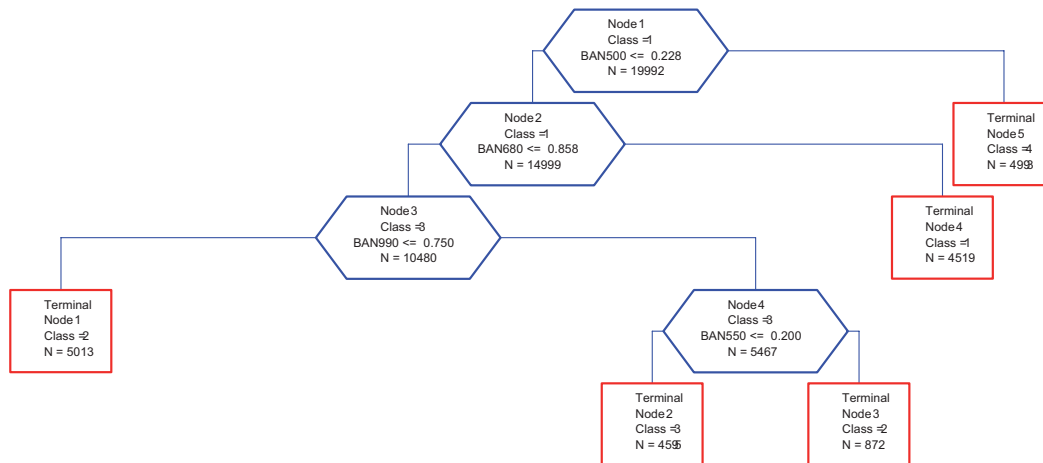
siendo  $\epsilon_c$  el error de la clasificación,  $N_n$  el número de nodos terminales y  $\beta$  es el parámetro de regularización que controlará la penalización aplicada por la adición de cada nodo terminal.

En la figura 4.6 se muestra un ejemplo de un árbol de clasificación obtenido con CART. La clasificación se puede implementar en base a una serie de reglas sencillas. En el ejemplo se muestran las reglas en base a las que se realizan las divisiones en cada nodo. Dependiendo de si una muestra cumple la condición descrita en el nodo o no, el patrón se desplazará hacia un nodo hijo u otro, hasta que llegue a un nodo terminal. En ese momento se le asigna la clase de dicho nodo.

Presentados todos los elementos necesarios para construir un árbol de decisión se puede definir la metodología seguida para construir un árbol de clasificación.

1. Para construir el primer nodo del árbol, CART realizará todas las posibles divisiones de una variable (en el rango de variación de dicha variable). Así, para cada una de las divisiones

<sup>3</sup>Un nodo terminal es aquél del que no surgen más ramas.



**Figura 4.6:** Ejemplo de árbol de clasificación construido con CART para el cultivar cv. clemenvilla con un número reducido de nodos.

realizadas, se obtendrán dos nodos hijos para cada posible división. Los patrones que satisfagan la pregunta avanzarán al nodo hijo de la izquierda, en caso contrario se desplazarán al nodo hijo de la derecha.

2. CART evalúa todas las divisiones realizadas en el paso anterior utilizando el criterio de la ecuación 4.3.15 y, seleccionará como mejor división  $d_{opt}$  aquella que presente una mayor variación de impureza  $\Delta i(d, t = 1)$ .
3. Se repiten los pasos 1 y 2 para cada una de las variables. Finalmente CART seleccionará la variable y su correspondiente umbral para realizar la división que maximiza la variación de impureza.
4. CART asignará al nodo analizado la clase que minimiza el error en la clasificación. Se repiten los pasos 1, 2, 3 y 4, en un proceso recursivo para cada uno de los nodos (no terminales) generados. El árbol crecerá hasta que cada muestra concluya su camino en un nodo terminal.
5. Finalmente, se realizará la poda del árbol generado, ya que sobrecrecido no tendrá capacidad de generalización ante nuevos casos. Para realizar la poda se empleará el parámetro  $CC$  definido en la ecuación (4.3.16), donde se seleccionará el árbol que minimice la función de coste  $CC$ , es decir el que minimice el error en la clasificación con el menor número de nodos terminales (Breiman et al., 1984).

### 4.3.6. Clasificación de la fruta

Construidos los clasificadores basados en LDA y CART utilizando las bandas proporcionadas por los algoritmos de selección, se segmentará el conjunto de imágenes hiperespectrales y posteriormente se clasificarán con el fin de determinar qué frutos están dañados y cuáles no.

Los estándares de calidad de los cítricos, generalmente están limitados, entre otras cosas, por el tamaño del mayor defecto que presente el cítrico. Cada una de las categorías está limitada por unos tamaños máximos de defecto, dentro de la misma. Esto ocurre para la mayor parte de defectos de los cítricos, no así para las podredumbres ya que este tipo de defectos evoluciona con el tiempo y aumenta su tamaño. En las líneas de inspección de los almacenes citrícolas, si un fruto es sospechoso de presentar un daño por podredumbre es eliminado de la línea. Así pues, un sistema automático debería descartar un fruto que presentará un número reducido de píxeles clasificados como podridos.

No obstante, el proceso de segmentación de una imagen clasificando cada uno de sus píxeles no es un proceso totalmente exacto. Factores como el ruido introducido por el sistema de adquisición o los errores que se producen en la clasificación de los píxeles pueden producir errores en la toma de decisión sobre la calidad de un fruto. Con el fin de detectar qué frutos son adecuados para su posterior comercialización se ha desarrollado un algoritmo de clasificación de fruta en el que se ha considerado que los píxeles clasificados como PP y PE pertenecen a una misma clase (a nivel de clasificación de fruta) denominada “Piel con Defecto Podrido” (PDP). Por el contrario, las clases PS y P pertenecen a la misma clase, a efectos de clasificación de fruta, denominada “Piel Sana o Pedúnculo” (PSP). El algoritmo desarrollado minimiza el efecto del ruido utilizando un filtro de mediana (con una ventana de vecindad de  $5 \times 5$ ) en la imagen segmentada. El criterio que se empleará para decidir si una fruta está podrida o no es evaluar el número de píxeles pertenecientes a la clase PDP. Si este número supera el 5% del total de píxeles de la superficie del cítrico, la mandarina será clasificada como una mandarina podrida, en cualquier otro caso la fruta es considerada como sana. El valor del 5% se ha elegido de manera empírica por no haber ningún estándar a la hora de determinar si el fruto está dañado o no. Como se observará en la siguiente sección, este criterio es robusto ante la variación de tamaño del defecto y consistente.

## 4.4. Resultados

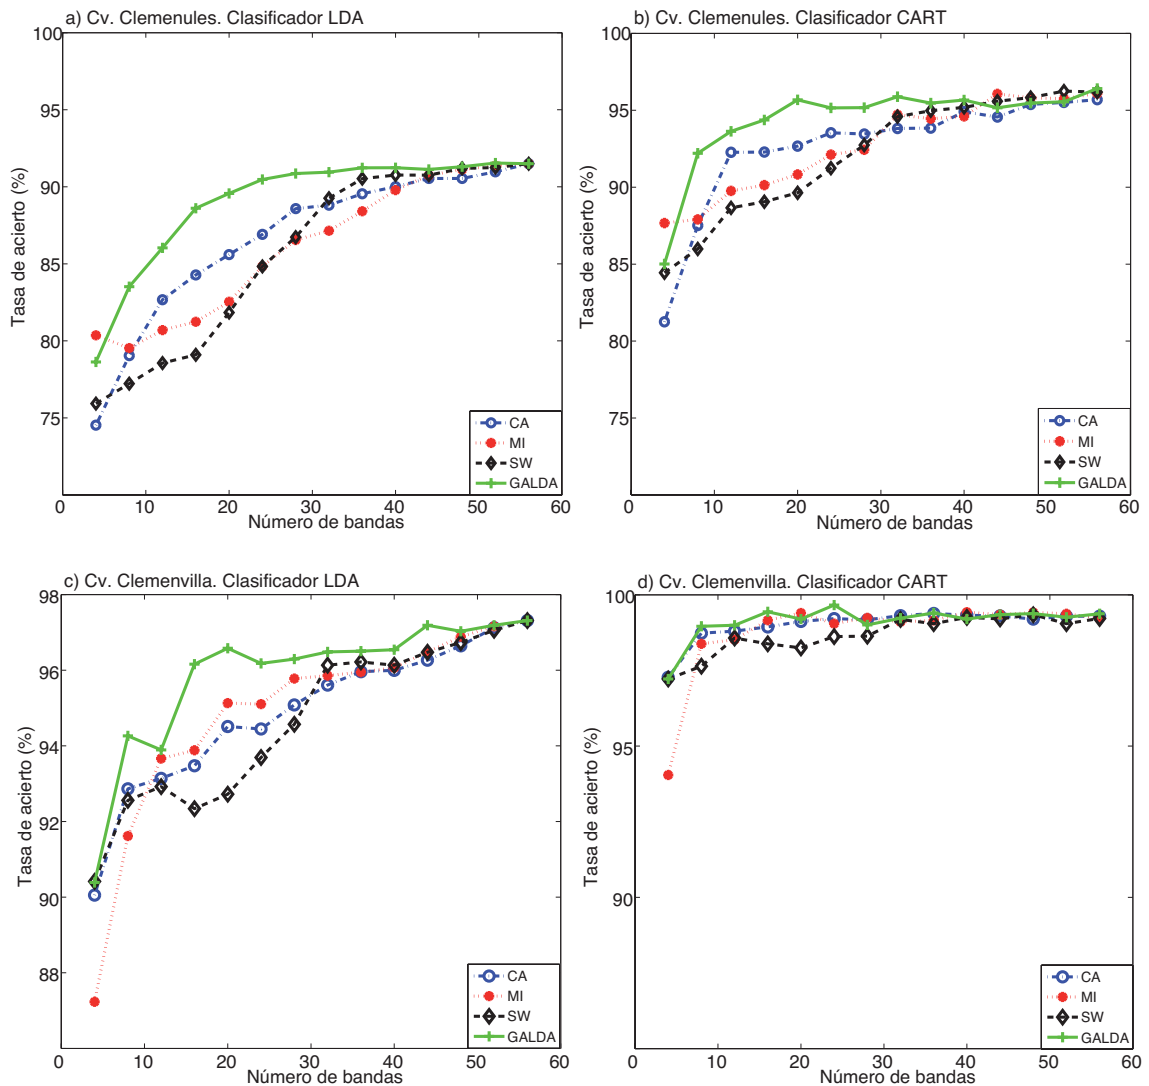
### Selección de las bandas más relevantes

En la parte superior de la figura 4.7 se observa la evolución de la tasa de acierto promedio con LDA y CART al variar el número de bandas proporcionadas por los cuatro métodos de selección

para las mandarinas cv. clemenules. En concreto, en la figura 4.7a), se observan los resultados obtenidos utilizando el clasificador LDA y en la figura 4.7 b) los proporcionados por CART. En ambos casos se observa que GALDA es el método de selección de características que obtiene un éxito mayor en la clasificación de píxeles. Otro de los resultados que se observa es que cuando se utiliza LDA como clasificador, el éxito promedio máximo que se obtiene es de aproximadamente el 92% utilizando las 57 bandas del conjunto de datos, mientras que en el caso de CART dicha tasa de éxito asciende hasta el 95% utilizando 20 bandas. En el caso particular de la clasificación con CART, utilizando las 20 bandas proporcionadas por GALDA, la adición de más bandas al modelo de clasificación no incrementa apenas la tasa de acierto del mismo. En concreto, utilizando las 57 bandas y CART se obtiene una tasa de acierto del 96%. Por este motivo se ha decidido utilizar las 20 bandas proporcionadas por GALDA con el fin de comparar el rendimiento de los clasificadores empleados con el conjunto de validación.

En la parte izquierda de la tabla 4.1 se observa el conjunto de bandas seleccionadas utilizando los cuatro métodos de selección de características para el cultivar cv. clemenules. Se observa que la selección proporcionada por GALDA presenta una diferencia notable con respecto a los otros conjuntos de bandas. Esta selección aporta un subconjunto de bandas (950 nm, 960 nm, 980 nm y 1010 nm) de la parte alta del espectro de trabajo, que no proporciona ninguno de los otros métodos de selección. Este hecho coincide con que GALDA es el método de selección que mejores resultados proporciona en la clasificación de píxeles y hace pensar que en esa zona del espectro puede ocurrir algún fenómeno físico de interés para el problema de la clasificación de podredumbres, como se discutirá en el siguiente capítulo. Por lo demás, los conjuntos de bandas que se obtienen son muy similares para los cuatro métodos de selección con la peculiaridad común de que las 20 bandas seleccionadas están distribuidas a lo largo de prácticamente todo el rango espectral de trabajo, no produciéndose aglomeraciones de bandas en ninguna zona concreta del espectro.

En la parte inferior de la figura 4.7 se muestran los resultados de la evolución de la tasa de acierto promedio con el número de bandas empleadas en la clasificación, en la fruta cv. clemenvilla, para los cuatro métodos de selección y los dos clasificadores empleados. En concreto, en la figura 4.7c) se observan los resultados obtenidos utilizando el clasificador LDA y en la figura 4.7d) utilizando CART. En ambos casos se ve cómo en el caso de las frutas cv. clemenules GALDA es el método de selección de características que obtiene un éxito mayor en la clasificación de píxeles. No obstante, para este cultivar las diferencias en la tasa de acierto promedio entre GALDA y los otros métodos de selección no son tan elevadas como en el caso de la fruta cv. clemenules. Para este cultivar se ha observado que, cuando se utiliza LDA como clasificador, el éxito promedio máximo que se obtiene es de aproximadamente el 97% utilizando las 57 bandas del conjunto de datos, mientras que en el caso de CART la tasa de éxito asciende hasta prácticamente el 99% utilizando



**Figura 4.7:** Evolución en la tasa de acierto promedio con el número de bandas para los cuatro métodos de selección empleados en a) cv. clemenules y LDA b) cv. clemenules y CART, c) cv. clemenvilla y LDA y d) cv. clemenvilla y CART.

únicamente 20 bandas. En el caso particular de la clasificación con CART, utilizando las 20 bandas proporcionadas por GALDA, los resultados en la clasificación son ligeramente superiores que si se utilizan todas las bandas del conjunto con LDA. Por este motivo se ha decidido utilizar las 20 bandas proporcionadas por GALDA con el fin de comparar el rendimiento de los clasificadores para el cultivar cv. clemenvilla.

En la parte derecha de la tabla 4.1 se observa el conjunto de bandas seleccionadas utilizando los 4 métodos de selección de características para las frutas cv. clemenvilla. En este cultivar se observa que los algoritmos CA, MI y GALDA proporcionan conjuntos de bandas similares en

Método de selección	Cv. Clemenules (nm)				Cv. Clemenvilla (nm)			
<b>CA</b>	510	650	740	880	480	600	820	950
	520	660	750	890	490	680	840	960
	530	670	760	900	500	690	850	970
	580	680	770	910	510	700	860	980
	590	690	780	920	520	710	870	990
<b>MI</b>	480	650	740	880	490	600	800	930
	490	660	750	890	500	610	820	970
	500	670	760	900	510	620	830	980
	510	680	770	910	520	630	840	990
	520	690	780	920	530	700	860	1000
<b>SW</b>	480	600	740	880	460	600	740	880
	490	610	750	890	470	610	750	890
	500	620	760	900	480	630	760	900
	520	630	770	910	490	640	770	910
	530	640	780	920	500	650	780	920
<b>GALDA</b>	460	600	740	880	490	600	740	880
	480	620	760	950	540	680	750	910
	520	630	800	960	550	690	770	930
	560	680	820	980	570	700	850	950
	590	730	870	1010	590	730	870	1010

**Tabla 4.1:** Resultado de la selección de bandas en los cultivares cv. clemenules y cv. clemenvilla.

cuanto a que las bandas están distribuidas en toda la zona de trabajo del espectro y, lo más importante, que los tres métodos aportan bandas de la zona alta del espectro (como en el caso de GALDA en el cultivar clemenules). Los conjuntos de bandas proporcionados por los tres métodos de selección antes citados proporcionan resultados en la clasificación significativamente mejores que los que proporciona SW. Este resultado pone de manifiesto, tanto para LDA como para CART, que las bandas situadas en la parte alta del espectro de trabajo proporcionan información útil para la clasificación de podredumbres. En ambos cultivares el algoritmo genético es el que obtiene los mejores resultados en la clasificación de píxeles. Asimismo los conjuntos de bandas proporcionados por GALDA están distribuidos uniformemente en todo el espectro de trabajo e incluyen bandas de la zona alta del espectro. Finalmente son las 20 bandas seleccionadas por GALDA las que se han utilizado para evaluar el rendimiento de los métodos de segmentación empleados en este trabajo.



### Segmentación de las imágenes hiperespectrales

El proceso de segmentación de las imágenes hiperespectrales ha consistido en clasificar cada uno de los píxeles de cada imagen utilizando los modelos de clasificación propuestos, empleando las bandas seleccionadas en la sección anterior con el método GALDA. Para la construcción de modelos se ha utilizado el conjunto de entrenamiento de datos etiquetados descrito en la sección de materiales y métodos de este capítulo.

<b>Matriz de confusión de validación, LDA y cv. clemenules</b>				
	<b>PS (%)</b>	<b>PP (%)</b>	<b>PE (%)</b>	<b>P (%)</b>
<b>PS</b>	87.53	10.52	0.69	11.45
<b>PP</b>	12.13	89.45	5.49	0.42
<b>PE</b>	0.03	0.02	93.80	0.24
<b>P</b>	0.31	0.01	0.02	87.89
$\kappa=0.862$		Acierto Promedio=89.60 %		
<b>Matriz de confusión de validación, CART y cv. clemenules</b>				
	<b>PS (%)</b>	<b>PP (%)</b>	<b>PE (%)</b>	<b>P (%)</b>
<b>PS</b>	86.51	9.74	1.05	3.14
<b>PP</b>	11.55	88.91	0.64	1.35
<b>PE</b>	0.49	0.76	97.65	0.94
<b>P</b>	1.45	0.59	0.66	94.57
$\kappa=0.892$		Acierto Promedio=91.80 %		

**Tabla 4.2:** Matriz de confusión de los clasificadores LDA y CART sobre el conjunto de validación del cultivar clemenules.

Se han construido cuatro clasificadores utilizando el conjunto de entrenamiento, dos para cada cultivar, utilizando modelos LDA y CART. A continuación, se ha evaluado el rendimiento de los mismos utilizando el conjunto de validación etiquetado. En la tabla 4.2 se muestran los resultados de clasificación a través de la matriz de confusión correspondiente al conjunto de validación del cultivar cv. clemenules utilizando las 20 mejores bandas proporcionadas por GALDA. En la parte superior de esa tabla se muestran los resultados correspondientes al clasificador LDA, con el que se ha obtenido un acierto promedio del 89,6 %, y un valor del parámetro  $\kappa = 0,862$ . Este valor indica que el clasificador no produce sesgo en la clasificación. En la parte inferior de la misma tabla se observan los resultados obtenidos para el mismo conjunto de datos utilizando el mismo conjunto de bandas y un modelo de clasificación no lineal (CART). En este caso el índice de acierto promedio en la clasificación es de 91,8 % y un valor del parámetro  $\kappa = 0,892$ . Como se

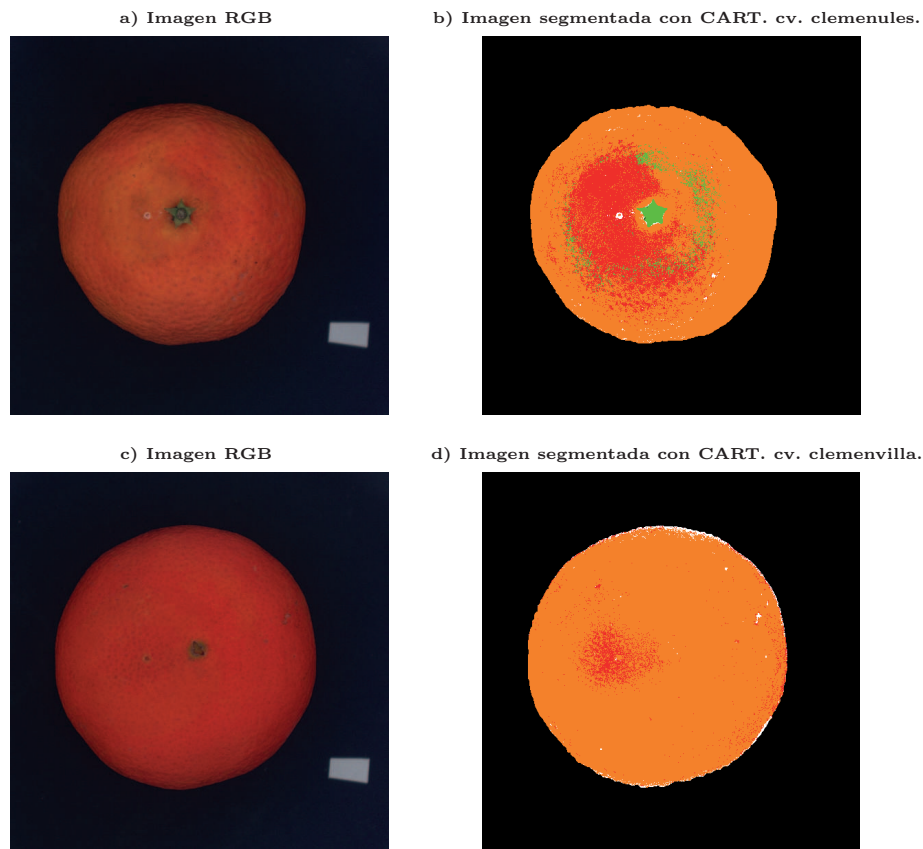
deduce del análisis de las matrices de confusión para el cultivar clemenules, el clasificador basado en CART proporciona mejores resultados que el clasificador basado en LDA en líneas generales.

Las clases que mejores índices de acierto proporcionan son las clases PE (93,8%) y P (87,89%). Estos resultados son coherentes con los gráficos mostrados en la figura 4.4, en la que se mostraban los espectros promedios de cada clase, y se observa que los espectros asociados a las clases PE y P se diferencian claramente entre sí y del resto de clases. Por el contrario, los resultados en la clasificación de píxeles de las clases PS (87,53%) y PP (89,45%) son más discretos, no tanto en índice de acierto como en el porcentaje de falsos positivos que se producen en cada clase con respecto a la otra. Estos resultados se repiten en las dos familias de clasificadores, poniendo de manifiesto que el principal problema en la segmentación de imagen consiste en distinguir los píxeles de piel sana de los que pertenecen a piel podrida en los estados iniciales de la infección.

