



**Universidad de Granada**

**Facultad de Ciencias**

**Departamento de Óptica**

**Color Imaging Laboratory**

**Tesis Doctoral**

**DISEÑO DE UN SISTEMA  
MULTIESPECTRAL PARA ADQUISICIÓN  
DE IMÁGENES DE LUZ-CIELO**

**Miguel Ángel López Álvarez**

**Noviembre 2007**





# DISEÑO DE UN SISTEMA MULTIESPECTRAL PARA ADQUISICIÓN DE IMÁGENES DE LUZ-CIELO

*por*

**Miguel Ángel López Álvarez**



**Universidad de Granada**

Granada, a 7 de Noviembre de 2007

**Directores**

Dr. D. Javier Hernández Andrés

Prof. Titular de Universidad

Dr. D. Javier Romero Mora

Catedrático de Óptica

**Departamento de Óptica, Universidad de Granada. Noviembre 2007.**

*Memoria presentada para optar al grado de*  
**DOCTOR POR LA UNIVERSIDAD DE GRANADA**

Fdo: Miguel Ángel López Álvarez.



**La parte más dura en la redacción de toda tesis doctoral es sin duda la de escribir los agradecimientos. Reducir a pocas líneas una expresión de afecto hacia todos aquellos que han colaborado en la elaboración de este trabajo es tarea ardua pero -sin embargo- satisfactoria.**

**Mi mayor reconocimiento va hacia mis directores, los profesores Hernández Andrés y Romero Mora, por iniciarme en el bello campo de la investigación óptica, por guiarme de manera sabia en la elaboración de este trabajo a la vez que por darme libertad de pensamiento y acción en todo momento. Pero sobre todo, por su incondicional confianza y apoyo moral durante estos cuatro años, tras los cuales me llevo una gran amistad más que unos estupendos jefes. Gracias, Javi, por lograr que el papel de ‘boss’ no estuviese reñido con el de amigo.**

**Debo hacer extensivo este afectuoso reconocimiento a otros miembros y compañeros del Departamento de Óptica de la Universidad de Granada, por la colaboración y sabios consejos que de ellos he recibido desde antes incluso de empezar la elaboración de esta tesis: profesores Melgosa, García Beltrán, Yebra, Díaz Navas, Pérez Gómez, Pozo, García García, Rubiño, Jiménez del Barco e Hita Villaverde. Y con especial cariño debo citar, por supuesto, a Juan Luis Nieves y a Eva Valero por su enorme esfuerzo y apoyo para con este trabajo.**

**Mención propia merecen otros profesores, becarios y exbecarios con los que he compartido grandes viajes, maravillosos momentos y memorables conversaciones trascendentales sobre lo humano y lo divino: prof. R. Huertas, Clara, Dani, Rafiki, mi estimado compañero Francisquito (doctor González Galindo), Ani (la doctora López Montes) y Luis. También recordaré con cariño a José Juan, Olga, Laura, Aixa, Juancho, y -muy especialmente- Carolina. A todos ellos debo agradecer su tiempo, compañía y ayuda a la hora de sobrellevar el día a día del investigador.**

**Los doctores D. Jaime Pujol y D. Joaquín Campos merecen mi más sincero agradecimiento por haberme aceptado en sendas estancias de investigación (financiadas por las redes temáticas de color a las que D. Joaquín ha dedicado tanto empeño) que, sin duda, han enriquecido enormemente la parte experimental de esta tesis doctoral. En este punto también debo reconocer la ayuda que he recibido de las doctoras Dña. Alicia Pons -por sus enseñanzas en los laboratorios del CSIC en Madrid-, y Meritxell Vilaseca (permíteme un trato más familiar) -por la gran**

**cantidad de bibliografía y consejos compartidos a lo largo de estos años, también por su ayuda durante mi estancia en el CD6 en Tarrasa-**

**De esta última estancia guardo un recuerdo especialmente entrañable, por razones obvias. No hay palabras para mostrarte mi agradecimiento y cariño, Marta. Tu ayuda, apoyo, afecto y compañía en estos últimos meses están en mi corazón, que es tuyo, y es algo que valoraré el resto de esta nueva vida que hoy empiezo y que espero poder compartir contigo.**

**Gran parte de las medidas presentadas en esta tesis se llevaron a cabo en el CEAMA, en colaboración con los profesores L. Alados y F. J. Olmo, a los que también estoy agradecido. El personal del grupo de investigación que ellos dirigen me acogió y me ayudó en todo momento, en especial Alberto Cazorla, por lo que dicho reconocimiento también es para ellos.**