<b>Matriz de confusión de test, LDA y cv. clemenvilla</b>			
	<b>PS (%)</b>	<b>PP (%)</b>	<b>PE (%)</b>
<b>PS</b>	97.86	6.05	0.40
<b>PP</b>	2.14	93.95	1.89
<b>PE</b>	0	0	97.71
$\kappa=0.947$		Acierto Promedio=96.49%	
<b>Matriz de confusión de test, CART y cv. clemenvilla</b>			
	<b>PS (%)</b>	<b>PP (%)</b>	<b>PE (%)</b>
<b>PS</b>	97.65	2.60	0
<b>PP</b>	2.26	97.34	0.17
<b>PE</b>	0.09	0.06	99.83
$\kappa=0.970$		Acierto Promedio=98.29%	

**Tabla 4.3:** Matriz de confusión de los clasificadores LDA y CART sobre el conjunto de validación del cultivar clemenvilla.

La tabla 4.3 muestra los resultados de clasificación obtenidos para el conjunto de validación de las mandarinas cv. clemenvilla utilizando las bandas seleccionadas. En la parte superior de dicha tabla se muestran los resultados correspondientes al clasificador LDA, con el que se ha obtenido un acierto promedio del 96,4% y un valor del parámetro  $\kappa = 0,947$ . Estos resultados indican que en las mandarinas cv. clemenvilla es más sencillo detectar la podredumbre. En la parte inferior de la tabla se observan los resultados obtenidos en el mismo conjunto de datos utilizando CART. En este caso, el índice de acierto promedio en la clasificación es de 98.29% y un valor del parámetro  $\kappa = 0,970$ .



**Figura 4.8:** a) Imagen RGB de una mandarina cv. clemenules dañada por el hongo *Penicillium digitatum*. b) Segmentación realizada utilizando el mejor modelo basado en CART. c) Imagen RGB de una mandarina cv. clemenvilla dañada por el hongo *Penicillium digitatum*. d) Segmentación realizada utilizando el mejor modelo basado en CART. El color naranja se corresponde con la clase PS, el verde con la clase P, el rojo con la clase PP y el blanco con la clase PE.

Al igual que ocurre en las mandarinas cv. clemenules, el clasificador basado en CART proporciona mejores resultados que el clasificador lineal. En las mandarinas del cultivar clemenvilla, en contraste con lo que ocurre en el otro cultivar estudiado, la tasa de acierto de cada una de las clases es muy similar. Estos mejores resultados obtenidos en las mandarinas de cv. clemenvilla pueden deberse a varias razones, como por ejemplo el menor número de clases presentes en el conjunto etiquetado, la mayor uniformidad en la forma de estos cítricos o una menor variabilidad en el tono de piel de los frutos del cultivar cv. clemenvilla. La parte superior de la figura 4.8 muestra un ejemplo de segmentación de una imagen hiperespectral de un fruto del cultivar clemenules con el método propuesto. Del mismo modo, la parte inferior de la figura 4.8 muestra un ejemplo análogo para un fruto del cultivar clemenvilla. En ambas imágenes se observa cómo los métodos de segmentación propuestos son capaces de detectar la presencia del podrido en ambas frutas.

### Clasificación de la fruta

La tabla 4.4 muestra los resultados de la clasificación de mandarinas cv. clemenules utilizando como segmentador CART. La matriz de confusión muestra que las mandarinas sanas se detectan correctamente (91,3%). La detección de fruta podrida está balanceada con respecto a la clase sano (91,1%). Estos resultados mejoran los obtenidos en (Blasco et al., 2007a) cuya tasa de detección utilizando luz visible y un sistema RGB fue del 65,5%. Los resultados obtenidos para las mandarinas cv. clemenvilla son muy similares, obteniéndose una tasa de acierto ligeramente superior (93,6% para las mandarinas sanas y 92,1% para las podridas). Los ensayos realizados en este capítulo constituyen una aproximación seria y razonable al problema de la detección de este tipo de daños utilizando sólo luz visible e infrarroja.

<b>Matriz de confusión Frutas cv. clemenules. Clasificación de fruta</b>		
	<b>Mandarinas sanas (%)</b>	<b>Mandarinas podridas (%)</b>
<b>Mandarinas sanas</b>	91.3	8.9
<b>Mandarinas podridas</b>	8.7	91.1
	$\kappa=0.824$	Acierto Promedio=91.2%

<b>Matriz de confusión Frutas cv. clemenvilla. Clasificación de fruta</b>		
	<b>Mandarinas sanas (%)</b>	<b>Mandarinas podridas (%)</b>
<b>Mandarinas sanas</b>	93.6	7.9
<b>Mandarinas podridas (%)</b>	6.4	92.1
	$\kappa=0.857$	Acierto Promedio=92.85%

**Tabla 4.4:** Matrices de confusión en clasificación de fruta con umbral de 5%.

Un factor que no ha sido tenido en cuenta en los ensayos propuestos en este capítulo es la presencia de otros tipos de hongos y defectos en las líneas de inspección de la industria citrícola. La presencia de otro tipo de defectos o fruta en diferentes estados de maduración puede afectar negativamente al rendimiento de la metodología propuesta. Con todo lo expuesto, se hace necesario desarrollar una metodología más robusta para mejorar la calidad de los resultados obtenidos. Las mejoras deben ir encaminadas a mejorar el sistema de adquisición de imagen (por ejemplo variar la geometría del sistema de iluminación), aumentar la casuística de la base de datos (otros tipos hongos, otros defectos superficiales o diferentes estados de maduración de la fruta) o emplear otro tipo de técnicas de aprendizaje máquina. En esta línea irán encaminados los experimentos realizados en el capítulo 5 de esta Tesis Doctoral.

## 4.5. Conclusiones

Se han evaluado cuatro métodos de selección de características con el fin de seleccionar las bandas más discriminantes en la clasificación de podredumbres producidas por *Penicillium digitatum*. Asimismo, se han evaluado dos métodos de clasificación para clasificar los píxeles de las imágenes hiperespectrales en cuatro (cv. clemenules) y 3 clases (cv. clemenvilla). Con el sistema hiperespectral empleado y la metodología propuesta, el mínimo número de bandas requeridas para optimizar la clasificación de píxeles ha sido 20, proporcionadas por el método de selección GALDA utilizando como clasificador CART. Utilizando las imágenes segmentadas con CART y un criterio de decisión de fruta podrida/sana en base a un umbral se ha implementado un método para distinguir fruta podrida de fruta sana. Los resultados mostrados en este capítulo muestran que es posible detectar fruta podrida por el hongo *Penicillium digitatum* utilizando un sistema de visión por computador hiperespectral sin utilizar luz ultravioleta. La tasa de acierto alcanzada en la clasificación de fruta en ambos cultivares está en torno al 90 %. El trabajo presentado en este capítulo de la Tesis Doctoral sienta las bases para detectar de manera automática podredumbres en cítricos, mejorando significativamente los resultados obtenidos en trabajos previos.



## Capítulo 5

# Clasificación hiperespectral de podredumbres producidas por *Penicillium digitatum* y *Penicillium italicum*

### 5.1. Introducción

En capítulos anteriores ya se ha discutido la importancia de la detección temprana de podredumbres producidas por *Penicillium digitatum* en cítricos en la industria cítrica (capítulo 4). No obstante, éste no es el único hongo que produce daños que evolucionan con el tiempo en los cítricos, existe una gran variedad de hongos que producen graves pérdidas en la industria cítrica, entre ellos el más importante es el *Penicillium italicum* (Eckert and Eaks, 1989). Diferenciar la presencia de una u otra infección fúngica en un cargamento de fruta es importante para utilizar tratamientos específicos para cada hongo ya que, a pesar de que existen fungicidas de amplio espectro, éstos empiezan a mostrarse ineficaces debido a resistencias creadas por su uso abusivo e indiscriminado (Eckert et al., 1986). En la mayoría de almacenes cítricos la detección de podredumbres se realiza de manera manual y el proceso no permite diferenciar dos hongos distintos. Además no existen sistemas automáticos capaces de detectar y diferenciar entre los daños producidos por los hongos *Penicillium digitatum* y *pencillium italicum*.

Actualmente los sistemas de visión por computador convencionales RGB se emplean en la industria cítrica para automatizar procesos de clasificación por color, forma o detectar algunos defectos visibles a simple vista (Blasco et al., 2007c, 2003; Leemans et al., 2002; Blasco et al.,

2007b). No obstante, estos sistemas no son capaces de clasificar defectos que no son apreciables a simple vista como las podredumbres. Una alternativa para diferenciar los daños producidos por este tipo de defectos puede venir del empleo de sistemas de visión por computador multispectrales avanzados (Aleixos et al., 2002; Kleynen et al., 2005). Existen trabajos previos que utilizan información multispectral para detectar podredumbres en cítricos, no obstante en algunos de ellos el índice de acierto en la detección de podredumbre es bajo (65,5 %) (Blasco et al., 2007a) o se limitan a la detección de podredumbres sin diferenciar el hongo que la produce (Blanc et al., 2007; Gómez-Sanchis et al., 2008b,a), sin emplear ningún tipo de información espacial de la escena. De este modo, si al empleo de información espectral de la escena se añade el uso de información sobre la distribución espacial del defecto, la labor de caracterización y detección del defecto puede ser más sencilla.

El empleo de información espectral y espacial para detectar este tipo de defectos es importante. No obstante, el número de bandas a emplear debe ser reducido ya que un número elevado de bandas produciría una reducción del rendimiento del sistema debido al elevado tiempo de adquisición de cada banda imposibilitando su trabajo en tiempo real. Otro problema añadido al empleo de un número elevado de bandas es la reducción del rendimiento de los clasificadores empleados (Friedman, 1994). Así pues, una etapa clave para implementar un sistema multispectral es determinar qué bandas contienen información relevante y que el número de bandas utilizado posibilite el trabajo en tiempo real. Para ello existen métodos de selección de características empleados en el análisis de imágenes hiperespectrales para reducir la dimensionalidad de las mismas (Wallays et al., 2009; Nakariyakula and Casasent, 2009).

Puesto que una imagen hiperespectral contiene información espectral y espacial de la escena, en muchos trabajos de análisis de imagen hiperespectral se han utilizado características espaciales además de las espectrales, sobre todo en el ámbito del sensado remoto (Zhai et al., 2006; Trias-Sanz et al., 2008). En concreto, se emplean con éxito características de este tipo como las funciones de Gabor (Arivazhagan et al., 2006) o características geométricas (Rohrmus, 2005). No obstante, tras realizar una serie de ensayos preliminares en el contexto de esta Tesis Doctoral utilizando las características de textura arriba citadas se llegó a la conclusión de que no aportaban información suficiente para discriminar las regiones podridas del cítrico. Esto se debe a que las texturas de la piel sana del cítrico y la piel dañada por una podredumbre son muy similares. Además, el cálculo de características de textura suele incorporar complejidad en los sistemas de clasificación desde el punto de vista del rendimiento en el tiempo de ejecución de los algoritmos que las incluyen (Mäenpää et al., 2003). Una solución alternativa y sencilla para incluir información espacial del contexto del píxel a clasificar es calcular la media y la desviación típica de una vecindad del píxel a clasificar. Estas características son muy eficientes desde el punto de vista del tiempo de cálculo y aportan información de primer y segundo orden de la vecindad del píxel a



clasificar.

Una etapa básica en la detección de defectos mediante un sistema de visión multispectral es la de segmentación. Para esta labor se emplean clasificadores tanto de tipo lineal como no lineal, aunque en general los clasificadores no lineales proporcionan mejores resultados como se vió en el capítulo 4. Puesto que este tipo de clasificadores ofrece mejores resultados en la detección de podredumbres, en este capítulo nos centraremos en el uso de los mismos. Algunas de las técnicas de clasificación no lineales más empleadas en problemas agrícolas son las redes neuronales artificiales (ANN) (Kondo et al., 2000), CART (Waheeda et al., 2006) o las máquinas de vectores soporte (SVM) (Gómez-Sanchis et al., 2007). La idoneidad del uso de CART se puso de manifiesto en el capítulo anterior y ANN es uno de los clasificadores no lineales más utilizado en todo tipo de aplicaciones de clasificación. SVM se ha mostrado eficaz en algunos ensayos preliminares de detección de podredumbres realizados en el ámbito de esta Tesis Doctoral (Gómez-Sanchis et al., 2007). A pesar de ello, se ha descartado su uso ya que el entrenamiento de las mismas produce un elevado coste computacional en problemas supervisados con muchas muestras.

En este capítulo de la Tesis Doctoral se va a analizar la capacidad de detectar y clasificar frutos con defectos comunes y dos tipos de podredumbres producidas por *Penicillium digitatum* y *Penicillium italicum* en mandarinas del cultivar clemenules utilizando iluminación halógena, un número reducido de bandas e información espacial de la escena. Para ello se emplearán métodos de selección de características *filter* y clasificadores no lineales como CART y ANN para segmentar las imágenes hiperespectrales. A partir de la segmentación obtenida se propondrá un clasificador basado en árboles de decisión para clasificar fruta con defectos producidos por trips, rameados, *Penicillium digitatum* y *Penicillium italicum*.

## 5.2. Objetivos

Este capítulo de la Tesis Doctoral amplía el estudio realizado en el pasado capítulo con el fin de detectar daños comunes en cítricos y distinguir entre podredumbres producidas por dos tipos de hongos: *Penicillium digitatum* y *Penicillium italicum* en estados tempranos de infección de las mandarinas. La premisa de partida será realizar una serie de mejoras encaminadas a:

1. Mejorar la metodología presentada en el capítulo anterior a nivel de sistema de adquisición. Después de evaluar en los capítulos 3 y 4 el sistema de iluminación con campana cilíndrica se observó que, el grado de uniformidad proporcionado por dicho sistema de iluminación podría ser mejorado variando la geometría del mismo. En los ensayos de este capítulo se empleará el sistema de iluminación semiesférico.
2. Emplear únicamente técnicas de selección de características de tipo *filter*. El propósito de

emplear este tipo de técnicas es obtener resultados independientes del tipo clasificador empleado *a posteriori*. Además se obtendrá una selección de características a partir de la combinación de los resultados obtenidos por cada uno de los métodos individuales a modo de comité de expertos.

3. Detectar y distinguir daños producidos por los hongos *Penicillium digitatum* y *Penicillium italicum* en mandarinas con diferentes estados de maduración. Para ello se emplearán técnicas de clasificación no lineal ya que en el capítulo anterior se puso de manifiesto que las técnicas no lineales de clasificación proporcionaban mejores resultados que las lineales en el problema propuesto. Así pues, en este capítulo se emplearán dos técnicas de clasificación no lineales ampliamente utilizadas como son CART y ANN.
4. Introducir el uso de información espacial (media y desviación típica) de una vecindad del píxel a clasificar con el fin de mejorar el rendimiento de la metodología propuesta en el capítulo anterior.
5. Reducir el número de bandas necesarias para segmentar las imágenes hiperespectrales a partir de las mejoras introducidas en la metodología. En el capítulo anterior, con la metodología propuesta, se determinó que con 20 bandas se alcanzaba el máximo acierto en la detección de podredumbres. Uno de los objetivos principales del trabajo presentado en este capítulo de la Tesis Doctoral será reducir el número de bandas a adquirir.
6. Determinar la mejor estrategia de segmentación, entendiendo “estrategia de segmentación” como la combinación técnica de selección y clasificador.
7. Obtener un sistema de clasificación de mandarinas con daños comunes (*trips* y *rameados*) y daños producidos por *Penicillium digitatum* y *Penicillium italicum* a partir de las imágenes segmentadas con la mejor estrategia y un clasificador basado en CART, que permita entender de forma sencilla las reglas subyacentes a la decisión.

## 5.3. Materiales y métodos

### 5.3.1. Sistema hiperespectral de adquisición de imagen

El sistema de visión hiperespectral se ha descrito detalladamente en el capítulo 2. Para adquirir las imágenes de los ensayos planteados en este capítulo el sistema de visión presenta una serie de particularidades en cuanto al sistema de iluminación empleado y a su configuración.

La etapa de adquisición de imagen (cámara y óptica) y de selección en frecuencia del sistema de visión hiperespectral se basa en filtros sintonizables de cristal líquido como el utilizado en el


resto de la Tesis Doctoral y que fue descrito con detalle en el capítulo 2. En los ensayos de este capítulo, a diferencia de los dos capítulos previos, se ha configurado la región de interés del CCD para adquirir una escena de  $651 \times 801$  píxeles. Esta decisión está motivada por la variación de geometría en la bandeja de colocación del fruto que introduce la campana semiesférica respecto a la cilíndrica. Con la nueva configuración la resolución espacial del sistema en los ensayos de este capítulo es de 4.32 píxeles/mm. Las imágenes hiperespectrales han sido transferidas al PC por medio de la tarjeta de adquisición de datos propietaria de la cámara. En los ensayos de este capítulo se empleó un ordenador personal con un procesador Intel Core Duo 1.67 GHz y memoria RAM de 2Gb. El enfoque del sistema de adquisición de imagen se realizó en la banda central del intervalo de adquisición (740 nm).

Cada fruta ha sido iluminada individualmente utilizando un sistema de iluminación indirecta constituido por 12 lámparas halógenas de 20 W (Philips Brilliantline 20 W/12 V) colocadas en un difusor semiesférico de aluminio. Se han empleado dos lámparas más que en el montaje utilizado en los capítulos 3 y 4, con menor potencia, la razón que motivó esta decisión fue distribuir mejor la intensidad lumínica en toda la escena. El sistema de iluminación fue alimentado por una fuente de alimentación 12 V/DC y 350 W. Los tiempos de integración de cada banda han sido calculados siguiendo la metodología expuesta en 2.3.6. Todo el sistema de visión hiperespectral está en el interior de una campana de acero inoxidable para evitar influencias negativas de la luz de la sala de adquisición. La figura 5.1 muestra un diagrama del sistema de visión hiperespectral.

### 5.3.2. Material vegetal

El material vegetal empleado en los ensayos está compuesto por mandarinas del cultivar clemenules (*Citrus clementina Hort. ex Tanaka*) con dos tipos de daños; 1) daños superficiales que no evolucionan con el tiempo producidos por *trips* y daños producidos por el golpeo de la piel del cítrico con las ramas (rameados), 2) daños que evolucionan con el tiempo producidos por los hongos *Penicillium digitatum* (podredumbre verde) y *Penicillium italicum* (podredumbre azul). Los daños producidos por *trips* o rameados son visibles a simple vista. Por el contrario, el aspecto de las podredumbres, en estadios tempranos, es similar al color de la piel sana. La discriminación visual entre los daños causados por cada hongo bajo estudio es prácticamente imposible para un operario. Los frutos afectados por el primer tipo de defectos se han seleccionado aleatoriamente de una línea de confección de una empresa de distribución cítrica. Por el contrario, los daños producidos por podredumbres se han causado en frutos sanos mediante la inoculación de esporas en el fruto.

Se utilizaron 240 frutos con diferentes estados de maduración, de los cuales 60 no presentaban



**Figura 5.1:** Diagrama del sistema de adquisición de imagen con campana semiesférica.


ningún tipo de defecto, 60 presentaban defectos por trips o rameados<sup>1</sup>, 60 fueron inoculados con una disolución de esporas de *Penicillium digitatum* y 60 fueron inoculados con una disolución de esporas de *Penicillium italicum*. La inoculación de esporas de los hongos se realizó empleando, en ambas ocasiones, una disolución de esporas en suspensión con una concentración de  $10^6$  esporas/ml. Esta concentración es la que se emplea habitualmente en ensayos para producir podredumbres (Palou et al., 2001). Los frutos se almacenaron durante tres días en atmósfera controlada a 25 °C y una humedad relativa del 99 %. Después de este periodo, todas las mandarinas inoculadas con esporas de ambos hongos presentaban daños por *Penicillium digitatum* y *Penicillium italicum* en etapas tempranas de formación, con un diámetro variable de entre 10 mm y 35 mm.

Se adquirieron imágenes hiperespectrales de toda la fruta (un total de 240 imágenes hiperespectrales), desde 460 nm hasta 1020 nm, con una resolución espectral de 10 nm. La base de datos construida consta de 13680 imágenes monocromáticas de los 240 cítricos con la colección de defectos descrita. El tamaño de los cítricos es variable, presentando diámetros desde 70 mm hasta 100 mm. Al mismo tiempo, las frutas presentan diferentes tipos de coloración, los tonos de piel van desde el verde al naranja, habiendo frutos que presentan las dos coloraciones en el momento

<sup>1</sup>Los daños superficiales producidos por trips o rameados son muy similares y difíciles de distinguir por los expertos. No obstante son defectos superficiales que producen el mismo tipo de depreciación en la fruta.

de la adquisición.

La figura 5.2 muestra imágenes RGB de cuatro frutos, el primero es un fruto sano y los tres restantes son cítricos afectados por *trips*/rameados, *Penicillium digitatum* y *Penicillium italicum* respectivamente. En las columnas contiguas se observan imágenes monocromáticas adquiridas a 530 nm, 640 nm, 740 nm y 910 nm respectivamente. Observando las imágenes RGB de los cuatro frutos se aprecia a simple vista el daño producido por *trips*/rameados comparado con la piel sana. Por el contrario, en los frutos con podredumbres verde y azul es difícil distinguir las zonas sanas de las afectadas por los hongos. Además también se pone de manifiesto la dificultad para distinguir un tipo de hongo del otro. Todas las imágenes adquiridas se han preprocesado siguiendo la metodología de corrección propuesta en (Gómez-Sanchis et al., 2008c) descrita en el capítulo 3 de esta Tesis Doctoral.



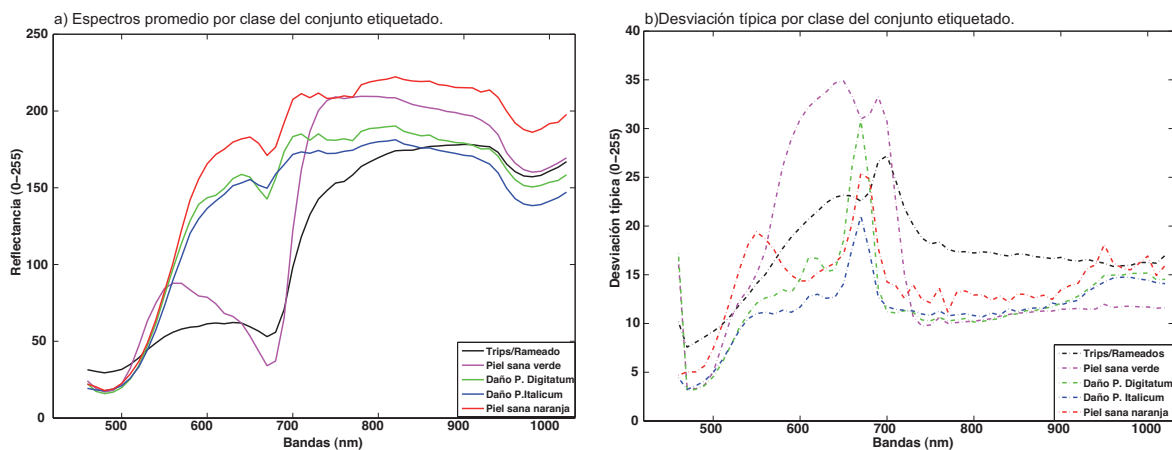
**Figura 5.2:** Imágenes RGB y monocromáticas (530 nm, 640 nm, 740 nm y 910 nm) de una mandarina sana y afectadas por *trips*/rameados, *p. digitatum* y *p. italicum*

### 5.3.3. Conjunto de datos etiquetado

El conjunto de técnicas supervisadas (tanto de selección de características como de segmentación) utilizadas en los ensayos de este capítulo motiva la construcción de un conjunto de datos etiquetado. Se han construido dos conjuntos etiquetados con 172 características asociadas a un

píxel. En concreto, una característica de tipo clase, 57 variables con carácter puramente espectral (nivel de reflectancia del píxel en cada banda adquirida) y 114 características con carácter espacio-espectral (reflectancia promedio y desviación típica de una vecindad del píxel en cada banda adquirida). La diferencia de ambos conjuntos viene impuesta por el tamaño de la vecindad considerada para obtener las características espacio-espectrales. Se han considerado dos tamaños de ventana,  $3 \times 3$  y  $5 \times 5$ , con el fin de evaluar el rendimiento de los modelos desarrollados optimizando el tamaño de la ventana. Cada una de las ventanas proporcionará una resolución espacial distinta, la primera de  $0.69 \times 0.69$  mm y la segunda de  $1.16 \times 1.16$  mm.

Los conjuntos etiquetados se han formado etiquetando manualmente regiones de tamaño variable de las imágenes adquiridas, en 143095 píxeles clasificados en 5 clases distintas. Las clases presentes son “daño por Trips/Rameado” (TR), “piel sana color verde” (PV), “daño por *Penicillium digitatum*” (PD), “daño por *Penicillium italicum*” (PI) y “piel sana color naranja” (PN). Cada patrón contiene 172 valores de reflectancia (del píxel, promedio y desviación típica de la región) y una clase asignada por un experto. No se ha incluido una clase *fondo* ya que los píxeles del fondo de la imagen se han segmentado previamente en la etapa de preprocesado. La figura 5.3 muestra los espectros promedios de cada clase en el conjunto de entrenamiento y la desviación típica.



**Figura 5.3:** a) Espectros promedio y b) Desviación típica por clase en el conjunto de entrenamiento etiquetado.

Las clases TR y PV presentan un pico de absorción en 680 nm, lo cual hace que sus espectros característicos sean claramente diferenciables del resto de clases. Esta diferencia se debe a la baja presencia de carotenoides y a la presencia de clorofila y flavonoides (Cercós et al., 2005) en los píxeles de estas clases. No obstante, en la segunda clase se observa que este pico de absorción es más acentuado, como es de esperar debido a la ausencia de defecto. Otro hecho que se observa es

que existe un pico de absorción de 950 nm a 980 nm, que es más acentuado en los espectros de las clases podrido. En esa región existe un pico de absorción secundario del agua (Matcher et al., 1994; Sims and Gamon, 2003), que denota la presencia de una mayor cantidad de agua. Esto concuerda con el aumento de la cantidad de agua que se produce en la piel de un cítrico dañado por podredumbres en estados incipientes debido a la rotura de la pared celular afectada por el hongo.

Tras el estudio de la figura 5.3b) se observa que la clase PV presenta una elevada variabilidad en las bandas que van del verde al rojo debido a la diferencia de tonos en el color de la piel de los píxeles de esta clase. Además existe un mínimo local coincidiendo con el pico de absorción de la clorofila. Esto puede deberse a que la variabilidad en esta banda se reduce por la predominancia del fenómeno antes mencionado sobre otros mecanismos de absorción. Este hecho contrasta con los máximos locales encontrados en el espectro de variabilidad para las clases PD y PI, debido a la presencia de píxeles de zonas dañadas con pigmentación naranja y verde. La mayoría de fruta de la que se han extraído los píxeles de las clases TR y PV presentaban un pigmentación verde predominante sobre la naranja, en contraste con el color de las frutas de las que se han extraído los píxeles de las clases PD, PI y PN. Este hecho está justificado por la dificultad de producir podredumbre en frutos con un grado de maduración menor, debido a la presencia de flavonoides que impiden su desarrollo (Ortuño et al., 2006).

La principal dificultad en el problema de clasificación propuesto es distinguir entre las clases PD, PI y PN como se puede observar en la figura 5.3a). Contrastando con los espectros mostrados en la figura 4.4a) de la base de datos del capítulo 4, se observa que la clase PN esta más separada de las dos clases podrido. Esto se debe a la mejora que introduce el sistema de iluminación (campana de iluminación esférica) en la adquisición de las imágenes. Concluida la fase de selección de características se realizará una interpretación física de las bandas más relevantes en el problema de clasificación.

El conjunto etiquetado se ha dividido en tres conjuntos: un conjunto de entrenamiento compuesto por el 10% de los píxeles, un conjunto de validación compuesto por otro 10% de los píxeles y un conjunto de test compuesto por el 80% restantes. Los dos primeros subconjuntos se han empleado para seleccionar características y construir los modelos de segmentación. El tercero se ha empleado para evaluar las técnicas propuestas para segmentar las imágenes. La elección de un porcentaje elevado en el número de píxeles que contiene el conjunto de test es comprobar la capacidad de generalización de los modelos.



#### 5.3.4. Selección de características

En el capítulo anterior se discutió la necesidad de emplear técnicas de selección de características en lugar de extracción de características para reducir la dimensionalidad. La filosofía empleada en este capítulo será la misma, esta decisión está motivada con un doble objetivo: 1) optimizar el funcionamiento de los clasificadores empleados reduciendo el número de entradas de los mismos, y 2) extraer conocimiento sobre el número mínimo de bandas, y su significado físico, que ayudan a diferenciar las clases en el problema de clasificación tratado y a evitar la adquisición del resto de bandas por un sistema de visión a medida para la detección de podredumbres. Existe otro tipo de técnicas para reducir la dimensionalidad del problema, la extracción de características. No obstante éstas no cumplen con el segundo objetivo planteado, ya que reducen la dimensionalidad del problema clasificación a costa de trabajar en un espacio transformado con características que se obtienen a partir de todas las bandas adquiridas. Por el contrario, una de las ventajas de la selección de características, es la interpretabilidad de los resultados obtenidos desde el punto de vista físico.

En el capítulo 4 se empleó una serie de métodos de selección de características del tipo *filter* (Blum and Langley, 1998) y *wrapper* (Kohavi and John, 1997). En este capítulo solo se van a emplear métodos *filter* debido a su rápida convergencia y su robustez ante cambios en el método de clasificación empleado, ya que no optimizan el acierto de un clasificador en concreto, como en el caso de los métodos *wrapper*<sup>2</sup>. Los métodos de selección de características empleados en estos experimentos son: T-Test (TT) (Li et al., 2006), divergencia Kullback-Leibler (KLD) (Abe et al., 2000), Análisis de Correlaciones (CA) (Gómez-Chova et al., 2003), Cota de Chernoff (CB) (Theodoridis and Koutroumbas, 1999), Lambda de Wilks (LW) (Ouardighi et al., 2007), Curva ROC (ROC) (Mamitsuka, 2006) y el método de Mínima Redundancia Máxima Relevancia (MRMR) (Ponsa and López, 2007). Otra diferencia sustancial en la estrategia de selección de bandas que se va a emplear en este capítulo es que los métodos de selección empleados no son del tipo multiclase<sup>3</sup>. Estos métodos *a priori* sólo son válidos para problemas de clasificación binarios. El problema de segmentación tratado en este capítulo presenta cinco clases, como se ha discutido en la sección 5.3.3. Para solventar este problema, se va a obtener una selección de características por cada una de las clases empleando el paradigma *one vs. all*<sup>4</sup>, obteniéndose una selección de características para cada clase, que maximiza la separabilidad entre esa clase y el resto. A partir de la selección de cada clase y la medida de relevancia dentro del método, se obtendrá una sola

---

<sup>2</sup>Las técnicas de clasificación empleadas en este capítulo, las redes neuronales, hace que no sea viable utilizar métodos *wrapper* debido al elevado tiempo de entrenamiento requerido en cada iteración del método de selección.

<sup>3</sup>En el capítulo 4 se emplearon métodos de selección que permitían la presencia de dos o más clases estableciendo la salida de los mismos como una variable de regresión.

<sup>4</sup>Este paradigma consiste básicamente en que cuando se está obteniendo la selección de una clase “*a*”, todas los patrones del resto de clases se consideran pertenecientes a una clase “ $\bar{a}$ ”.



selección por método, a partir de combinar los subconjunto de variables seleccionadas para cada clase.

Cada una de las selecciones obtenidas con cada método se utilizará al final como entrada de otro método que denominaremos comité de expertos (CE) y que producirá una selección de características fruto de todas las demás. Finalmente se comparará la selección obtenida con cada uno de los métodos por separado con la obtenida por el comité de expertos.

### Métodos de selección de características

Cada uno de los métodos empleados en este capítulo proporciona una selección de características asociada a cada clase y la relevancia de cada variable. El modo de obtener una sola selección por método se repite para cada uno de los métodos y consiste en sumar los índices de relevancia asociados a la selección de cada banda para, a continuación, ordenar los índices de relevancia asociados a cada variable obteniéndose un ranking y la relevancia global de la misma. La selección obtenida es la que optimiza la separabilidad global de todas las clases. A continuación revisamos los métodos de selección usados.

- **TT.** Este método evalúa si dos clases, en un problema de clasificación binario, son estadísticamente diferentes entre sí. Para ello se evalúa la diferencia cociente entre las medias de las dos clases y las varianzas de las mismas para cada variable (Liu and Motoda, 1998b).
- **CA.** Este método se ha usado en dos tareas de la estrategia de selección de características. En primer lugar se va a emplear para eliminar las bandas contiguas correlacionadas linealmente más allá de un umbral, obteniéndose una preselección de características. Además CA se empleará como método de selección de características que participará en CE. Los detalles técnicos de CA se presentaron en la sección 4.3.4.
- **KLD.** Consiste en el cálculo de la entropía relativa entre las distribuciones de dos variables aleatorias. Esta medida permite establecer la información común entre cada variable y la clase (Kullback, 1987).
- **CB.** Método basado en la minimización del error de clasificación basado en la distancia de Bhattacharyya (Guorong et al., 1996).
- **LW.** El estadístico  $\lambda$  de Wilks permite establecer la importancia de una variable en base a la significancia estadística en el proceso de discriminación lineal de dicha variable respecto de la salida (El Ouardighi and Aboutajdine, 2007).
- **ROC.** Basado en el cálculo del área bajo la curva ROC (*Receiver Operating Curve*) y la exclusión/inclusión de variables en el problema de clasificación propuesto (Mamitsuka,

2006).

- **MRMR.** Este método se caracteriza por evaluar qué variable está más correlacionada con la variable clase (*maximal relevance*) y evaluar simultáneamente la información compartida con el resto de variables desde el punto de vista de su información mutua (*minimum redundancy*) (Peng et al., 2005; Ding and Peng, 2005, 2003).
- **CE.** Este método proporciona una selección de características a partir de la selección global proporcionada por cada uno de los métodos anteriores. La idea fundamental de la técnica radica en evaluar qué características son seleccionadas con más frecuencia por cada miembro del comité, ponderando dicha elección por la posición que ocupa la variable en los respectivos rankings. La relevancia de una variable proporcionada por este método se calcula a partir de la suma de las inversas de la posición que ocupa la variable en el ranking establecido por cada método. La razón por la que se ha elegido la inversa de la posición en el ranking de cada método, en lugar de la propia relevancia de cada método, es que los diferentes métodos proporcionan relevancias en diferentes escalas que no pueden ser comparadas. Esta técnica se ha aplicado con éxito en problemas de selección de características aplicados al sentido remoto (Gómez-Chova, 2008).

### Estrategia para obtener el número óptimo de bandas

Uno de los objetivos de este capítulo es obtener un número reducido de bandas que permita obtener buenos resultados en la etapa de segmentación de los defectos. Pero, ¿cuál es el número adecuado de bandas para realizar este cometido? La respuesta a esta pregunta es, en la mayoría de problemas, aquél que mejore el resultado de la clasificación, hasta que se alcanza en mayor o menor medida una saturación en el índice de acierto del clasificador (como se observó en la sección 4.4 del capítulo anterior).

La estrategia empleada consiste en utilizar como variables de entrada a los métodos de selección de características la reflectancia promedio y la desviación típica de una vecindad del píxel tratado en cada banda adquirida. Se ha descartado utilizar la reflectancia del píxel en cada banda con el fin de que los métodos de selección proporcionen información sobre qué bandas son las más relevantes evitando que los *rankings* proporcionen información redundante. Un ejemplo de esta situación sería que un método seleccionará una determinada banda y su promedio en dos posiciones contiguas del ranking.

Posteriormente se realiza una preselección de variables utilizando un análisis de correlaciones, fijando empíricamente una correlación umbral de  $|0,9|$  con el fin de eliminar variables espectralmente contiguas muy correlacionadas. La preselección de las variables obtenidas se emplea como

entrada de los métodos de selección arriba descritos.

A continuación se procede a evaluar el número de variables  $N_{sat}$  que produce la saturación en el acierto de un clasificador utilizando secuencialmente las variables proporcionadas por cada método de selección. Para ello se va a construir un clasificador con la primera variable del ranking y se evalúa su acierto, a continuación se repite el proceso incluyendo la siguiente variable en el ranking. Así sucesivamente hasta emplear las 114 variables introducidas al método de selección.

El clasificador empleado ha sido CART debido a la rapidez de convergencia de este algoritmo y el bajo coste computacional que requiere esta técnica. Este proceso se repetirá para cada método de selección con el fin de evaluar cuál proporciona un mejor rendimiento en la clasificación.

De este experimento se extraerán las longitudes de onda que aportan la información más relevante para la clasificación. El criterio empleado para seleccionar una longitud de onda u otra será el de seleccionar aquellas asociadas a un promedio o desviación típica de las  $N_{sat}$  primeras variables seleccionadas por los métodos vencedores. Por ejemplo, supongamos que el método CE proporciona el mejor acierto con el clasificador empleado, y el acierto promedio del mismo se satura empleando las variables  $\bar{\lambda}_{530}$ ,  $\bar{\lambda}_{560}$ ,  $\bar{\lambda}_{680}$  y  $\sigma_{480}$ . Ante esta situación se deduciría que las longitudes de onda relevantes proporcionadas por CE son 530 nm, 560 nm, 680 nm y 480 nm. La metodología propuesta se repetirá para los dos tamaños de vecindad empleados, obteniéndose a la conclusión de esta etapa las características ( $\lambda, \bar{\lambda}$  y  $\sigma$ ) de las longitudes de onda vencedoras, que se emplearán como entrada de los métodos de segmentación de imagen.

### 5.3.5. Técnicas de segmentación no lineales

Los resultados obtenidos en el capítulo 4 pusieron de manifiesto que las técnicas de clasificación no lineal producían mejores resultados en la detección de podredumbres. Siguiendo estos resultados se van a utilizar únicamente técnicas no lineales para la detección de podredumbres. En concreto se va a emplear CART y ANN. Tanto CART como las ANN se han mostrado eficaces en problemas de clasificación de imágenes hiperespectrales (Ham et al., 2005; Gómez-Chova et al., 2003; Du et al., 2006; Tumbo et al., 2002; Ye et al., 2006).

### Árboles de decisión

En la sección 4.3.5 se presentaron las principales características y razones por las que se ha utilizado esta herramienta para segmentar imágenes hiperespectrales en esta Tesis Doctoral. Asimismo se realizó una breve descripción de la técnica desde un punto de vista formal. Los parámetros elegidos para construir los modelos basados en CART que se han empleado en este capítulo han sido los mismos que se emplearon en los ensayos del capítulo anterior. La principal

diferencia radica en la estrategia de selección de características, la base de datos empleada y las características de entrada del árbol, en concreto características espaciales como la reflectancia promedio y la desviación típica de una vecindad del píxel a analizar.

### Redes neuronales artificiales

No existe una definición general de red neuronal artificial, existiendo diferentes según el texto consultado. No obstante, en casi todas las definiciones aparece el componente de simulación del comportamiento biológico. Lo que sí tienen en común las ANN con el cerebro humano es la distribución de las operaciones a realizar en una serie de elementos básicos que, por analogía con los sistemas biológicos, se conocen como neuronas. Estos elementos están interconectados entre sí mediante una serie de conexiones que, siguiendo con la analogía biológica, se conocen como pesos sinápticos. Estos pesos varían con el tiempo mediante un proceso conocido como aprendizaje. Así pues, podemos definir el aprendizaje de una red como el proceso por el cual modifica las conexiones entre neuronas (los pesos sinápticos) para realizar una tarea determinada. Veremos más adelante los diferentes tipos de aprendizaje que existen. La potencia computacional de una red neuronal deriva, principalmente, de su estructura de cálculo distribuido.

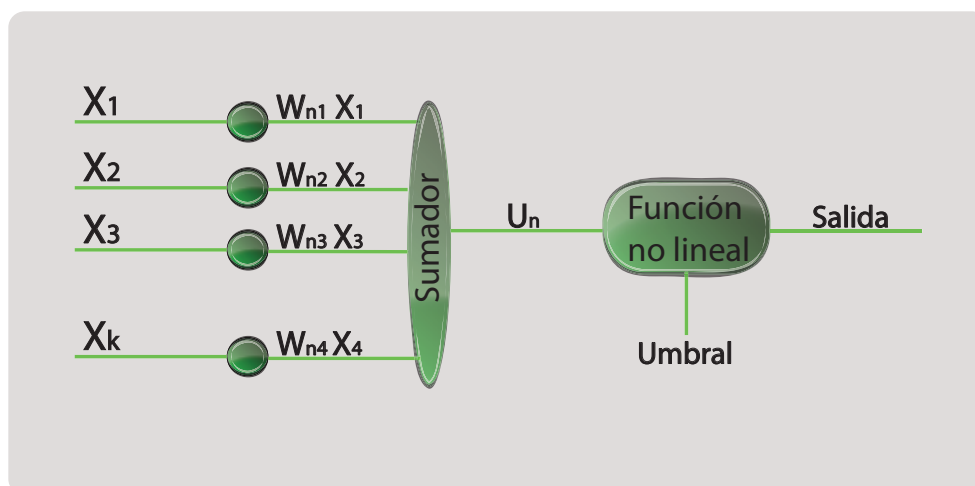
Las principales ventajas que presentan las redes neuronales son (Haykin, 1999):

- **Son sistemas distribuidos no lineales:** Una neurona es, en su definición más general, un elemento no lineal por lo que una interconexión entre ellas (red neuronal) también será un sistema de procesamiento no lineal. Esta propiedad permitirá la modelización de sistemas no lineales y caóticos, modelización que, con los modelos lineales no se puede realizar con éxito.
- **Son sistemas tolerantes a fallos:** Una red neuronal, al ser un sistema distribuido, permite el fallo de algunos elementos individuales (neuronas) sin alterar significativamente la respuesta total del sistema.
- **Son sistemas adaptables:** Una red neuronal tiene la capacidad de modificar los parámetros de los que depende su funcionamiento de acuerdo con los cambios que se produzcan en su entorno de trabajo (cambios en las entradas, presencia de ruido, etc.). Esta capacidad de adaptación no puede ser excesivamente grande ya que se tendría un sistema inestable que respondería a pequeñas perturbaciones. Éste es el problema conocido como el dilema plasticidad-estabilidad.
- **Establecen relaciones no lineales entre variables dependientes e independientes:** Las redes neuronales son capaces de relacionar dos conjuntos de variables. Comparando con los métodos estadísticos clásicos tienen como ventaja que los datos no tienen por qué cumplir las condiciones de linealidad, Gaussianidad y estacionariedad (Proakis, 1997).

El elemento fundamental de cálculo de una red neuronal artificial es la neurona, todo modelo artificial de neurona presenta los siguientes elementos básicos:

1. Un conjunto de conexiones, pesos o sinapsis que determinan el comportamiento de la neurona.
2. Una función de transformación que se encarga de combinar todas las entradas con las respectivas sinapsis.
3. Una función de activación no lineal para limitar la amplitud de la salida de la neurona.
4. Un umbral exterior que determina el valor por encima del cual la neurona se activa.

Esquemáticamente, una neurona artificial quedaría representada por la figura 5.4.