**A D. José Luis Menjibar siempre le estaré agradecido por las no pocas ocasiones en que tuvo que solucionar mis problemas informáticos, y por ayudarme a desarrollar el software de control del sistema multiespectral y el hardware para la cámara monocromática. Alguna botella de vino te sigo debiendo...**

**Debo también lanzar un agradecimiento a algunos profesores que sin duda han contribuido a mi formación científica: D. Pedro Garrido -que me inició en el manejo de la Física Computacional y los algoritmos de simulated annealing-, D. Juan Antonio López Villanueva -que me facilitó numerosa bibliografía y explicaciones magistrales sobre CCDs-, D. Andrés Godoy -por su ayuda en todos los aspectos durante este último año-, D. Ángel Delgado -por ser un modelo como persona, docente y científico- y D. Juan José Rodríguez Molina -que ha sabido como nadie enseñar Física preuniversitaria de forma rigurosa a la vez que amena-**

**Los amigos más cercanos (aunque pocos, saben que no necesito nombrarlos) son los que, sin duda, han soportado de manera estoica los peores momentos del desarrollo de este trabajo, y han sabido sacarme de los baches más profundos, sobre todo al final, y para ellos va desde estas líneas un cariñoso abrazo.**

**Finalmente, las líneas más emotivas son para mis padres y mis hermanos. Ellos me inculcaron el amor a la ciencia y la investigación, y me han dado su tiempo, comprensión, afecto, compañía y apoyo incondicional durante estos 28 años.**

Este trabajo ha podido ser llevado a buen término gracias a los fondos del III Plan Andaluz de Investigación de la Consejería de Innovación, Ciencia y Empresa de la Junta de Andalucía, así como al proyecto de investigación DPI 2004-03734 de la Comisión Interministerial de Ciencia y Tecnología.



**A mis padres y a mi abuelo Miguel...**

*“Todos los ríos van al mar  
y el mar no se llena...”  
Eclesiastés.*



## ÍNDICE:

<b>GLOSARIO.</b>	<b>1</b>
<b>1.- INTRODUCCIÓN Y OBJETIVOS.</b>	<b>5</b>
<b>2.- TEORÍA DE SISTEMAS MULTIESPECTRALES.</b>	<b>11</b>
2.1.- Definición de sistema multiespectral.	11
2.1.1.-Sistema multiespectral basado en una cámara RGB.	13
2.1.2.-Sistema multiespectral basado en una cámara monocromática y filtros de banda estrecha.	14
2.1.3.-Sistema multiespectral diseñado de forma óptima.	15
2.2.- Dispositivos electrónicos fotosensibles.	15
2.2.1.- Charge Couple Device CCD.	17
2.2.2.- Complementary Metal Oxide Semiconductor CMOS.	20
2.2.3.- Ruido en dispositivos semiconductores para captura de imágenes.	22
2.2.3.a.- <i>Relación señal-ruido (SNR).</i>	23
2.2.3.b.- <i>Valor cuadrático medio y valor eficaz (rms).</i>	24
<i>Adición de ruidos.</i>	
2.2.3.c.- <i>Densidad de potencia espectral del ruido.</i>	26
2.2.3.d.- <i>Fuentes de ruido en CCDs y CMOS.</i>	28
2.3.- Algoritmos de estimación espectral.	31
2.3.1.- Algoritmo de Maloney-Wandell.	35
2.3.2.- Algoritmo de Imai-Berns.	36
2.3.3.- Algoritmo de Shi-Healey.	38
2.3.4.- Algoritmo de Wiener.	41
2.3.5.- Algoritmo de regresión lineal.	42
2.3.6.- Algoritmos de regresión no-lineal.	43

<b>3.- BÚSQUEDA DE SENSORES ÓPTIMOS PARA MEDIDAS ESPECTRALES DE LUZ-CIELO.</b>	<b>45</b>
3.1.- Introducción al problema.	45
3.1.1.- Interés histórico por la optimización de sensores.	45
3.1.2.- Parámetros de la simulación.	46
3.2.- Búsqueda de los sensores óptimos.	50
3.2.1.-El algoritmo de ‘ <i>simulated annealing</i> ’.	51
3.2.2.-La métrica combinada espectral y colorimétrica (CSCM).	54
3.2.3.-Utilidad del ‘ <i>simulated annealing</i> ’ y la métrica CSCM.	58
3.2.3.a.- ‘ <i>Simulated annealing</i> ’ vs. <i>búsqueda exhaustiva</i> .	59
3.2.3.b.- <i>Comparación entre métricas</i> .	60
3.3.- Resultados de la búsqueda de sensores óptimos.	62
3.3.1.- Forma espectral de los sensores óptimos.	63
3.3.2.- Calidad de las reconstrucciones espectrales.	69
3.3.3.- Vectores base.	72
3.3.4.- Tiempo de cálculo y esquemas de cuantización.	78
<b>4.- APLICACIONES I: ESTIMACIÓN ESPECTRAL DE LUZ-CIELO CON UNA CÁMARA CCD DIGITAL RGB.</b>	<b>85</b>
4.1.- Descripción del sistema.	85
4.2.- Entrenamiento del sistema.	89
4.2.1.- Elección de los espectros de entrenamiento.	90
4.2.2.- Influencia del tamaño del conjunto de entrenamiento.	94
4.3.- Resultados de las estimaciones espectrales.	95
4.4.- Utilización de las curvas espectrales de luz-cielo.	97
4.4.1.- Estimación del exponente de Angström y del AOD para aerosoles.	99