**Figura 5.4:** Esquema de neurona artificial.

siendo  $x$  el vector de entrada,  $w_n$  el vector de pesos sinápticos,  $U_n$  la función de transformación y  $\psi$  la función de activación no lineal (ecuación 5.3.1, 5.3.2).

$$U_n = \sum_{n=1}^k w_{nk} \cdot x_k \quad (5.3.1)$$

$$salida = \psi(U_n) = \psi\left(\sum_{n=1}^k w_{nk} \cdot x_k\right) \quad (5.3.2)$$

En la bibliografía se encuentran un sinnúmero de funciones de transformación  $U_n$  y funciones de activación  $\psi$ . En concreto en este trabajo se ha empleado como función de transformación  $U_n$  el

producto escalar (ecuación 5.3.1). En este trabajo se han empleado dos funciones de activación distinta dependiendo de la posición que ocupa la neurona en la arquitectura del modelo. En particular se han empleado la función sigmoide en las capas ocultas:

$$\psi(U_n) = \frac{1}{(1 + e^{-a \cdot U_n})} \quad (5.3.3)$$

y la función de activación de *Potts* en la capa de salida:

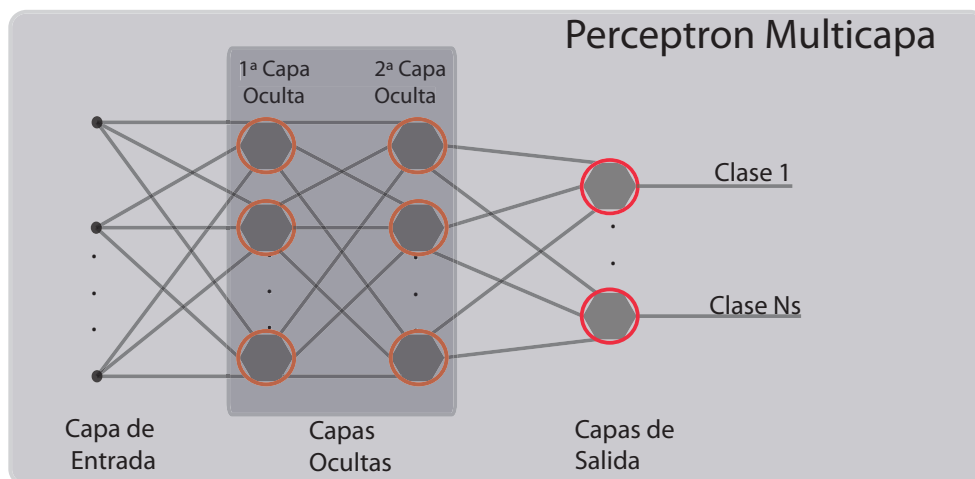
$$\psi(U_n) = \frac{e^{U_n}}{\sum_{i=1}^{N_S} e^{U_i}} \quad (5.3.4)$$

Donde  $N_S$  es el número de neuronas en la capa de salida y  $U_i$  la salida de cada neurona de la última capa oculta. El empleo de de la función de Potts está especialmente indicado en problemas de clasificación con varias neuronas de salida, la peculiaridad que introduce esta función es que tiene en cuenta el valor obtenido por el sumador de cada una de las neuronas de salida sobre una dada.

Las neuronas se pueden conectar entre sí para dar lugar a estructuras neuronales. Estas estructuras constituyen lo que se denomina arquitectura de la red. En este trabajo se han empleado arquitecturas con una y dos capas ocultas. La red neuronal empleada en este trabajo ha sido el perceptrón multicapa (MLP). El perceptrón multicapa es la red neuronal artificial más conocida y con un mayor número de aplicaciones. Su historia comienza en 1958 cuando Rosenblatt publica los primeros trabajos sobre un modelo neuronal y su algoritmo de aprendizaje que llama perceptrón. El perceptrón multicapa es una red formada por una capa de entrada, al menos una capa oculta y una capa de salida. Su estructura se muestra en la figura 5.5. La presencia de capas ocultas es la cualidad que permite al MLP realizar clasificación de problemas no lineales. El número de neuronas que forman las capas de entrada y salida está determinado por el problema. En este trabajo se han empleado  $3 \cdot N_{sat}$  neuronas de entrada y 5 neuronas de salida.

El número de capas ocultas y de neuronas en cada una de ellas no está fijado ni por el problema ni por ninguna regla teórica, por lo que el diseñador es quien decide esta arquitectura en función de la aplicación. Únicamente está demostrado que, dado un conjunto de datos conexo, con una sola capa oculta de neuronas no lineales es posible establecer una relación entre dicho conjunto de datos, aunque no se especifica el número de neuronas necesarias. Si el conjunto no es conexo hacen falta al menos dos capas ocultas (Kolmogorov, 1957), de ahí que se hayan evaluado arquitecturas con una y dos capas ocultas. Intuitivamente, es lógico pensar que, ante estos inconvenientes, la solución idónea es implementar una red con muchas capas ocultas y una gran cantidad de neuronas en cada una de ellas. No obstante esta solución no siempre es adecuada ya que puede disminuir la capacidad de generalización de la red. La solución empleada para determinar el número de

neuronas en las capas ocultas ha sido evaluar arquitecturas con un número variable de neuronas. En concreto, se han realizado pruebas con arquitecturas de 10 a 20 neuronas en cada capa oculta, cuyos valores se han fijado a través de ensayos preliminares.



**Figura 5.5:** Esquema de la arquitectura del MLP.

La última pieza necesaria para elaborar un modelo basado en ANN es el algoritmo de aprendizaje. Existen diferentes algoritmos de aprendizaje que optimizan las conexiones ( $w$ ) entre las neuronas según el error  $e_j$  cometido por cada neurona de salida de la red, entendiendo por error la diferencia que existe entre la salida de la red y la salida deseada. Los más utilizados son los algoritmos por descenso de gradiente (ecuación 5.3.5) que se basan en la minimización, de una determinada función monótona creciente del error cometido. La velocidad de convergencia y la resolución del algoritmo de aprendizaje viene dada por la constante de adaptación  $\alpha$ .

$$w(t+1) = w(t) - \alpha \cdot \nabla J \quad (5.3.5)$$

Siendo  $t$  y  $t+1$  los instantes temporales previo y posterior a la actualización de los pesos  $w$ . La función  $J$  a minimizar, se denomina función de coste. La función de coste que se ha empleado en este trabajo es:

$$J = \frac{1}{2M} \sum_{i=1}^M \sum_{j=1}^{N_s} e_j^2(i) \quad (5.3.6)$$

En esta expresión,  $M$  es el número de muestras utilizadas para entrenar la red. Desde un punto de vista de máxima verosimilitud, esta función de coste asume una distribución de errores de tipo normal (Bishop, 1995). Una vez definida la función de coste a utilizar hay que aplicar un

procedimiento de minimización de dicha función; este proceso recibe el nombre de aprendizaje de la red y existen dos tipos (Haykin, 1999):

- ***On-line***. El aprendizaje se realiza patrón a patrón. Durante todo el entrenamiento se le proporciona a la red cada entrada junto con su salida deseada. Se mide el error y en función de éste se adaptan los pesos sinápticos mediante el algoritmo de aprendizaje escogido.
- ***Batch***. En este tipo, el aprendizaje se realiza época a época ( $t \rightarrow t + 1$ ). En esta aproximación, una época supone el paso de todos los patrones de entrenamiento por la red. En este tipo de aprendizaje, se pasa a la red todos los patrones de entrenamiento, se estima el error total cometido y se adaptan los pesos en función del error promediado cometido.

Para este trabajo se ha empleado un tipo de aprendizaje de tipo *batch*. Esta decisión esta motivada por los resultados de una serie de ensayos preliminares que pusieron de manifiesto que el aprendizaje de tipo *on-line* presentaba un tiempo de convergencia mucho mayor, proporcionando resultados similares al tipo *batch*.

El algoritmo de aprendizaje empleado se denomina *backpropagation* y es un algoritmo de descenso por gradiente que propaga las señales desde la capa de salida hasta la capa de entrada, optimizando los valores de los pesos sinápticos mediante un proceso basado en la minimización de la función de coste. Por ello, puede dividirse el algoritmo en dos fases; 1) Propagación hacia adelante: se propagan las señales desde la capa de entrada hasta la de salida, determinándose la salida de la red y el error cometido al comparar ésta con el valor de la salida deseada que se le facilita a la red durante la etapa de aprendizaje. 2) Propagación hacia atrás: en función de los errores cometidos en la capa de salida, el algoritmo se encarga de optimizar los valores de los pesos sinápticos que determinan las conexiones entre las neuronas mediante la retropropagación del error desde la capa de salida a la de entrada a través de las capas ocultas.

El desarrollo matemático de la regla de actualización de pesos del algoritmo *backpropagation* es largo y complejo y se puede consultar en cualquier libro de redes neuronales citados en esta sección (Bishop, 1995; Haykin, 1999), así pues nos centraremos en los aspectos prácticos de implementación del algoritmo.

1. **Inicialización de los pesos sinápticos.** Es fundamental en el funcionamiento de una red ya que el algoritmo de aprendizaje parte de un punto determinado de la función de error y se mueve por ella hasta llegar al mínimo más cercano. Este mínimo no tiene porqué ser el mínimo global de la función sino que puede tratarse de un mínimo local. Por tanto, es fundamental variar el punto de partida para que en algún momento el mínimo alcanzado sea un mínimo global. Para solventar este problema la estrategia planteada ha sido realizar 50



inicializaciones aleatorias de pesos sinápticos con el fin de explorar aleatoriamente el espacio vectorial donde se define la función de error.

2. **Elección de la constante de adaptación.** Es la responsable de la velocidad de convergencia del algoritmo. Se ha de llegar a un compromiso en la elección de la constante de adaptación, ya que un valor excesivo de ésta puede dar lugar a inestabilidades en la convergencia del algoritmo mientras que un valor demasiado pequeño puede implicar un tiempo de convergencia muy elevado. Existen algoritmos que plantean modificaciones sobre la constante de adaptación durante el proceso de entrenamiento. Estos algoritmos tienen todos ellos en común la siguiente característica: la constante de adaptación es grande lejos del mínimo y pequeña en sus inmediaciones. La diferencia entre ellos es la forma de plantear el crecimiento/decrecimiento de dicha constante (Soria et al., 2006). El algoritmo empleado que ajuste la constante de adaptación es el propuesto por Silva and Almeida (1990).
3. **Criterio de parada del aprendizaje.** Este criterio determina cuándo el algoritmo de aprendizaje considera que ha finalizado su convergencia efectiva. Sobre esta cuestión hay diferentes criterios: fijar el número de épocas de antemano, fijar un umbral del error por debajo del cual detener el proceso de aprendizaje, fijarse en la evolución de los errores, etc. La solución empleada en este trabajo es dividir el conjunto de datos etiquetado en tres conjuntos: entrenamiento, validación y test. Con el primero de ellos se entrena la red y con el segundo se comprueba el funcionamiento de la red entrenada con patrones no vistos anteriormente y se decide el momento en el que se detiene el entrenamiento. El objetivo de este método es obtener la mejor capacidad de generalización posible, ya que llega un momento en el que el error de generalización empieza a aumentar porque la red está “sobreadaptando” los patrones de entrenamiento, lo que conduce a una peor capacidad de generalización.
4. **Arquitectura de la red.** Como ya se comentó anteriormente, la elección del número de neuronas ocultas, así como el número de capas ocultas es problemática porque es básicamente un proceso de prueba y error. En este trabajo se han elegido arquitecturas con un número de neuronas variables de 10 a 20. Asimismo, se han evaluado arquitecturas con 1 y 2 capas ocultas.
5. **Función de error.** Esta función determinará el mínimo al cual tienden los pesos de la red. La función de error empleada en este trabajo es el error cuadrático medio:

$$e = \sum_{k=1}^{N_s} (d_k - y_k)^2, \quad (5.3.7)$$

siendo  $y_k$  la salida de la neurona de salida  $k$ ,  $d_k$  el valor deseado de dicha salida y  $N_s$  el número de neuronas en la capa de salida (que en nuestro problema viene dado por el número de clases a clasificar).

### **Estrategia de segmentación. Comparación de grupos de bandas**

Tras la etapa de selección de longitudes de onda, se han construido modelos de clasificación basados en CART y ANN para segmentar imágenes hiperespectrales con diferentes subconjuntos de bandas. Las entradas a los modelos de clasificación han sido el valor de reflectancia del píxel ( $\lambda$ ), el valor promedio de una vecindad del píxel ( $\bar{\lambda}$ ) y la desviación típica de la vecindad del píxel ( $\sigma$ ). Por ejemplo, si se hubieran seleccionado 10 longitudes de onda con los métodos de selección, el clasificador tendría 30 entradas.

Se han elaborado modelos de segmentación basados en las técnicas de selección de características que mejores resultados proporcionan para los diferentes tamaños de ventana ensayados y en dos clasificadores no lineales, CART y ANN. En concreto, se ha evaluado la selección del número óptimo de bandas espectrales proporcionadas por el mejor método de selección de características individual y la del comité de expertos, con vecindades de  $3 \times 3$  y  $5 \times 5$ , y los clasificadores propuestos. Esta decisión está motivada para determinar cuál es la estrategia óptima de segmentación (método de selección+vecindad+clasificador). Utilizando la mejor estrategia se ha elaborado un clasificador de fruta a partir de características obtenidas de las imágenes segmentadas.

Una vez construidos los modelos de segmentación se ha evaluado su rendimiento mediante el acierto promedio del segmentador (OA) y la  $\kappa$  de Cohen<sup>5</sup> en el conjunto de test. Esta decisión está motivada con el fin de evaluar tanto el acierto como el rendimiento global del clasificador, por ejemplo utilizando esta medida se puede evaluar si el clasificador está sesgado hacia una o más clases.

#### **5.3.6. Clasificación de frutas**

Se ha implementado una metodología de clasificación de fruta a partir de la imagen segmentada por la mejor estrategia de segmentación. El clasificador elegido es un árbol de decisión con las 4 clases definidas en el material vegetal de este ensayo (*trips*/rameados, Fruta sana, Podredumbre por *Penicillium digitatum* y *Penicillium italicum*). Las características de entrada del clasificador son los siguientes:

- Porcentaje de píxeles en la imagen segmentados como “*trips*/rameados” (PTR).

---

<sup>5</sup> $\kappa$  de Cohen ya utilizada en el capítulo anterior sirve para evaluar el rendimiento de un clasificador.

- Porcentaje de píxeles en la imagen segmentados como “piel sana verde” (PSV).
- Porcentaje de píxeles en la imagen segmentados como “piel sana naranja” (PSN).
- Porcentaje de píxeles en la imagen segmentados como “*p. digitatum*” (PPD).
- Porcentaje de píxeles en la imagen segmentados como “*p. italicum*” (PPI).

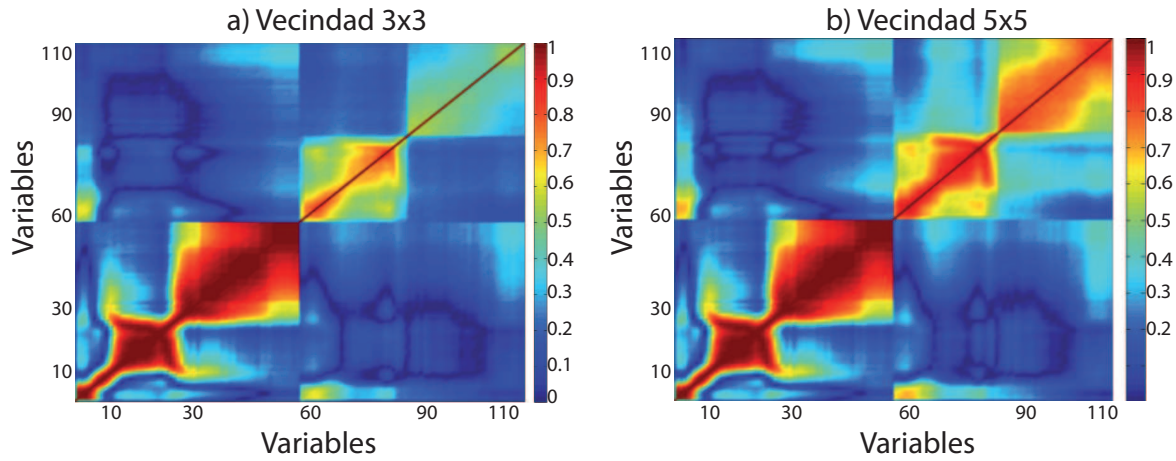
Dichos porcentajes se han obtenido a partir de las imágenes segmentadas con la mejor estrategia de segmentación. El modelo se ha entrenado utilizando una selección aleatoria del 40 % del material vegetal utilizado en este ensayo, el 60 % de las frutas restante se ha utilizado para validar el modelo.

## 5.4. Resultados

### 5.4.1. Selección de bandas

La figura 5.6 muestra las matrices de correlación lineal utilizadas para realizar la preselección de variables (media y desviación típica de cada banda adquirida) que se han empleado como entradas de los métodos de selección con los dos tamaños de vecindad ensayados. La principal diferencia entre ambos conjuntos de datos radica en que el grupo de variables a partir de la banda 57 (desviaciones típicas de cada banda) presenta una correlación más elevada en la vecindad  $5 \times 5$  que en la vecindad  $3 \times 3$ ; este hecho se debe a que en la primera vecindad las distribuciones de datos están más suavizadas. Tras descartar las variables contiguas con una correlación mayor de  $|0,9|$  se han preseleccionado 87 variables con ambas vecindades de las 114 variables iniciales. La tabla 5.1 muestra los dos tipos de variable (media y desviación típica) y dentro de cada tipo las bandas preseleccionadas utilizando una y otra vecindad. En ambos conjuntos, el proceso de preselección afecta a las variables de tipo promedio.

Las variables preseleccionadas se han utilizado como entrada de los métodos de selección. La figura 5.7 muestra el rendimiento, a efectos de acierto de un clasificador CART, en función del número de variables seleccionadas (en orden creciente del ranking) con cada uno de los métodos de selección para ambas vecindades. Se observa que el número de variables a partir del que se produce la saturación en el acierto del clasificador es 10 en ambas vecindades. En dicha figura se observa que todos los métodos de selección proporcionan rendimientos similares. No obstante, el método de selección individual que proporciona los mejores resultados en la clasificación es MRMR. El método que se coloca en segunda posición es CE. Otro resultado destacable es que en el conjunto de la vecindad  $3 \times 3$  el acierto promedio (95 %) (en el que se produce la saturación) es




**Figura 5.6:** Matriz de correlación para la preselección de variables espectrales media y desviación típica utilizando, a) una vecindad  $3 \times 3$  y b)  $5 \times 5$ .

Vecindad/Tipo de variable	$\bar{\lambda}(\text{nm})$					$\sigma(\text{nm})$
$3 \times 3$	460	480	500	510	520	TODAS
	530	540	550	560	590	
	610	640	690	700	710	
	730	770	780	790	810	
	830	840	850	860	870	
	880	900	920	930	960	
$5 \times 5$	460	480	490	510	520	TODAS
	530	550	560	570	600	
	620	630	650	690	700	
	720	740	770	790	810	
	820	830	840	850	870	
	880	890	910	930	970	

**Tabla 5.1:** Resultado de la preselección de bandas en las vecindades  $3 \times 3$  y  $5 \times 5$

ligeramente menor que en la vecindad  $5 \times 5$  (97%). Este resultado, sin ser definitivo, muestra un primer indicio (que se verificará en el estudio más detallado que se mostrará en la siguiente sección) acerca de qué vecindad es más adecuada para la segmentación de las imágenes hiperespectrales

de este ensayo.



**Figura 5.7:** Evaluación del número óptimo de variables a seleccionadas con cada uno de los métodos de selección empleada utilizando, a) una vecindad  $3 \times 3$ , b) una vecindad  $5 \times 5$ .

Los métodos de selección vencedores en este primer ensayo de rendimiento son, en ambas vecindades, MRMR y CE. Así pues, los conjuntos de variables proporcionados por estos métodos van a ser el punto de partida para determinar las longitudes de onda más relevantes para el problema de clasificación propuesto según la metodología propuesta en la sección 5.3. La tabla 5.2 muestra los grupos de longitudes de onda obtenidos (en orden decreciente de relevancia) a partir de cada uno de los métodos de selección vencedores para cada vecindad estudiada.


Vecindad/Método de selección	MRMR (nm)				CE (nm)			
$3 \times 3$	770	690	700	730	690	770	640	610
	930	640	530	970	700	710	730	590
	610	510			540	780		
$5 \times 5$	650	720	700	740	690	650	630	720
	930	530	770	710	770	480	740	620
	480	460			700	600		

**Tabla 5.2:** Selección de bandas proporcionadas por CE y MRMR utilizando vecindades  $3 \times 3$  y  $5 \times 5$

No se observa una coincidencia completa de las bandas proporcionadas con cada método. No obstante, sí que existen determinadas zonas del espectro de trabajo en las que se aprecia una ligera acumulación de bandas proporcionadas por todos los métodos. La figura 5.8 muestra la superposición de los espectros promedio correspondientes a cada clase del conjunto de datos etiquetado y las zonas de acumulación de bandas arriba citadas. La acumulación de bandas relevantes en las regiones sombreadas de la figura 5.8 se puede deber a fenómenos físicos de absorción:

- **Región rosa (470-490 nm).** Esta zona permite, junto con la amarilla, diferenciar claramente los píxeles afectados por *trips*/rameados. Estos defectos se caracterizan por presentar un color marrón característico que contiene un elevado nivel de color azul respecto al resto de clases y un déficit de color verde comparado con los píxeles de piel verde.
- **Región amarilla (600-630 nm).** Esta región permite diferenciar el grado de maduración de la fruta, ya que los píxeles de piel naranja y los afectados por podredumbres presentan una elevada reflectividad respecto a los píxeles de piel sana verde y daños por *trips*. El grado de maduración de los frutos con podredumbres es generalmente avanzado, las podredumbres atacan más fácilmente a frutos maduros debido al bajo contenido de flavonoides (Cercós et al., 2005) en los mismos.
- **Región verde (670-710 nm).** Esta región espectral coincide con el intervalo de absorción debido a la presencia de clorofila en tejidos vegetales (680 nm).
- **Región violeta (760-790 nm).** Esta región coincide con la zona de elevada reflectividad debido a la presencia de celulosa en la piel de los cítricos (Ververis et al., 2007). En esta región del espectro no existen fenómenos significativos de absorción debido a componentes bioquímicos, la principal contribución se debe a la celulosa y otros carbohidratos estructurales. La elevada reflectancia observada en esta región se debe al fenómeno reflexiones múltiples en la epidermis del fruto causadas por la estructura interna de la misma. La reflectancia de los píxeles correspondientes a frutos dañados (TR, PD y PI) es considerablemente menor en esta zona del espectro que en los píxeles sanos. Este fenómeno indica un cambio en la estructura interna de los frutos que presentan daño respecto a los sanos.
- **Región azul (940-980 nm).** Esta región coincide con un pico de absorción secundario, pero importante, del agua centrado en 980 nm (Curcio and Petty, 1951). En estados tempranos de infecciones fúngicas en cítricos, uno de los primeros efectos que produce el hongo en la epidermis del cítrico es la rotura de la pared celular produciendo una acumulación de agua bajo la epidermis del fruto podrido. De este modo se justifica la mayor absorbancia en esta región espectral presente en los píxeles de zonas podridas.

La selección de bandas tiene un doble propósito, obtener las bandas a adquirir que servirán de entrada a los modelos de segmentación que se mostrarán en la siguiente sección y extraer conocimiento sobre qué regiones del espectro contienen información sobre el problema tratado que puede ser utilizada para implementar sistemas industriales a medida. Fruto de los resultados obtenidos se han implementado varios subsistemas en el IVIA en una máquina de clasificación de podridos patentada y en explotación por la empresa RODA IBERICA S.L (Blanc et al., 2007), actualmente en fase de pruebas en varios almacenes citrícolas.



**Figura 5.8:** Zonas del espectro de trabajo con más bandas seleccionadas por CE y MRMR.

#### 5.4.2. Segmentación no lineal con árboles de decisión y redes neuronales

En esta sección se evaluará el rendimiento de los modelos de segmentación basados en CART y ANN utilizando las bandas seleccionadas por los mejores métodos de selección. Asimismo se determinará qué tamaño de vecindad produce mejores resultados en la segmentación. Cada uno de los clasificadores de píxel consta de 30 entradas (3 entradas por banda seleccionada,  $\lambda$ ,  $\bar{\lambda}$  y  $\sigma$ ) obtenidas a partir de las bandas proporcionadas por los métodos de selección CE y MRMR. Para determinar el rendimiento de las diferentes estrategias de segmentación<sup>6</sup> se han empleado dos medidas: el acierto promedio (OA) y la  $\kappa$  de Cohen (Sim and Wright, 2005) en el conjunto etiquetado de test. El acierto promedio del clasificador proporciona conocimiento sobre la exactitud del clasificador (comprendida entre el 0% y 100%). La  $\kappa$  de Cohen (comprendida entre 0 y 1) proporciona información de si el clasificador está sesgado hacia alguna de las clases.

Se han implementado 4 estrategias de segmentación basadas en CART:

- **CART-CE-3x3.** Este modelo se caracteriza por utilizar una vecindad de tamaño 3 del píxel a clasificar y utilizar las bandas proporcionadas por CE.
- **CART-MRMR-3x3.** Este modelo se caracteriza por utilizar una vecindad de tamaño 3 del píxel a clasificar y utilizar las bandas proporcionadas por MRMR.

<sup>6</sup>Consideramos como estrategia de segmentación el conjunto clasificador+ método de selección + vecindad.

- **CART-CE-5x5.** Este modelo se caracteriza por utilizar una vecindad de tamaño 5 del píxel a clasificar y utilizar las bandas proporcionadas por CE.
- **CART-MRMR-5x5.** Este modelo se caracteriza por utilizar una vecindad de tamaño 5 del píxel a clasificar y utilizar las bandas proporcionadas por MRMR.

Acierto promedio (OA) y $\kappa$ de Cohen en segmentadores CART				
	Conjunto de Entrenamiento		Conjunto de Test	
	CART-CE	CART-MRMR	CART-CE	CART-MRMR
3 × 3	OA = 95,41 % $\kappa = 0,942$	OA = 92,52 % $\kappa = 0,906$	OA = 91,20 % $\kappa = 0,890$	OA = 89,11 % $\kappa = 0,864$
5 × 5	OA = 97,01 % $\kappa = 0,961$	OA = 95,93 % $\kappa = 0,949$	OA = 94,65 % $\kappa = 0,933$	OA = 93,71 % $\kappa = 0,921$

**Tabla 5.3:** Acierto promedio OA y  $\kappa$  de Cohen de las diferentes estrategias de segmentación basadas en CART.

La tabla 5.3 muestra los parámetros OA y  $\kappa$  para evaluar cada una de las estrategias basadas en CART para los conjuntos de entrenamiento<sup>7</sup> y test. La misma tabla, resaltado en color verde y amarillo, muestra el valor de estos parámetros para las estrategias vencedoras para los conjuntos de entrenamiento y test respectivamente. CART-CE-5x5 se muestra cómo la estrategia que mejores resultados proporciona en entrenamiento y test, tanto a nivel de exactitud (OA = 97,01 % entrenamiento, OA = 94,65 % test) como de sesgo ( $\kappa = 0,961$  entrenamiento,  $\kappa = 0,933$  test). El parámetro OA presenta pocas diferencias en los conjuntos de entrenamiento y test. Este hecho pone de manifiesto que el proceso de etiquetado de píxeles se ha realizado de manera uniforme y que la capacidad de generalización de los modelos desarrollados es elevada.

A continuación se han implementado 4 modelos de segmentación basados en ANN con una y dos capas ocultas respectivamente. Después de evaluar cada una de las redes neuronales (2000 de una sola capa y 20000 de dos capas) correspondientes a las diferentes arquitecturas, inicializaciones de pesos sinápticos y estrategias de selección, las mejores modelos para cada estrategia basada en ANN son:

- **ANN1-CE3x3.** Este modelo se caracteriza por utilizar una vecindad de tamaño tres del píxel a clasificar y utilizar las bandas proporcionadas por CE. La red neuronal que ha

<sup>7</sup>Construidos los modelos, se han fusionado los conjuntos de entrenamiento y validación, diferenciando así del conjunto de test que nunca ha sido visto por los modelos.



proporcionado mejores resultados en test con la estrategia presentada tiene 15 neuronas en su capa oculta.

- **ANN1-MRMR3x3.** Este modelo se caracteriza por utilizar una vecindad de tamaño tres del píxel a clasificar y utilizar las bandas proporcionadas por MRMR. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene 19 neuronas en su capa oculta.
- **ANN1-CE5x5.** Este modelo se caracteriza por utilizar una vecindad de tamaño cinco del píxel a clasificar y utilizar las bandas proporcionadas por CE. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene 17 neuronas en su capa oculta.
- **ANN1-MRMR5x5.** Este modelo se caracteriza por utilizar una vecindad de tamaño cinco del píxel a clasificar y utilizar las bandas proporcionadas por MRMR. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene 17 neuronas en su capa oculta.
- **ANN2-CE3x3.** Este modelo se caracteriza por utilizar una vecindad de tamaño tres del píxel a clasificar y utilizar las bandas proporcionadas por CE. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene dos capas ocultas, 13 neuronas en la primera y 13 en la segunda.
- **ANN2-MRMR3x3.** Este modelo se caracteriza por utilizar una vecindad de tamaño tres del píxel a clasificar y utilizar las bandas proporcionadas por MRMR. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene dos capas ocultas, 15 neuronas en la primera y 19 en la segunda.
- **ANN2-CE5x5.** Este modelo se caracteriza por utilizar una vecindad de tamaño cinco del píxel a clasificar y utilizar las bandas proporcionadas por CE. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene dos capas ocultas, 18 neuronas en la primera y 17 en la segunda.
- **ANN2-MRMR5x5.** Este modelo se caracteriza por utilizar una vecindad de tamaño cinco del píxel a clasificar y utilizar las bandas proporcionadas por MRMR. La red neuronal que ha proporcionado mejores resultados en test con la estrategia presentada tiene dos capas ocultas, 17 neuronas en la primera y 20 en la segunda.

La tabla 5.4 muestra los parámetros OA y  $\kappa$  para evaluar cada una de las estrategias basadas en ANN con una sola capa oculta para los conjuntos de entrenamiento y test. Tras analizar la tabla

Acierto promedio (OA) y $\kappa$ de Cohen en ANN con una capa oculta				
	Conjunto de Entrenamiento		Conjunto de Test	
	ANN1-CE	ANN1-MRMR	ANN1-CE	ANN1-MRMR
$3 \times 3$	$OA = 97,16 \%$ $\kappa = 0,964$	$OA = 97,77 \%$ $\kappa = 0,972$	$OA = 95,47 \%$ $\kappa = 0,94,3$	$OA = 95,38 \%$ $\kappa = 0,942$
$5 \times 5$	$OA = 99,31 \%$ $\kappa = 0,991$	$OA = 99,14 \%$ $\kappa = 0,989$	$OA = 98,30 \%$ $\kappa = 0,979$	$OA = 98,02 \%$ $\kappa = 0,975$

**Tabla 5.4:** Acierto promedio OA y  $\kappa$  de Cohen de las diferentes estrategias de segmentación basadas en ANN con una capa oculta.


se observa que ANN1-CE5x5 es la estrategia de segmentación que mejores resultados proporciona tanto en entrenamiento como en test. La exactitud de este modelo es  $OA = 99,31 \%$  en entrenamiento,  $OA = 98,30 \%$  en test. La tendencia en la  $\kappa$  es la misma,  $\kappa = 0,991$  en entrenamiento y  $\kappa = 0,979$  en test. La estrategia de segmentación ANN1-CE5x5 proporciona mejores resultados que la vencedora de las basadas en CART (CART-CE-5x5), este hecho pone de manifiesto que los modelos basados en ANN proporcionan un rendimiento más elevado que los basados en CART.

Acierto promedio (OA) y $\kappa$ de Cohen en ANN con dos capas ocultas				
	Conjunto de Entrenamiento		Conjunto de Test	
	ANN2-CE	ANN2-MRMR	ANN2-CE	ANN2-MRMR
$3 \times 3$	$OA = 97,74 \%$ $\kappa = 0,972$	$OA = 96,94 \%$ $\kappa = 0,962$	$OA = 95,34 \%$ $\kappa = 0,942$	$OA = 95,33 \%$ $\kappa = 0,941$
$5 \times 5$	$OA = 99,21 \%$ $\kappa = 0,990$	$OA = 99,06 \%$ $\kappa = 0,988$	$OA = 98,09 \%$ $\kappa = 0,976$	$OA = 98,02 \%$ $\kappa = 0,975$

**Tabla 5.5:** Acierto promedio OA y  $\kappa$  de Cohen de las diferentes estrategias de segmentación basadas en ANN con dos capas ocultas.

La tendencia se repite en los modelos basados en ANN con dos capas ocultas (tabla 5.5) siendo, ANN2-CE5x5 la estrategia basada en ANN con dos capas ocultas con un rendimiento más elevado. Estos resultados demuestran que el tamaño de vecindad óptimo es 5, al mostrarse repetidamente como la mejor vecindad independientemente de que técnica se utilice. A nivel de método de selección, CE se muestra como el mejor método en todos los tests realizados. Este hecho pone de manifiesto la robustez del método de selección de características CE ante la variación de clasificador utilizado.

La figura 5.9 muestra el producto de  $OA$  y  $\kappa$  para cada una de las estrategias implementadas en el conjunto de test. En dicha figura se observa que, en general, las estrategias basadas en ANN proporcionan un rendimiento más elevado a nivel global que las basadas en CART. Dentro de las estrategias basadas en ANN la que mejor rendimiento proporciona es ANN1-CE5x5 así pues ésta será la estrategia empleada para segmentar las imágenes hiperespectrales. Merece la pena resaltar que el modelo vencedor contiene una sola capa oculta con 17 neuronas, proporcionando un rendimiento más elevado que los modelos con dos capas ocultas. Este hecho se explica desde el punto de vista de la pérdida de capacidad de generalización al aumentar la complejidad del modelo.



**Figura 5.9:** Evaluación del rendimiento del segmentador mediante el producto del acierto promedio ( $OA$ ) y la  $\kappa$  de Cohen. En todas las estrategias evaluadas la tendencia en  $OA$  y la  $\kappa$  es la misma si se representan ambos parámetros por separado.

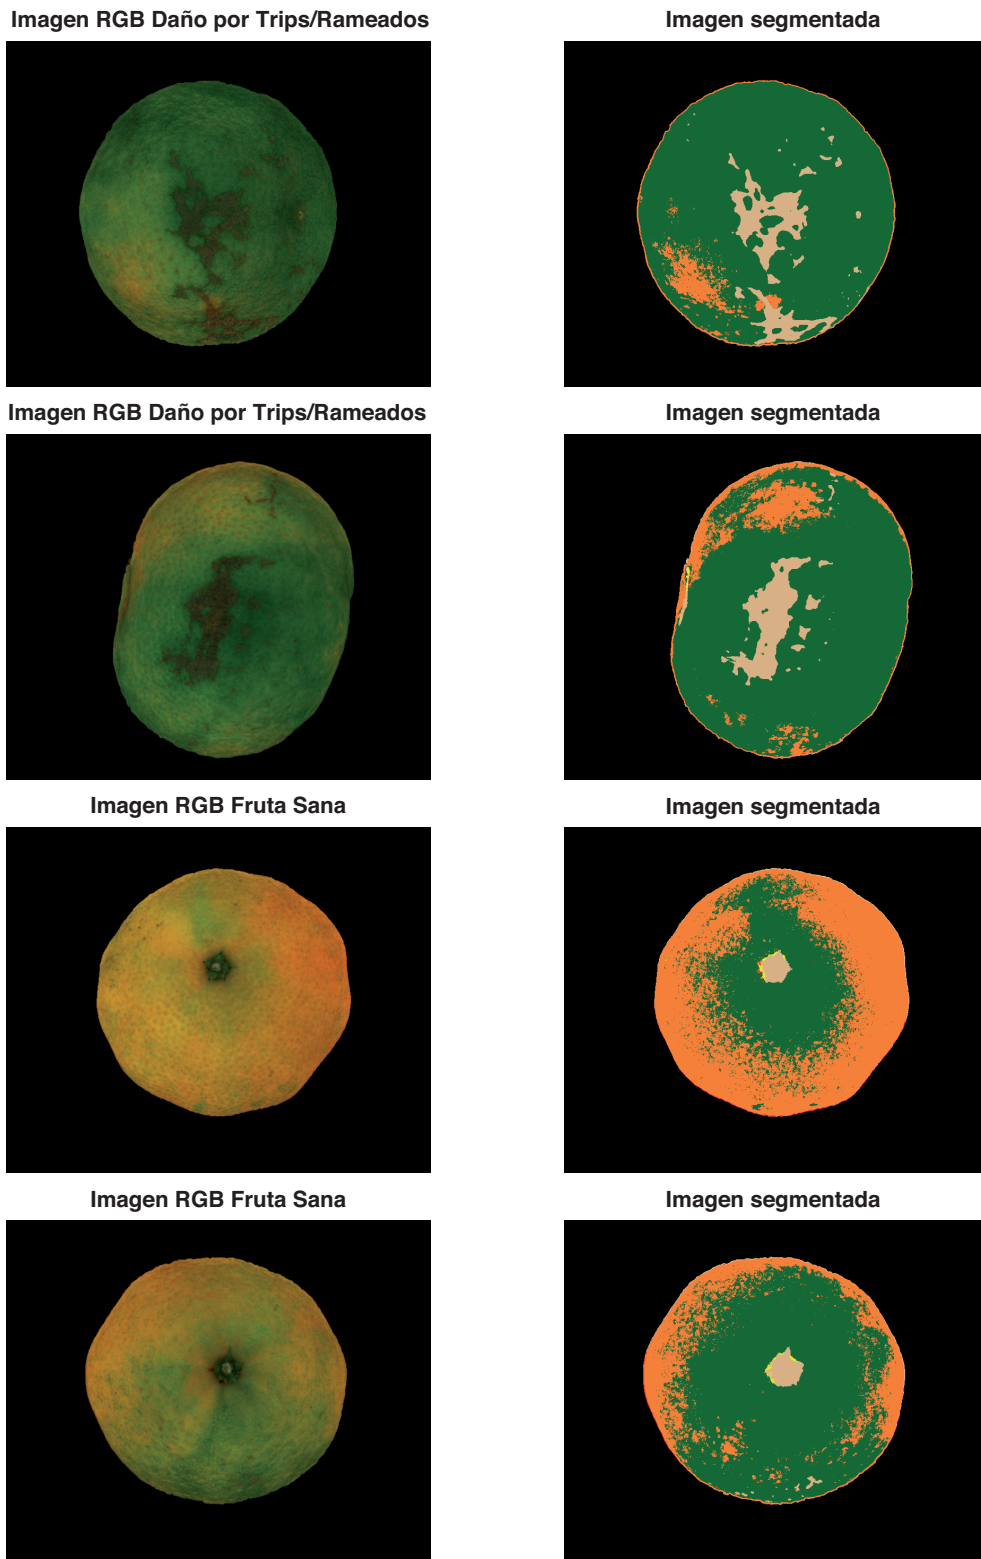
La tabla 5.6 muestra las matrices de confusión de entrenamiento y test de la estrategia de segmentación ANN1-CE5x5. Se observa que los resultados de entrenamiento y test son muy similares mostrando la excelente capacidad de generalización de la estrategia empleada. La matriz de confusión del conjunto de test muestra que los errores de la clasificación se producen principalmente en el número de falsos positivos PI, en la clase PD, y falsos positivos PD en la clase PI, lo cuál era de esperar teniendo en cuenta la similitud entre el daño producido por ambos hongos. Merece la pena destacar el bajo porcentaje de píxeles sanos (PV y PN) clasificados como podridos (PD y PI).

Además, el clasificador es capaz de distinguir claramente las dos clases de podredumbres presentes, a pesar la similitud del daño que ambas producen. Los resultados de segmentación obtenidos en los ensayos de este capítulo de la Tesis Doctoral (98.30% utilizando 10 bandas) mejoran los obtenidos en trabajos previos de detección de podredumbre (91.80% utilizando con 20 bandas) (Gómez-Sanchis et al., 2008b, 2006). La mejora no sólo se produce en el índice de acierto sino que además estos resultados se han obtenido utilizando una base de datos con más defectos y utilizando un menor número de bandas (10 bandas menos). Este incremento en el rendimiento del segmentador se debe a varias razones: la mejora del sistema de iluminación empleado en los experimentos de este capítulo, la metodología propuesta de selección de bandas es más robusta ante cambios en el clasificador, la inclusión de información espacial (media y desviación típica de una vecindad) y el empleo de técnicas de clasificación más potentes como las ANN.

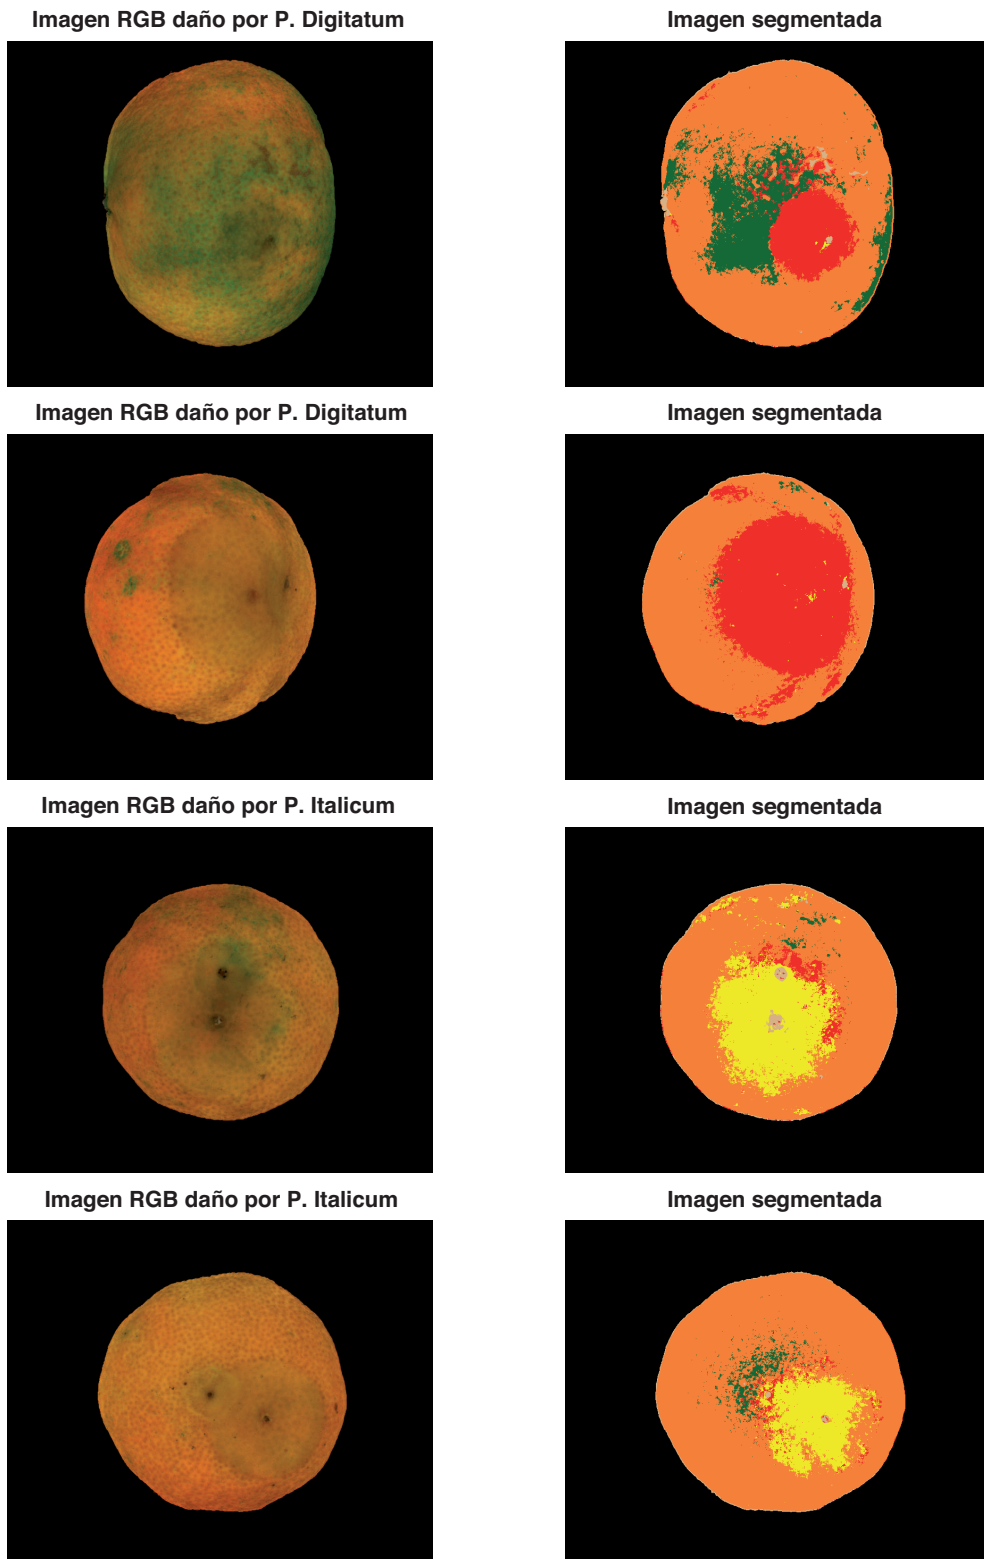
ANN1-CE5x5 Conjunto entrenamiento					
Clasificación/Clase	TR (%)	PV (%)	PD (%)	PI (%)	PN (%)
TR	100	0	0	0	0
PV	0	98.6	0	0	0
PD	0	0	98.2	0.2	0
PI	0	0	1.8	99.8	0.9
PN	0	1.4	0	0	99.1
$\kappa=0.991$		Acierto Promedio=99.31%			
ANN1-CE5x5 Conjunto test					
Clasificación/Clase	TR (%)	PV (%)	PD (%)	PI (%)	PN (%)
TR	99.9	0	0	0	0
PV	0	98.58	0.02	0	0.24
PD	0	0.19	97.07	2.08	0.68
PI	0.1	0	2.33	97.52	0.59
PN	0	1.23	0.58	0.41	98.50
$\kappa=0.979$		Acierto Promedio=98.30%			

**Tabla 5.6:** Matrices de confusión (entrenamiento y test) de la estrategia de segmentación ANN1-CE5x5.

A continuación, decidida la estrategia de segmentación óptima, de las propuestas en este trabajo se procedió a segmentar las imágenes obtenidas a partir del material vegetal.



**Figura 5.10:** Imágenes RGB y segmentadas con la estrategia ANN1-5x5CE de mandarinas cv. clemenules dañadas por trips y sanas.



**Figura 5.11:** Imágenes RGB y segmentadas con la estrategia ANN1-5x5CE de mandarinas cv. clemenules dañadas por *Penicillium digitatum* y *Penicillium italicum*

La figura 5.10 muestra ejemplos de segmentación de fruta sana y fruta dañada por *trips*/rameados. En la columna de la izquierda se muestra la imagen RGB del cítrico y en la de la derecha la imagen segmentada con la estrategia ANN1-CE5x5. El color verde y naranja se corresponden con las clases PV y PN respectivamente, el color marrón se corresponde con la clase TR y, los colores rojo y amarillo con las clases PD y PI respectivamente.

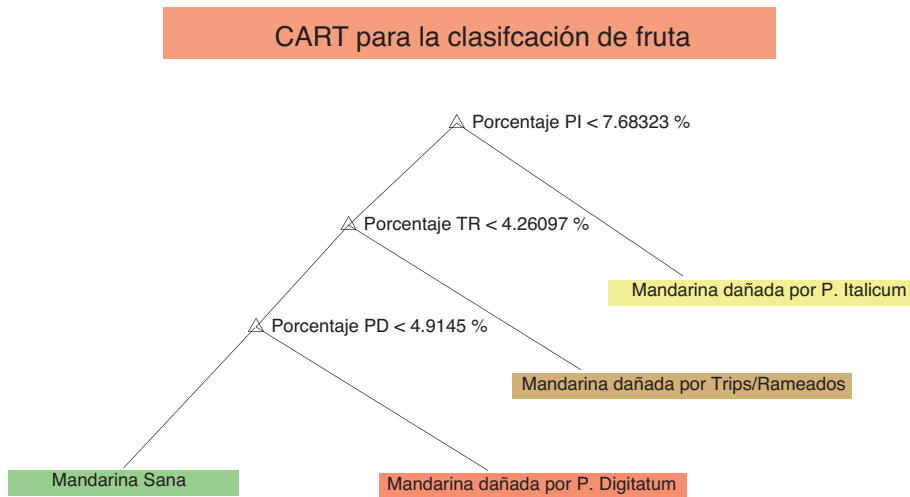
En las primeras figuras se observa que la estrategia de segmentación propuesta es capaz de distinguir los daños producidos por *trips*/rameados. Se aprecia un número reducido de píxeles clasificados como PI y PD, estos píxeles se consideran como ruido de clasificación y prácticamente no se percibe en las imágenes segmentadas. Resaltar que en los ejemplos mostrados, los píxeles del pedúnculo del fruto son clasificados como *trips*/rameados, ya que la clase pedúnculo no se ha incluido en el segmentador y los píxeles del pedúnculo presentan una coloración muy similar a la clase TR. No obstante, esto no supone un problema para clasificar imágenes ya que el tamaño del pedúnculo es muy pequeño respecto a la mayoría de defectos por *trips*/rameados y en este trabajo no se está tratando de discriminar defectos por tamaño.

La figura 5.11 muestra ejemplos de segmentación de fruta con defectos que evolucionan con el tiempo, *Penicillium digitatum* y *Penicillium italicum*. Las dos primeras imágenes se corresponden con frutos afectados por *penicillium digitatum* y las dos últimas con frutos afectados por *Penicillium Italicum*. La codificación de colores empleada en las imágenes segmentadas es la misma que la empleada en la figura 5.10. Las imágenes RGB de dicha figura muestran la similitud del daño producido por ambos tipos de podredumbres en el visible. A pesar de ello, las imágenes segmentadas muestran como el segmentador es capaz de diferenciar claramente una podredumbre de otra en frutos con diferentes grados de desverdización del fruto. Este resultado concuerda con los buenos resultados de segmentación mostrados en la tabla 5.5.

### 5.4.3. Clasificación de fruta con CART

La figura 5.12 muestra el árbol de clasificación empleado para clasificar los cítricos de la base de datos de este capítulo. El árbol construido muestra los umbrales en los porcentajes de cada daño en las imagen segmentadas. Una de las principales ventajas de CART es que los resultados que proporciona son (completamente) interpretables ya que los umbrales obtenidos en los nodos de decisión proporcionan una idea del tamaño mínimo de daño presente en la base de datos. Observando la figura se aprecia que en ningún nodo de decisión aparece la característica de entrada “Porcentaje de PV” o “Porcentaje de PN”. Así pues, estas características no tienen que ser calculadas, lo que mejora la velocidad de clasificación del algoritmo. El principal inconveniente del método de clasificación es que si una fruta presenta un defecto con un tamaño menor que los umbrales que proporciona el árbol ésta sería mal clasificada. Este problema podría reducirse au-

mentando la variabilidad en los tamaños de defectos presentes en la base de datos y construyendo otro árbol diferente.



**Figura 5.12:** Árbol de decisión para la clasificación de fruta. Si la condición se cumple el patrón se desplaza hacia la izquierda.

La tabla 5.7 muestra los resultados de clasificación de fruta en entrenamiento y test utilizando la estrategia de segmentación ANN1-CE5x5. En la misma tabla se observa como principal resultado que los cítricos sanos son correctamente clasificados en entrenamiento y prácticamente la totalidad en test (97,33%). El porcentaje de fruta podrida por ambos hongos clasificado como sano es de un 0%. Este resultado es crucial desde el punto de vista de estándares de calidad que impone la industria cítrica. El clasificador presenta un leve tendencia (1,02%) a clasificar frutos podridos por *Penicillium italicum* como *Penicillium digitatum*. Esta mínima tasa de falsos positivos no supone un problema grave para esta clase, ya que a efectos de detección de podredumbre, la industria cítrica descarta cualquier fruto con podredumbres del tipo que sea. Los resultados obtenidos mejoran significativamente los presentados en trabajos previos de detección de podredumbres (en torno al 90% únicamente con dos clases “sano” y “podrido”) (Gómez-Sanchis et al., 2008b; Blasco et al., 2007a) mejorando los mismos en el número de características a emplear e incrementando la variedad de tipos de defectos y podredumbres.

La implementación de la metodología de segmentación y clasificación propuesta se puede realizar utilizando un sistema de visión hiperespectral o un sistema de visión por computador multiespectral a medida que implemente el conocimiento extraído de la selección de bandas realizada en este trabajo. El trabajo presentado en este capítulo de la Tesis Doctoral constituye una opción adecuada y novedosa para clasificar frutos con podredumbres producidas por *Peni-*



Matriz de confusión Frutas entrenamiento. Clasificación de fruta				
Clasificación/Clase	T/R (%)	S (%)	P.D (%)	P.I (%)
<b>Trips/Rameado</b>	88.46	0	0	0
<b>Sano</b>	3.84	100	0	0
<b><i>P.Digitatum</i></b>	7.70	0	94.4	0
<b><i>P.Italicum</i></b>	0	0	5.56	100
$\kappa=0.940$		Acierto Promedio=95.83%		

Matriz de confusión Frutas Test. Clasificación de fruta				
Clasificación/Clase	T/R (%)	S (%)	P.D (%)	P.I (%)
<b>Trips/Rameado</b>	82.35	0	0	0
<b>Sano</b>	8.84	97.33	0	0
<b><i>P.Digitatum</i></b>	8.82	2.77	100	1.02
<b><i>P.Italicum</i></b>	0	0	0	98.98
$\kappa=0.910$		Acierto Promedio=93.06%		

**Tabla 5.7:** Matrices de confusión en clasificación de fruta con CART.

*llium digitatum*, *Penicillium italicum* y defectos superficiales en cítricos con diferentes grados de maduración.

## 5.5. Conclusiones

En este capítulo de la Tesis Doctoral se ha planteado el problema de detección y clasificación de mandarinas cv. clemenules con defectos comunes (*trips*/rameados) y dos tipos de podredumbres *Penicillium digitatum* y *Penicillium italicum*. Con el fin de reducir el número de bandas a adquirir y extraer conocimiento sobre las variables más importantes en el problema dado, se han implementado 8 métodos de selección de características de tipo *filter*: TT, DKL, CA, CB, LW, ROC, MRMR y CE. Con los siete primeros métodos se ha implementado el último a modo de comité de expertos. El número óptimo de bandas, utilizando la metodología propuesta, ha sido de 10 y los métodos de selección que han producido un rendimiento más elevado han sido MRMR y CE.

Con los valores de reflectancia del píxel, el valor medio de una vecindad de tamaño 3 o 5 y la desviación típica de dicha vecindad de las bandas seleccionadas, se han construido estrategias de segmentación basadas en CART y ANN. Tras analizar el rendimiento de todas las estrategias se ha comprobado que la vecindad que produce mejores resultados en todos los casos ha sido de

tamaño 5.

Asimismo, ANN produce mejores resultados en la segmentación que CART y, dentro de las estrategias basadas en redes neuronales las de una sola capa oculta se han mostrado más eficientes. La mejor estrategia de segmentación, ANN1-5x5CE, presenta excelentes índices de rendimiento en test ( $OA = 98,3\%$  y  $\kappa = 0,979$ ) y es capaz de diferenciar los píxeles de zonas sanas de los que presentan daños por *trips*, rameados y podredumbres. A su vez, el sistema solventa con éxito uno de los objetivos más ambiciosos de este capítulo de la Tesis Doctoral, la distinción entre los defectos producidos por *Penicillium digitatum* y *Penicillium italicum*.

A partir del porcentaje de cada uno de los daños en la imagen segmentada, se ha construido un árbol de decisión para determinar la clase a la que pertenece la fruta. Los índices de rendimiento para este clasificador,  $OA = 93,06\%$  y  $\kappa = 0,910$ , indican que el modelo es preciso, fiable y desde el punto de vista práctico es capaz de diferenciar correctamente las mandarinas podridas de las sanas (0% de fruta podrida clasificada como sana). La metodología propuesta es capaz de discriminar entre dos tipos de podredumbres y el rendimiento obtenido mejora significativamente los índices obtenidos en trabajos previos, utilizando un menor número de bandas. La selección de bandas obtenida y la metodología propuesta son completamente generales y pueden utilizarse para implementar un sistema de visión por computador multiespectral para detectar podredumbres en cítricos.

## Capítulo 6

# Conclusiones generales, proyección futura y logros alcanzados

### 6.1. Aportaciones de la Tesis Doctoral y conclusiones generales

Los estudios realizados en el ámbito de esta Tesis Doctoral se justifican por la importancia que tiene la detección y eliminación de fruta podrida en las líneas de confección de cítricos. En la actualidad no existen sistemas automáticos capaces de detectar podredumbres en cítricos, por lo que esta tarea se lleva a cabo de manera manual por operarios especializados. El gran problema que presenta esta enfermedad es que debido a que los daños que causan son difíciles de observar a simple vista, los operarios realizan su labor en cámaras oscuras donde la fruta se ilumina con luz ultravioleta, que es potencialmente dañina para la piel de las personas. En cuanto a la distinción y clasificación de distintas podredumbres (por ejemplo, distinguir entre la podredumbre verde y azul), actualmente, esta tarea no se realiza ni manualmente ni automáticamente debido a la similitud que presentan ambos tipos de defectos en el fruto. A efectos prácticos ambas podredumbres son igualmente peligrosas y las frutas afectadas deben ser eliminadas. Sin embargo, esta distinción puede aportar un conocimiento importante a la hora de aplicar tratamientos preventivos o fungicidas. Este problema no sólo está por resolver en el ámbito industrial, en la actualidad existe un número muy reducido de publicaciones científicas sobre la detección y clasificación de podredumbres en cítricos utilizando sistemas automáticos de visión con tasas de acierto en la clasificación satisfactorias.

Esta Tesis Doctoral analiza y aporta conocimiento sobre para la detección automática de podredumbres en cítricos sin el empleo de la peligrosa iluminación ultravioleta, desarrollando para ello un sistema de procesamiento de imágenes hiperespectrales en cítricos. Para llevar a cabo este

cometido se han desarrollado técnicas novedosas a nivel de adquisición, preprocesado y análisis de imágenes hiperespectrales de cítricos.

En relación con la adquisición de las imágenes hiperespectrales, se ha desarrollado un sistema de visión hiperespectral basado en filtros sintonizables de cristal líquido y se ha propuesto una metodología con diferentes etapas para la puesta a punto del mismo. Este sistema incorpora dos LCTF (solventando la problemática añadida por el empleo de dos filtros) y permite adquirir imágenes hiperespectrales desde 460 nm hasta 1020 nm con una resolución espectral de 10 nm.

Se ha mostrado la necesidad de preprocesar las imágenes hiperespectrales para reducir los efectos adversos que introduce la forma esférica del cítrico y poder extraer conocimiento de las imágenes hiperespectrales. Para solventar este problema se ha desarrollado una metodología novedosa de preprocesado de imágenes de objetos esféricos basado en la obtención de un modelo de elevación digital de las frutas. La metodología propuesta es completamente general y se puede aplicar a otros problemas de inspección utilizando visión por computador.

En esta Tesis Doctoral se ha propuesto la combinación de una serie de técnicas de aprendizaje automático de selección de características (*filter* y *wrapper*) y clasificación (lineales y no lineales) con el fin de detectar podredumbres producidas por *Penicillium digitatum* a partir de imágenes hiperespectrales e iluminación halógena difundida mediante un difusor cilíndrico. Los resultados obtenidos en la detección de podredumbres producidas por este hongo (aproximadamente un 90 % de detecciones correctas) supera los obtenidos en trabajos previos (situados en torno al 65 %). No obstante el número de bandas empleadas (20) es elevado para implementar dicho conocimiento en un sistema de inspección a medida.

A la conclusión de los ensayos de detección de podredumbres, se ha propuesto una metodología novedosa de clasificación de podredumbres producidas por *Penicillium digitatum*, *Penicillium italicum* y daños comunes (*trips* y rameados). Se ha demostrado que empleando un sistema de iluminación basado en un difusor semiesférico, utilizando información espacial y espectral de la escena y combinando la información proporcionada por varios métodos de selección de características y empleando clasificadores no lineales, es posible aumentar el rendimiento de la metodología de detección propuesta. La mejora no sólo se produce a efectos de rendimiento en la clasificación (índice de acierto y número de defectos clasificables), sino que también se ve reflejada por un descenso en el número de bandas necesario (10) para conseguir este fin, llegando a ser muy próximo a los empleados por algunos sistemas de inspección comerciales.

La relevancia y el carácter novedoso de los estudios propuestos en esta Tesis Doctoral están avalados por la publicación de sus resultados en ocho publicaciones en revistas científicas internacionales indexadas pertenecientes al ámbito de la Agroingeniería y una patente en explotación relativa a la invención de una máquina para detectar las podredumbres de los cítricos de forma

automática. Dichos estudios demuestran que es posible detectar y clasificar los daños producidos por las podredumbres más comunes de los cítricos en poscosecha empleando un sistema multispectral con 10 bandas e iluminación halógena. Las técnicas propuestas proporcionan resultados adecuados y novedosos en cuanto a la clasificación de dos tipos de podredumbres en cítricos y mejoran los resultados de detección de podredumbres producidas por *Penicillium digitatum*, sentando las bases para la implementación de un prototipo basado en tecnología multispectral para la clasificación de podredumbres en tiempo real.

## 6.2. Conclusiones específicas

### 6.2.1. Sistemas de visión hiperespectral

Las conclusiones obtenidas en esta parte de la Tesis Doctoral hacen referencia a la presentación global de los principales aspectos en cuestiones de diseño y calibrado que un investigador en una materia aplicada debe tener en cuenta para diseñar un sistema de visión hiperespectral basado en tecnología LCTF a partir de sus componentes fundamentales. La importancia de los aspectos tratados radica en que la mayoría de subsistemas comerciales hacen hincapié en su funcionamiento particular, sin hacer referencia a aspectos referentes a la integración del sistema completo que, a la sazón, debe proporcionar imágenes comparables y uniformemente iluminadas de frutas esféricas y con una superficie muy reflexiva.

- En este capítulo se han discutido las principales cuestiones de diseño de un sistema de visión hiperespectral basado en LCTF para la inspección de frutos cítricos. Un sistema de visión hiperespectral consta de varias partes con diferentes funcionalidades, se ha presentado cada una de las partes de un sistema de visión hiperespectral para la inspección de cítricos y se ha realizado un estudio de las principales características de cada una de las partes del sistema.
- La problemática que aparece para obtener imágenes de exactamente la misma escena empleando los dos LCTF que es necesario intercambiar para alcanzar el rango espectral deseado, ha hecho necesario diseñar elementos auxiliares (sistema de posicionamiento y guiado de los filtros) para permitir adquirir las imágenes hiperespectrales de manera sistemática y así posibilitar la realización de ensayos con un número elevado de muestras.
- La adquisición de imágenes en un rango espectral amplio hace que surjan problemas, como por ejemplo la pérdida de foco entre longitudes de onda alejadas, que es necesario solucionar estudiando cada una de las partes del sistema y discutiendo la idoneidad de las mismas. Por ello, se han enumerado los factores a tener en cuenta en la elección de elementos del

sistema tales como la óptica más adecuada (que permite obtener imágenes sin variaciones significativas de enfoque), la fuente de alimentación, la cámara o el sistema de iluminación.

- La iluminación es uno de los subsistemas más importante del sistema de adquisición. Por ello, se han diseñado y evaluado dos tipos de sistemas de iluminación diferentes en cuanto a tipo de iluminante y geometría (campana de iluminación cilíndrica y semiesférica) con el fin de disponer de una iluminación eficiente desde el punto de vista espectral, espacialmente uniforme y sin brillos. El sistema de iluminación semiesférico es más eficiente para la inspección de frutos cítricos con daños producidos por podredumbres.
- Las diferentes partes que conforman el sistema de visión hiperespectral presentan propiedades espectrales distintas. En el capítulo 2 se ha mostrado la caracterización espectral realizada para cada uno de los elementos del sistema, permitiendo establecer el rango espectral de trabajo óptimo del sistema propuesto en 460 nm - 1020 nm.
- Las aplicaciones *software* de control de cada elemento del sistema de adquisición (cámara y LCTF) proporcionadas por el fabricante imposibilitan la sincronización de ambos elementos y no permite realizar ensayos de adquisición de un número elevado de muestras. Para solventar este problema se ha desarrollado íntegramente una aplicación *software* informática que ha permitido realizar esta sincronización, así como labores de calibrado y adquisición sistemática de imágenes hiperespectrales.
- Cada una de las partes del sistema de visión hiperespectral introduce una eficiencia espectral distinta que hace que la respuesta global del sistema no sea uniforme. Este hecho ha motivado el desarrollo de una metodología novedosa para uniformizar la respuesta espectral del sistema utilizando tiempos de integración variables, asumiendo una respuesta lineal con el tiempo de integración del CCD.
- Cada una de las partes del sistema de visión, así como la metodología para uniformizar la respuesta espectral, ofrece diferentes posibilidades de configuración. Se han obtenido los parámetros óptimos de funcionamiento del sistema de visión hiperespectral (rango espectral de trabajo, resolución, tiempo de precalentamiento del sistema de iluminación y tiempos de integración por banda) necesarios para adquirir imágenes hiperespectrales de una manera adecuada.
- A partir de las peculiaridades presentes en el sistema hiperespectral se ha propuesto un protocolo de adquisición de las imágenes de los cítricos con el sistema desarrollado que garantiza que las imágenes son comparables.

### 6.2.2. Preprocesado de imágenes hiperespectrales

Las conclusiones obtenidas en este capítulo de la Tesis Doctoral ponen de manifiesto que, para analizar las imágenes hiperespectrales con la garantía de obtener resultados extrapolables a un sistema a medida, es necesario realizar un preprocesamiento previo a su análisis.

- Los cítricos, debido a su forma esférica, presentan un oscurecimiento gradual de los píxeles al alejarse del centro, lo cual dificulta el análisis de la imagen.
- Para solventar los efectos adversos producidos por la curvatura del cítrico se ha propuesto una metodología de preprocesado de imágenes hiperespectrales específica para frutos cítricos, pero que es completamente generalizable y puede ser utilizada en imágenes convencionales de otros frutos esféricos.
- Para utilizar la metodología propuesta es necesario conocer parámetros geométricos del fruto. Con el fin de conocer estos parámetros se ha desarrollado un modelo de elevación digital que considera la superficie del cítrico como un elipsoide tridimensional.
- La metodología desarrollada considera la superficie del cítrico como una superficie Lambertiana elipsoidal y cuantifica la cantidad de radiación que teóricamente debería alcanzar el CCD de la cámara y no lo hace debido a la geometría del fruto. A partir de esta cuantificación y conociendo la radiación que realmente alcanza el CCD, se puede uniformizar y determinar el nivel de reflectancia real del fruto en todas las regiones de su piel.
- Los ensayos desarrollados para validar la metodología propuesta demuestran que la curvatura del cítrico introduce efectos negativos en la adquisición de imagen y que la metodología propuesta minimiza estos efectos, permitiendo un análisis más preciso de la piel.

### 6.2.3. Detección hiperespectral de podredumbres producidas por *Penicillium digitatum*

En este capítulo de la Tesis Doctoral se han planteado una serie de ensayos preliminares para evaluar la capacidad que el sistema hiperespectral desarrollado tiene para detectar las podredumbres y detectar potenciales causas de error y mejora. Aunque el número de defectos, especies de hongo y estados de maduración de la fruta empleados para estos ensayos es relativamente bajo, el trabajo realizado en este capítulo de la Tesis pone de manifiesto que es posible detectar la presencia de podredumbres en cítricos y sienta las bases para desarrollar un sistema capaz de detectar de manera automática estas podredumbres, mejorando significativamente los resultados obtenidos en trabajos previos. En concreto:

- Se ha construido una base de datos de imágenes hiperespectrales de mandarinas de los cultivares cv. clemenules y cv. clemenvilla con daños producidos por *Penicillium digitatum*.
- Se han evaluado cuatro métodos de selección de características (CA, MI, SW y GALDA), con el objetivo de reducir el número de bandas a emplear por un potencial sistema automático y seleccionar las bandas más discriminantes en la clasificación de podredumbres producidas por *Penicillium digitatum*.
- Con el fin de determinar qué tipo de clasificadores (lineales o no lineales) proporcionan los mejores resultados para el problema propuesto, se han evaluado dos métodos de clasificación (LDA y CART) para clasificar los píxeles de las imágenes hiperespectrales. Con el sistema hiperespectral empleado y la metodología propuesta, CART proporciona mejores resultados en la segmentación que LDA.
- El número mínimo de bandas requeridas para optimizar la clasificación de los píxeles es de 20 bandas y se ha conseguido con el método de selección GALDA, utilizando como clasificador el método CART.
- Utilizando las imágenes segmentadas mediante CART y definiendo un criterio de decisión para clasificar la fruta en dos clases (podrida/sana), se ha implementado un método que discrimina fruta infectada con *Penicillium digitatum* de fruta sana.
- Los resultados obtenidos muestran que es posible detectar fruta podrida por este hongo utilizando el sistema de visión por computador hiperespectral desarrollado, sin utilizar luz ultravioleta. La tasa de acierto alcanzada en la clasificación de fruta en ambos cultivares está en torno al 90 %.

#### 6.2.4. Segmentación de podredumbres producidas por *P. digitatum* y *P. italicum*

En este capítulo de la Tesis Doctoral se han planteado una serie de mejoras en el sistema de visión hiperespectral, en la capacidad del sistema para distinguir más tipos de defectos y en la metodología de selección de bandas y clasificación empleada. La metodología propuesta es capaz de discriminar entre dos tipos de podredumbres y su rendimiento mejora significativamente los índices obtenidos en el capítulo anterior, así como otros publicados en trabajos previos, utilizando un menor número de bandas.

- En base a la experiencia adquirida en los ensayos del capítulo anterior, se ha mejorado el sistema de visión hiperespectral, en concreto el sistema de iluminación. La configuración ba-



sada en una campana semiesférica proporciona una iluminación más uniforme, e igualmente eficiente desde el punto de vista espectral, que el sistema de iluminación cilíndrico.

- Debido a que existe una gran variedad de podredumbres esta Tesis Doctoral se ha planteado el problema de la detección y clasificación de dos tipos de podredumbres. Para ello se han escogido las dos más importantes en poscosecha desde el punto de vista económico y que son las causadas por los hongos *Penicillium digitatum* y *Penicillium italicum*. Adicionalmente se han incorporado otros defectos a la base de datos con el objetivo de comprobar si el sistema desarrollado es capaz de detectar tanto podredumbres como otros defectos menos importantes.
- Se han reducido el número de bandas necesarias para detectar los daños de la piel de las frutas y se ha extraído información sobre qué bandas son más importantes en el problema de clasificación. Para ello se han implementado 8 métodos de selección de características de tipo *filter*: TT, DKL, CA, CB, LW, ROC, MRMR y CE. A partir de las selecciones obtenidas con cada uno de los siete primeros métodos se ha implementado el último a modo de comité de expertos (CE). Todos los métodos de selección de características son binarios y se ha empleado una estrategia *one vs. all* para obtener una selección única para cada método basada en *rankings*.
- El número óptimo de bandas, utilizando la metodología propuesta, es de 10 y los métodos de selección que han producido un rendimiento más elevado han sido MRMR y CE.
- Las 10 bandas proporcionadas por los métodos de selección anteriormente citados se han utilizado como entrada de los clasificadores CART y ANN. Para cada banda, los valores empleados como entrada son: el valor de reflectancia de cada píxel, el valor medio de la vecindad de tamaño tres o de tamaño cinco, y la desviación típica de dicha vecindad.
- Se han implementado diferentes estrategias de segmentación con cada una de las variantes propuestas (método de selección, clasificador y vecindad). Tras analizar el rendimiento de todas las estrategias se ha comprobado que la vecindad que produce mejores resultados en todos los casos ha sido la de tamaño cinco.
- Asimismo, el método basado en ANN ha producido mejores resultados en la segmentación que CART y, dentro de las estrategias basadas en redes neuronales, las de una sola capa oculta se han mostrado más eficientes, mostrando una capacidad de generalización más elevada que las de dos capas.
- La mejor estrategia de segmentación, ANN1-5x5CE, presenta excelentes índices de rendimiento en test ( $OA = 98,3\%$  y  $\kappa = 0,979$ ) y es capaz de diferenciar los píxeles de zonas sanas de los de zonas podridas, así como distinguir los píxeles de cada tipo de podredumbre.

- A partir del porcentaje del área de cada uno de los daños respecto al total de la piel de la fruta en la imagen segmentada, se ha construido un árbol de decisión que determina el tipo de defecto que presenta cada una de las frutas de la base de datos construida en este capítulo.
- Se ha demostrado que empleando la metodología desarrollada se puede discriminar y clasificar la fruta afectada por los dos tipos de podredumbres causadas por los hongos *P. digitatum* y *P. italicum*. Los índices de rendimiento para el clasificador de fruta basado en CART ( $OA = 93,06\%$  y  $\kappa = 0,910$ ) indican que el modelo es preciso y confiable desde el punto de vista estadístico. Además se ha demostrado que la metodología es capaz de diferenciar y clasificar correctamente fruta con daños producidos por podredumbres habituales y fruta afectada por otros daños comunes.

### 6.3. Proyección futura

A la conclusión de esta Tesis Doctoral se han abierto diversas líneas de investigación encaminadas a aplicar los conocimientos extraídos para conseguir una posible implementación de un sistema de clasificación automática de cítricos. Más concretamente, las líneas que se abren son:

- La evaluación de la metodología propuesta con otras especies y cultivares de interés económico, así como aumentar en la base de datos el número de defectos comunes que pueden aparecer en cualquier central citrícola con el fin de evaluar la viabilidad de una implementación en línea.
- Puesto que las redes neuronales se han mostrado eficaces para resolver el problema propuesto, se van a aplicar métodos de regularización y poda en redes neuronales con el fin de obtener un número muy reducido de bandas a adquirir, concretamente 3 bandas. Éste es el número de bandas que utilizan la mayoría de cámaras industriales empleadas para la inspección del producto, lo que permitiría aprovechar toda la tecnología ya existente para implementar sistemas de inspección en línea en tiempo real.
- Trabajar en la implementación física de un sistema de visión por computador a medida centrado en las 3 bandas de adquisición más relevantes y evaluar si se adecua a los requerimientos de calidad, velocidad y robustez de los sistemas de inspección actuales en entornos industriales.
- Comparar el rendimiento de la implementación propuesta con otros sistemas de detección de podredumbres basados en fluorescencia inducida por luz UV.

## 6.4. Logros científicos obtenidos relacionados con la Tesis Doctoral

Durante la etapa investigadora desarrollada en el ámbito de los estudios de doctorado asociados a esta Tesis Doctoral en el Centro de Agroingeniería del IVIA se ha producido una serie de resultados científicos. Estos resultados se han plasmado en una serie de artículos científicos, participaciones en congresos y transferencia de dicho conocimiento a la sociedad en forma de patentes. En las siguientes secciones se enumerarán los resultados científicos relacionados con sistemas de inspección en aplicaciones agrícolas.

### 6.4.1. Publicaciones en revistas internacionales indexadas y capítulos en libro

- Blasco, J., Aleixos, N., **Gómez-Sanchis, J.**, Moltó, E. (2007). Citrus sorting by identification of the most common defects using multispectral computer vision. *Journal of Food Engineering*, 83(3):384-393
- **Gómez-Sanchis, J.**, Blasco, J., Moltó, E., Camps-Valls, G. (2007). Hyperspectral Detection of Citrus Damage with Mahalanobis Kernel Classifier. *IEE Electronics Letters*, 43(20):1082-1084
- **Gómez-Sanchis, J.**, Moltó, E., Camps-Valls, G., Gómez-Chova, L., Aleixos, N., Blasco, J. (2008). Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. *Journal of Food Engineering*, 85(2):191-200
- **Gómez-Sanchis, J.**, Gómez-Chova, L., Aleixos, N., Camps-Valls, G., Montesino-Herrero, C., Moltó, E., Blasco, J. (2008). Hyperspectral system for early detection of rottenness caused by *Penicillium digitatum* in mandarins. *Journal of Food Engineering*, 89(1):80-86
- Blasco, J., Aleixos, N., Cubero, S., **Gómez-Sanchis, J.**, Moltó, E. (2009). Automatic sorting of satsuma (*Citrus unshiu*) segments using computer vision and morphological features. *Computers and Electronics in Agriculture*, 66(1):1-8
- Blasco, J., Aleixos, N., **Gómez-Sanchis, J.**, Moltó, E. (2009). Recognition and classification of external skin damage in citrus fruits using multispectral data and morphological features. *Biosystems Engineering*, 103(2):137-145
- Blasco, J., Aleixos, N., **Gómez-Sanchis, J.**, Moltó, E. (2009). A Survey of Bayesian Techniques in Computer Vision *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods and Techniques*, Ed. IGI Global.

- **Gómez-Sanchis, J.**, Moltó, E., Blasco, J. (Aceptado 2009). Chapter 10 Analysis of Hyperspectral Images of Citrus Fruits *Hyperspectral Imaging for Food Quality Analysis and Control*, Editor: Sun, D.W.
- **Gómez-Sanchis, J.**, Camps-Valls, G., Blasco, J. (Enviado a revista en 2009). Hyperspectral computer vision system based on liquid crystal tunable filters for agricultural inspection applications. *Computers and Electronics in Agriculture*, Enviado pendiente de revisión.
- **Gómez-Sanchis, J.**, Camps-Valls, G., Blasco, J. (Enviado a revista en 2009). Automatic hyperspectral system for classification of *Penicillium digitatum* and *Penicillium italicum* damages in mandarins using artificial neural networks. *Journal of Food Engineering*, Enviado pendiente de revisión.

#### 6.4.2. Transferencia tecnológica y patentes

- Blanc, P., Blasco, J., Moltó, E., **Gómez-Sanchis, J.**, Cubero, S. (2007). System for automatic selective separation of rotten citrus fruit, detects position of defective fruit using encoder associated with conveyor. Núms. Patente: WO2008104627-A1, ES2324324-A1 y ES2325199-A1. Fecha de publicación: 04/09/2008. .

La patente hace referencia a una máquina para la inspección de cítricos que es capaz de detectar podredumbres de forma automática. En la actualidad esta patente se está explotando por la empresa Roda Ibérica, S.A. y se ha extendido a Europa, Estados Unidos, Japón y Suráfrica.

#### 6.4.3. Proyectos de investigación

Los estudios de doctorado en el ámbito de esta Tesis Doctoral han sido subvencionados y se enmarcan en una serie de proyectos de investigación con financiación pública y privada. Algunos de estos proyectos de investigación han sido subvencionados por empresas privadas como RODA IBÉRICA S.A para realizar estudios sobre detección de podredumbres en cítricos. Por el contrario, otros proyectos de investigación se han centrado en aplicaciones de inspección agrícola.

- Técnicas avanzadas de visión por computador mediante imágenes hiperespectrales aplicadas a la inspección y detección de daños en cítricos. MEC (DPI2007-66596-C02-02), FEDER. Duración: 01/10/2007 - 30/09/2009. Investigador principal: Dr. José Blasco Ivars
- Desarrollo de prototipos de tecnología avanzada para la inspección y clasificación automática de fruta procesada mediante visión artificial. INIA (TRT2006-00046-00-00). Duración: 01/01/2007 - 31/12/2008. Investigador principal: Dr. José Blasco Ivars.

- Técnicas avanzadas de visión por computador para el reconocimiento e identificación automática de los defectos externos de los cítricos (RADTAVIC). MCYT (DPI2003-09173-C02-02), FEDER. Duración: 01/12/2003 - 01/12/2006. Investigador principal: Dr. Florentino Juste Pérez.
- Sistema inteligente de selección automática de cítricos en línea mediante el empleo de técnicas avanzadas de visión artificial y computación paralela. Generalitat Valenciana (GV04B/245). Duración: 01/01/2004 - 31/12/2005. Investigador principal: Dr. José Blasco Ivars.
- Desarrollo de una investigación industrial y el diseño de un sistema automático de detección de podredumbres en cítricos. RODA IBERICA. Duración: 21/10/2005 - 31/12/2008. Investigador principal: Dr. José Blasco Ivars.



# Apéndice A

## Acrónimos

**AC** Alternating Current

**ANN** Artificial Neural Networks

**AOTF** Acousto-Optic Tunable Filters

**CA** Correlation Analysis

**CART** Classification and Regression Trees

**CB** Chernoff Bound

**CC** Complexity Cost

**CCD** Charge-Coupled Device

**CE** Comité de Expertos

**DC** Direct Current

**DEM** Digital Elevation Model

**FWHM** Full Width at Half Maximum

**GA** Genetic Algorithm

**GALDA** Genetic Algorithm based on Linear Discriminant Analysis

**ITT** Interline Transfer Technology

**KLD** Kullback-Leibler Divergence

**LCTF** Liquid Crystal Tunable Filters

- LDA** Linear Discriminant Analysis
- LW** Lambda de Wilks
- MI** Mutual Information
- MLP** MultiLayer Perceptron
- MRMR** Mínima Redundancia Máxima Relevancia
- NIR** Near InfraRed
- NIR-07** Near InfraRed LCTF Filter
- OA** Overall Accuracy
- P** clase Pedúnculo
- PC** Personal Computer
- PE** clase Piel Esporulada por penicillium digitatum
- PCA** Principal Component Analysis
- PD** clase daño por Penicillium Digitatum
- PDP** fusión clase Piel con Defecto Podrido
- PI** clase daño por Penicillium Italicum
- PN** clase Piel sana color Naranja
- PP** clase Piel Podrida por penicillium digitatum
- PPD** Porcentaje píxeles Penicillium Digitatum
- PPI** Porcentaje píxeles Penicillium Italicum
- PS** clase Piel Sana
- PSN** Porcentaje píxeles Sana Naranja
- PSP** fusion clase Piel Sana Pedunculo
- PSV** Porcentaje píxeles piel Sana Verde
- PTR** Porcentaje píxeles Trips Rameados
- PV** clase Piel sana color Verde



---

**RAM** Random Access Memory

**RGB** Red Green Blue

**ROC** Receiver Operating Characteristic

**SW** StepWise regression

**TR** clase Trips/Rameados

**TT** T-Test

**UV** UltraViolet

**VIS** Visible

**VIS-07** Visible LCTF Filter

**VLSI** Very Large Scale Integration





## Apéndice B

# Lista de símbolos

### Símbolos introducidos en el capítulo 3

$\lambda$	Longitud de onda	$x$	Posición horizontal del píxel
$\rho_{xy}$	Reflectancia relativa	$y$	Posición vertical del píxel
$R^{abs}$	Radiancia absoluta cítrico	$R^{abs}_{blanca}$	Radiancia absoluta referencia
$R_{blanca}$	Radiancia referencia	$R_{negra}$	Radiancia anulando iluminación
$R$	Radiancia cítrico	$\rho_{ref}$	Reflectancia promedio referencia
$I_T$	Intensidad luminosa	$I$	Intensidad total
$I_D$	Componente directa iluminación	$I_F$	Componente difusa iluminación
$\phi$	Ángulo de incidencia	$\alpha_D$	Proporción luz directa
$\rho$	Reflectancia cítrico	$\epsilon_g$	Factor de corrección geométrico
$P_G$	Centro geométrico del cítrico	$P_i$	Puntos perímetro del cítrico
$N_{P_i}$	Número puntos perímetro	$\eta$	Factor de forma cítrico
$h_c$	Altura del cítrico	$\bar{r}$	Radio promedio
$r_{ij}$	Radio red de interpolación	$h_{ij}$	Altura red interpolación

### Símbolos introducidos en capítulo 4

$x_i$	Vector $i$ de características	$y_i$	Clase del vector $x_i$
$n$	Número de muestras	$r_{x,y}$	correlación lineal
$J(y)$	Función de entropía	$J(y x_j)$	Función de entropía condicional
$MI(y, x_j)$	Información mutua	$P(c x_j)$	Probabilidad condicionada
$P(c)$	Probabilidad de clase $c$	$P(x_j)$	Probabilidad patron $x_j$
$N_f$	Dimensión espacio original	$N_T$	Dimensión espacio LDA
$G$	Transformación LDA	$S_t$	Covarianza total

---

$S_i$	Covarianza interclase	$S_e$	Covarianza entre clases
$N_C$	Número de clases	$\eta_i$	Autovectores LDA
$\lambda_i$	Autovalores LDA	$\mathbb{R}$	Números reales
$\rho(\lambda)$	Reflectancia banda $\lambda$	$\rho(\lambda)_{umbral}$	Reflectancia umbral
$p(k t)$	Probabilidad clase $k$ a nodo $t$	$i(t)$	Impureza del nodo $t$
$\psi$	Función de probabilidad	$\Delta i(d, t)$	Variación de impureza
$p_i$	Proporción a nodo izquierdo	$p_d$	Proporción a nodo derecho
$\epsilon_c$	Error de la clasificación	$\beta$	Parámetro regularización
$N_n$	Número de nodos terminales	$\kappa$	Kapa de Cohen

### Símbolos introducidos en capítulo 5

$\psi$	Función de activación	$U_n$	Función de transformación
$x_k$	Entrada $k$ a la red neuronal	$\omega_{nk}$	Peso neurona $n$ entrada $k$
$N_{sat}$	Número variables de saturación	$\lambda$	Reflectancia píxel
$\bar{\lambda}$	Reflectancia promedio vecindad	$\sigma$	Desviación típica vecindad
$\omega(t)$	Matriz de pesos preactalización	$\omega(t + a)$	Matriz de pesos postactalización
$\alpha$	Constante de adaptación	$J$	Función de coste
$e$	Error total	$e_j$	Error de neurona salida $j$
$N_s$	Neuronas de salida	$M$	Número de muestras entrenamiento
$y_k$	Salida neurona salida $k$	$d_k$	Deseada neurona salida $k$
$\kappa$	Kapa de Cohen	$OA$	Acierto promedio



# Bibliografía

- Abe, N., Kudo, M., Toyama, J., and Shimbo, M. (2000). A divergence criterion for classifier-independent feature selection. *Lecture Notes in Computer Science. Advances in Pattern Recognition*, 1876:668–676.
- Aleixos, N., Blasco, J., Navarrón, F., and Moltó (2002). Multispectral inspection of citrus in real-time using machine vision and digital signal processors. *Computers and Electronics in Agriculture*, 33(2):121–137.
- Aranda, J. and Tomás, L. (1997). Automatic process for the stoning peach inspection and classification phase in a packaging fruits factory using artificial vision techniques. In *Robotics and automated machinery for bio-productions, BIO-ROBOTICS 97*, pages 77–82, Gandía (Valencia).
- Ariana, D., Lu, R., and Guyer, D. (2006). Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers. *Computer and Electronics in Agriculture*, 53(1):60–70.
- Arivazhagan, S., Ganesan, L., and Priyal, S. (2006). Texture classification using Gabor wavelets based rotation invariant features. *Pattern Recognition Letters*, 27(16):1976–1982.
- Bajcsy, P. and Kooper, R. (2005). Prediction accuracy of color imagery from hyperspectral imagery. Technical report, National Center for supercomputing applications, university of Illinois, Urbana-Champaign, USA.
- Batiti, R. (1994). Using mutual information for selecting features in supervised neural net learning. *IEEE Transactions on Neural networks*, 5:537–550.
- Bei, L., Dennis, G., Miller, H., Spaine, T., and Carnahan, J. (2004). Acousto-optic tunable filters: fundamentals and applications as applied to chemical analysis techniques. *Progress in Quantum Electronics*, 28:67–87.

- Bennedsen, B., Peterson, D., and Tabb, A. (2005). Identifying defects in images of rotating apples. *Computers and Electronics in Agriculture*, 48(2):98–102.
- Bishop, C. (1995). *Neural Networks for Pattern Recognition*. Clarendon Press.
- Blanc, P., Blasco, J., Moltó, E., Gómez-Sanchis, J., and Cubero, S. (2007). Sistema para la selección selectiva automática de cítricos afectados por podredumbre. Ref. P200700514 Oficina Española de Patentes y Marcas. 27/02/2007. Patent Issued.
- Blasco, J. (2001). Concepción de un sistema de visión artificial multispectral para la detección e identificación de daños en cítricos. Master's thesis, Valencia.
- Blasco, J., Aleixos, N., Cubero, S., Gómez-Sanchis, J., and Moltó, E. (2009a). Automatic sorting of satsuma (citrus unshiu) segments using computer vision and morphological features. *Computers and Electronics in Agriculture*, 66(1):1–8.
- Blasco, J., Aleixos, N., Gómez-Sanchis, J., and Moltó, E. (2007a). Citrus sorting by identification of the most common defects using multispectral computer vision. *Journal of Food Engineering*, 83(3):384–393.
- Blasco, J., Aleixos, N., Gómez-Sanchis, J., and Moltó, E. (2009b). Recognition and classification of external skin damage in citrus fruits using multispectral data and morphological features. *Biosystems Engineering*, 103(2):137–145.
- Blasco, J., Aleixos, N., and Moltó, E. (2007b). Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. *Journal of Food Engineering*, 81(3):535–543.
- Blasco, J., Aleixos, N., and Moltó, E. (2003). Machine vision system for automatic quality grading of fruit. *Biosystems Engineering*, 85(4):415–423.
- Blasco, J., Gómez-Sanchis, J., Cubero, S., Alegre, S., Juste, F., and Moltó, E. (2007c). Máquina para la clasificación de gajos de mandarina para conserva. Ref. P200703384 Oficina Española de Patentes y Marcas. 20/12/2007. Patent Issued.
- Blasco, J. and Moltó, E. (2002). Identification of defects in citrus skin using multispectral imaging. In *International Conference on Agricultural Engineering, AgEng 02*, pages 02–AE–031, Budapest.
- Blum, A. and Langley, P. (1998). Selection of relevant features and examples in machine learning. *Artificial Intelligence*, 97:245–271.



- 
- Breiman, L., F. J., Olshen, R., and Stone, J. (1998). *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. CRC Press, USA.
- Breiman, L., Friedman, P., Olshen, R., and Stone, C. (1984). *Classification and Regression Trees*. Wadworth, Belmont-CA.
- Cayuela, J. (2008). VIS/NIR soluble solids prediction in intact oranges (*Citrus sinensis* L.) cv. Valencia Late by reflectance. *Postharvest Biology and Technology*, 47(1):75–80.
- Cercós, M., Soler, G., and Talón, M. (2005). Análisis global de la expresión genética durante el desarrollo y maduración interna de los frutos cítricos. In *Red Valenciana de genómica y pronemómica*, Valencia.
- Chang, C. (2003). *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Springer, USA.
- Chen, Y., Chao, K., and Kim, M. (2002). Machine vision technology for agricultural applications. *Computers and electronics in agriculture*, 36:173–191.
- Cheng, X., Chen, Y., Tao, Y., Wang, C., and Kim, M.S. and Leftcourt, A. (2004). A novel integrated PCA and FLP method on hyperspectral image feature extraction for cucumber chilling damage inspection. *Transactions on ASAE*, 47(4):1313–1320.
- Cho, I., Lee, D., and Jeong, J. (2002). Weed-plant discrimination by machine vision and artificial neural network. *Biosystems Engineering*, 83(3):275–280.
- Clark, M., Roberts, D., and Clark, D. (2005). Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote sensing of environment*, 96(3-4):375–398.
- Conn, A. R., Gould, N., Toint, P., and Qx, O. (1997). A globally convergent lagrangian barrier algorithm for optimization with general inequality constraints and simple bounds. *Math. of Computation*, 66:261–288.
- Curcio, J. and Petty, C. (1951). The near infrared absorption spectrum of liquid water. *J. Opt. Soc. Am.*, 41:302–304.
- Ding, C. and Peng, H. (2003). Minimum redundancy feature selection from microarray gene expression data. In *IEEE Computational Systems Bioinformatics Conference (CSB 2003)*, pages 523–528, Stanford, CA.
- Ding, C. and Peng, H. (2005). Minimum redundancy feature selection from microarray gene expression data. *Journal of Bioinformatics and Computational Biology*, 3(2):185–205.

- Du, C. and Sun, D. (2004). Recent development in the applications of image processing techniques for food quality evaluation. *Trends in Food Science and Technology*, 15:230–249.
- Du, P., Tan, K., Zhang, W., and Yan, Z. (2006). ANN classification of OMIS Hyperspectral Remotely Sensed Imagery: Experiments and Analysis. *Image and Signal Processing*, 4(27-30):692–696.
- Duda, R., Hart, P., and Stork, D. (2001). *Pattern Classification*. John Wiley Sons, INC, second edition edition.
- Eckert, J., Brown, G., Usall, J., and Viñas, I. (1986). Evaluation of postharvest treatments for citrus fruits. *Methods for evaluation pesticides for control of plant pathogens*, pages 92–97.
- Eckert, J. and Eaks, I. (1989). *Postharvest disorders and diseases of citrus. The citrus industry*. University California Press, CA, USA.
- El Ouardighi, A. and El Akadi, A. and Aboutajdine, D. (2007). Feature selection on supervised classification using wilks Lambda statistic. *Computational Intelligence and Intelligent Informatics*, 28(30):51–55.
- Erives, H. and Fitzgerald, G. (2005). Automated registration of hyperspectral images for precision agriculture. *Computer and electronics in agriculture*, 47:103–119.
- Fleiss, J. L. (1981). *Statistical Methods for Rates and Proportions and Machine Learning*. John Wiley & Sons, Inc., 2 edition.
- Foley, J., Van Dam, A., Feiner, S., and Hughes, J. (1996). *Computer Graphics. Principles and Practice*. Addison-Wesley Publishing Company, 2 edition.
- Friedman, J. (1994). An overview of predictive learning and function approximation. In *From Statistics to Neural Networks, Proc. NATO/ASI Workshop*, pages 1–61.
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Classification*. Academic Press, USA, 1st edition.
- Gaffney, J. (1973). Reflectance properties of citrus fruit. *Transactions of the ASAE*, 16(1):310–314.
- García-Reyes, J., Llorent-Martínez, E., Ortega-Barrales, P., and Molina-Díaz, A. (2006). Determination of thiabendazole residues in citrus fruits using a multicommuted fluorescence-based optosensor. *Analytica Chimica Acta*, 557(1-2):95–100.
- Gat, N. (2000). Imaging spectroscopy using tunable filters: A review. Technical report, Opto-Knowledge Systems Inc. OKSI.

- Generalitat Valenciana (2008). Aforos Estadísticos. Consellería Agricultura Ganadería i Pesca.
- Goel, P., Prasher, S., Patel, R., Landry, J., Bonnell, R., and Viau, A. (2003). Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computer and electronics in agriculture*, 39:67–93.
- Goetz, A., Vane, G., Solomon, J., and Rock, B. (1985). Imaging spectrometry for Earth remote sensing. *Science*, 228:1147–1153.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley.
- Gómez-Chova, L., Calpe, J., Soria, E., Camps-Valls, G., Martín, J., and Moreno, J. (2003). CART-based feature selection of hyperspectral images for crop cover classification. In *IEEE International Conference on Image Processing (ICIP2003)*, volume 2, pages III–589–92, Spain.
- Gómez-Sanchis, J., Blasco, J., Moltó, J., and Camps-Valls, G. (2007). Hyperspectral Detection of Citrus Damage with Mahalanobis Kernel Classifier. *IEE Electronics Letters*, 43(20):1082–1084.
- Gómez-Sanchis, J., Camps-Valls, G., Moltó, E., Gómez-Chova, L., Aleixos, N., and Blasco, J. (2008a). Segmentation of hyperspectral images for the detection of rotten mandarins. *Lecture Notes in Computer Science. Image Analysis and Recognition*, 5112:1071–1080.
- Gómez-Sanchis, J., Gómez-Chova, L., Aleixos, N., Camps-Valls, G., Montesino-Herrero, C., Moltó, E., and Blasco, J. (2008b). Hyperspectral system for early detection of rottenness caused by penicillium digitatum in mandarins. *Journal of Food Engineering*, 89(1):80–86.
- Gómez-Sanchis, J., Moltó, E., Gómez-Chova, L., Aleixos, N., Camps-Valls, G., Juste, F., and Blasco, J. (2006). Hyperspectral computer vision system for the detection for the detection of Penicillium digitatum in citrus packing line. In *International Conference on Agricultural Engineering, AgEng06*, Bonn, Germany.
- Gómez-Sanchis, J., Moltó, E. and Camps-Valls, G., Gómez-Chova, L., and Aleixos, N. and Blasco, J. (2008c). Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. *Journal of Food Engineering*, 85(2):191–200.
- Guorong, X., Peiqi, C., and Minhui, W. (1996). Bhattacharyya distance feature selection. *Proceedings of the 13th International Conference on Pattern Recognition*, 2(25-29):195–199.
- Guyon, I. and Elisseev, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3:1157–1182.

- Gómez-Chova, L. (2008). Cloud screening algorithm for MERIS and CHRIS multispectral sensors. Master's thesis, Valencia.
- Gómez-Sanchis, J., Blasco, J., Andreu, G., Aleixos, N., Valiente, J., and E., M. (2005). Identificación de los defectos superficiales de los cítricos mediante un sistema de visión hiperespectral. In *V Congreso Nacional de AgroIngeniería*, León.
- Hair, J., Anderson, R., Tatham, R., and Black, W. (1995). *Multivariate Data Analysis*. Prentice Hall, fourth edition edition.
- Ham, J., Chen, C., Crawford, M., and Ghosh, J. (2005). Investigation of the random forest framework for classification of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3):492–501.
- Hastie, T. and Tibshirani, R. (1996). Discriminant analysis by gaussian mixtures. *Journal of the Royal Statistical Society series B*, 58:158–176.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice-Hall.
- Hetchts, E. (1998). *Optics*. Addison Wesley Longman, 3rd ed. edition.
- Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14(1):55–63.
- Jin, Z., Yang, Y., Hu, Z., and Lou, Z. (2001a). Face recognition based on the uncorrelated discriminant transformation. *Pattern Recognition*, 10(34):1405–1416.
- Jin, Z., Yang, Y., Tang, M., and Hu, Z. (2001b). A theorem on the uncorrelated optimal discriminant vectors. *Pattern Recognition*, 10(34):2041–2047.
- John, G., Kohavi, R., and Pflieger, K. (1994). Irrelevant features and the subset selection problem. In *Proceedings of the 11th International Conference on Machine Learning*, pages 121–129. Morgan Kaufmann.
- Jolliffe, I. T. (1986). *Principal Component Analysis*. J. Wiley & Sons.
- Kim, M., Chen, Y., and Mhel, P. (2001). Hyperspectral reflectance and fluorescence imaging system for food quality and safety. *Transactions of the ASAE*, 44(3):721–729.
- Kim, M., Leftcourt, A., Chao, K., and Chen, Y. (2005a). Statistical and neural network classifiers for citrus disease detection using machine vision. *Transactions on ASAE*, 48(5):2007–2014.
- Kim, M., Leftcourt, A., Chen, Y., and Tao, Y. (2005b). Automated detection of fecal contamination of apples based on multispectral fluorescence image fusion. *Journal of food engineering*, 71:85–91.

- Kleynen, O., Leemans, V., and Destain, M. (2005). Development of a multi-spectral vision system for the detection of defects on apples. *Journal of Food Engineering*, 69(1):41–49.
- Kohavi, R. and John, G. (1997). Wrappers for features subset selection. *International Journal on Digital Libraries*, 1:108–121.
- Kolmogorov, A. (1957). On the representation of continuous functions of several variables by superposition of continuous functions of one variable and addition. *Dokl. Akad. Nauk.*, 114:953–956.
- Kondo, N., Ahmad, U., Monta, M., and Murase, H. (2000). Machine vision based quality evaluation of Iyokan orange fruit using neural networks. *Computer and Electronics in Agriculture*, 29(1-2):135–147.
- Kullback, S. (1987). The Kullback-Leibler distance. *The American Statistician*, 41:340–341.
- Latza, H. and Ernes, D. (1978). Selective fluorescence detection of citrus oil components separated by high-performance liquid chromatography. *Journal of Chromatography A*, 166(1):189–199.
- Lawrence, R. and Labus, M. (2003). Early detection of DOUGLAS-FIR beetle infestation with subcanopy resolution hyperspectral imagery. *Western Journal of Applied Forestry*, 18(3):202–206.
- Lee, K., Kang, S., Kim, M., and Noh, S. (2005). Hyperspectral Imaging for Detecting Defect on Apples. Technical Report 053075, ASABE.
- Leemans, V., Magein, H., and Destain, M. (2002). On-line fruit grading according to their external quality using machine vision. *Biosystems Engineering*, 83(4):397.
- Li, S., Liao, C., and Kwok, J. (2006). Gene feature extraction using T-test statistics and Kernel Partial Least Squares. *Lecture Notes in Computer Science. Neural Information and Processing*, 4234:11–1.
- Lillesand, T. M., Kiefer, R. W., and Chipman, J. W. (2004). *Remote sensing and image interpretation*. John Wiley, New York, 5th edition.
- Liu, H. and Motoda, H. (1998a). *Feature Extraction Construction and Selection: A Data Mining Perspective*. Kluwer Academic Publishers, Norwell:MA.
- Liu, H. and Motoda, H. (1998b). *Feature selection for knowledge discovery and data mining*. Kluwer Academic Publishers, Boston,USA.

- Ma, J., Zheng, Z., Tong, Q., and Zheng, L. (November, 2003). An application of genetic algorithms on band selection for hyperspectral image classification. In *Proceedings of the Second International Conference on Machine Learning and Cybernetics*, Xi'an.
- Mamitsuka, H. (2006). Selecting features in microarray classification using ROC curves. *Pattern Recognition*, 39(12):2393–2404.
- Martínez-Sotoca, J. and Plá, F. (2006). Hyperspectral data selection from mutual information between image bands. *Lecture Notes in Computer Science*, (4109):853–861.
- Matcher, S., Cope, M., and Delpy, D. (1994). Use of the water absorption spectrum to quantify tissue chromophore concentration changes in near-infrared spectroscopy. *Physics in Medicine and Biology.*, 39:177–196.
- Mhel, P., Chen, Y., Kim, M., and Chan, D. (2004). Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations. *Journal of food engineering*, 61:67–81.
- Miller, W. and Drouillard, G. (2001). Multiple feature analysis for machine vision grading of Florida citrus. *Applied Engineering in Agriculture*, 17(5):627–633.
- Mirick, M., Michels, J., Kassymzhanova-Mirick, S., Elliott, N., Catana, V., Jones, D., and Bowling, R. (2006). Using digital image analysis and spectral reflectance data to quantify damage by greenbug (Hemitera:Aphididae) in winter wheat. *Computer and electronics in agriculture*, 51:86–98.
- Muhammed, H. (2005). Hyperspectral crop reflectance data for characterising and estimating fungal disease severity in wheat. *Biosystem Engineering*, 91(1):9–20.
- Mäenpää, T., Turtinen, M., and Pietikäinen, M. (2003). Real-time surface inspection by texture. *Real-Time Imaging*, 9(5):289–296.
- Nakariyakula, S. and Casasent, P. (2009). Fast feature selection algorithm for poultry skin tumor detection in hyperspectral data. *Journal of Food Engineering*, 94(3-4):358–365.
- Okamoto, H. and Lee, W. (2009). Green citrus detection using hyperspectral imaging. *Computers and Electronics in Agriculture*, 66(2):201–208.
- Ortuño, A., Báidez, A., Gómez, P., Arcas, M., Porras, I., García-Lidón, P., and Del Río, J. (2006). Citrus paradisi and citrus sinensis flavonoids: Their influence in the defence mechanism against penicillium digitatum. *Journal of the Royal Statistical Society series B*, 98(2):351–358.

- Ouardighi, A., Akadi, A., and Aboutajdine, D. (2007). Feature selection on supervised classification using Wilks lambda statistic. In *International Symposium on Computational Intelligence and Intelligent Informatics ISCIII07*, volume 1, pages 51–55.
- Palou, L., Smilanick, J., Usall, J., and Viñas, I. (2001). Control postharvest blue and green molds of oranges by hot water, sodium carbonate, and sodium bicarbonate. *Plant disease*, (85):371–376.
- Papadakis, S., Abdul-Malek, S., Kandem, R., and Yam, K. (2000). A versatile and inexpensive technique for measuring colour of foods. *Food Technology*, 54(12):48–51.
- Park, B., Lawrence, K., Windhand, W., and Buhr, R. (2002). Hyperspectral imaging for detecting fecal and ingesta contaminants on poultry carcasses. *Transactions of the ASAE*, 45(6):2017–2026.
- Peng, H., Long, F., and Ding, C. (2005). Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(8):1226–1238.
- Poger, S. and Angelopoulou, E. (2001). Multispectral sensors in computer vision. Technical report, Stevens Institute of Technology, Hoboken, USA.
- Polder, G., Heijden, G., and Young, I. (2000). Hyperspectral image analysis for measuring ripeness of tomatoes. In *ASAE International Meeting*, Wisconsin, USA.
- Polder, G., van der Hijden, G., Keizer, L., and Young, I. (2003). Calibration and characterisation of imaging spectrographs. *Near Infrared Spectroscopy*, 11:193–210.
- Polder, G., van der Hijden, G., Keizer, L., and Young, I. (2004). Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers. *Near Infrared Spectroscopy*, 11:193–210.
- Ponsa, D. and López, A. (2007). Feature selection based on a new formulation of the minimal-redundancy-maximal-relevance criterion. *Lecture Notes in Computer Science. Pattern Recognition and Image Analysis*, 4477:47–54.
- Proakis, J. G. (1997). *Tratamiento digital de señales: principios, algoritmos y aplicaciones*. Prentice-Hall.
- Pydipati, R. and Burks, T. and Lee, W. (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture*, 52(1-2):49–59.



- Qin, J., Burksa, T., Ritenour, M., and Bonn, W. (2009). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of Food Engineering*, 93(2):183–191.
- Rohrmus, D. (2005). Invariant and adaptive geometrical texture features for defect detection and classification. *Pattern Recognition*, 38(10):1546–1559.
- Shaw, G. and Burke, H. (2003). Spectral imaging for remote sensing. *Lincoln Laboratory Journal*, 14(1):3–28.
- Silva, M. and Almeida, L. (1990). Acceleration techniques for the backpropagation algorithm. *Lecture Notes in Computer Science. Neural Networks*, 412:110–119.
- Sim, J. and Wright, C. C. (2005). The Kappa Statistic in Reliability Studies: Use, Interpretation, and Sample Size Requirements. *Physical Therapy*, 85:257–268.
- Sims, D. and Gamon, J. (2003). Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water and chlorophyll absorption features. *Remote sensing of environment*, 84(4):526–537.
- Soria, E., Martín, J., and Lisboa, P. (2006). Classical training methods. *Metaheuristic Procedures for Training Neural Networks*, 36:7–36.
- Steingberg, P. and Colla, P. (1997). *CART. Classification and Regression Trees*. Salford Systems, San Diego.
- Sun, D. (2009). *Infrared Spectroscopy for Food Quality Analysis and Control*. Elsevier.
- Swain, P. (1978). *Remote Sensing: The Quantitative Approach*, chapter Fundamentals of pattern recognition in remote sensing, pages 136–188. McGraw-Hill, New York.
- Tao, Y. and Wen, Z. (1999). An adaptive spherical image transform for high speed fruit defect detection. *Transactions of the ASAE*, 42(1):241–246.
- Tatzer, P., Wolf, M., and Panner, T. (2005). Industrial application for inline material sorting using hyperspectral imaging in the NIR range. *Real Time Imaging*, 11:99–107.
- Theodoridis, S. and Koutroumbas, K. (1999). *Pattern Recognition*. Academic Press.
- Trias-Sanz, R., Stamon, G., and Louchet, J. (2008). Using colour, texture, and hierarchical segmentation for high-resolution remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(2):156–168.



- Tumbo, S., Wagner, D., and Heinemann, P. (2002). Hyperspectral based neural network for predicting chlorophyll status in corn. *Transactions of the ASAE*, 45(3):825–832.
- Unay, D. and Gosselin, B. (2007). Stem and calyx recognition Jonagold apples by pattern recognition. *Journal of Food Engineering*, 78:597–605.
- Ververis, C. and Georghiou, K., Danielidis, D., Hatzinikolaou, G., Santas, P., Santas, R., and Corleti, V. (2007). Cellulose, hemicelluloses, lignin and ash content of some organic materials and their suitability for use as paper pulp supplements. *Bioresource technology*, 98(2):296–301.
- Waheeda, T., Bonnell, R., Prashera, S., and Pauleta, E. (2006). Measuring performance in precision agriculture: CART, A decision tree approach. *Agricultural Water Management*, 84(1-2):173–185.
- Wallays, C., Missotten, B., DeBaerdemaeker, J., and Saeys, W. (2009). Hyperspectral waveband selection for on-line measurement of grain cleanness. *Biosystems Engineering*, 104(1):1–7.
- Wills, R., Maglasson, W., Graham, D., and Joice, D. (1998). *Postharvest. Introduction to the physiology and handling of fruits, vegetables and ornamentals*. CAB International, 4th edition.
- Xing, J., Bravo, C., Jancsó, P., Ramon, H., and Baerdemacker, J. (2005). Detecting bruises on 'golden delicious' apples using hyperspectral imaging with multiple wavebands. *Biosystems Engineering*, 90(1):27.
- Yang, C., Everitt, J., and Bradford, J. (2004). Airborne hyperspectral imagery and yield monitor data for estimating grain sorghum yield variability. *Transactions of the ASAE*, 47(3):915–924.
- Yang, C., Prasher, S., Whalen, J., and Goel, P. (2002). Use of hyperspectral imagery for identification of different fertilisation methods with decision-tree technology. *Biosystems Engineering*, 83(3):291–298.
- Yao, P. and Tian, M. (2003). A genetic-algorithm-based selective principal component analysis (GA-SPCA) method for high-dimensional data feature extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 41(6):1469–1478.
- Ye, J. (2005). Characterization of a family of algorithms for generalized discriminant analysis on undersampled problems. *Journal of Machine Learning Research*, (6):483–502.
- Ye, X., Sakai, K., Ortega-Garciano, L., Asada, S., and Sasao, A. (2006). Estimation of citrus yield from airborne hyperspectral images using a neural network model. *Ecological Modelling*, 198(3-4):426–432.

- Yohannes, Y. and Webb, P. (1999). Classification and regression trees, CART. A user manual for identifying indicators of vulnerability to famine and chronic food insecurity. Technical report, International Food Policy Research Institute.
- Zhai, Y., Thomasson, J., Bogges, J., and Sui, R. (2006). Soil texture classification with artificial neural networks operating on remote sensing data. *Computers and Electronics in Agriculture*, 54(2):53–68.
- Zheng, C., Sun, D., and Zheng, L. (2006). Recent development and applications of image features for food quality evaluation and inspection. A review. *Trends in Food Science and Technology*, 17:642–655.

Detección automática de podredumbres en cítricos mediante procesado avanzado de  
imágenes hiperespectrales

Juan Gómez Sanchis, 2009