<b>5.- APLICACIONES II: MEDIDAS ESPECTRALES DE LUZ-CIELO CON UNA CÁMARA MONOCROMÁTICA Y FILTRO LCTF.</b>	<b>105</b>
5.1.- Descripción del sistema.	105
5.2.- Calibración espectral del filtro LCTF.	108
5.3.- Calibración de la cámara.	110
5.3.1.- Ruido temporal de alta frecuencia.	111
5.3.2.- Variación del ruido de alta frecuencia con el tiempo de exposición.	113
5.3.3.- Ruido temporal de baja frecuencia.	115
5.3.4.- Ley de reciprocidad.	119
5.3.5.- No linealidad y no uniformidad.	121
5.3.6.- Calibración espectral.	126
5.3.6.a.- <i>Esfera integradora y láser sintonizable.</i>	127
5.3.6.b.- <i>Filtro sintonizable y luz-cielo.</i>	129
5.4.- Implementación de un sistema hiperespectral de banda estrecha.	136
5.4.1.- Medidas espectrorradiométricas suponiendo canales monocromáticos.	138
5.4.2.- Modelo de regresión de 33 canales de banda estrecha.	140
5.5.- Implementación de un sistema multiespectral óptimo con pocos sensores.	145
<b>6.- CONCLUSIONES Y TRABAJO FUTURO.</b>	<b>149</b>
<b>REFERENCIAS.</b>	<b>155</b>

<b>APÉNDICES.</b>	<b>165</b>
<b>Apéndice I:</b> Hoja de características del filtro LCTF VariSpec de CRi.	167
<b>Apéndice II:</b> Hoja de características de la cámara Retiga QImaging SRV-1394.	171
<b>Apéndice III:</b> Hoja de características de la cámara Retiga QImaging Q1300C.	173
<b>Apéndice IV:</b> Hoja de características del espectrorradiómetro SpectraScan PR650.	175

**GLOSARIO:**

$E$	Energía de un sistema termodinámico.
$N$	número total de muestras en que se divide el espectro visible, es decir, número de longitudes de onda en que queda definido un espectro. Por tanto, también es el número de componentes de los vectores que representan dichos espectros.
$n$	número de vectores de una base lineal utilizados para representar un espectro.
$m$	número de espectros utilizados para construir el conjunto de entrenamiento.
$k$	número de sensores del sistema multiespectral.
$R(\lambda)$	Sensibilidad espectral de la cámara CCD. En caso de disponer de varios canales, $R$ será una matriz con la sensibilidad de cada canal por columnas.
$p$	número de imágenes promediadas para eliminar el ruido de alta frecuencia.
$C_i$	número de cuentas registradas por la cámara CCD en el píxel $i$ -ésimo.
$M$	número total de píxeles en una cámara CCD.
$\lambda$	longitud de onda
$\rho$	respuestas de los sensores de una cámara digital.
$\sigma$	ruido que afecta a las respuestas de los sensores.
$\varepsilon$	coeficientes de un espectro o vector en una base lineal.
$E(\lambda)$	Radiancia espectral de luz-cielo correspondiente a una curva medida espectrorradiométricamente, que denominaremos <i>original</i> .

## Glosario

$E_R(\lambda)$  Radiancia espectral de luz-cielo correspondiente a una curva reconstruida mediante algún algoritmo de estimación espectral.

$\sigma_{ext\lambda}$  Coeficiente de extinción.

$\tau_\lambda$  Espesor óptico.

$\bar{x}$  Promedio temporal de la magnitud  $x$ .

$\langle x \rangle$  Promedio espacial de la magnitud  $x$ .

## **1.- INTRODUCCIÓN Y OBJETIVOS.**

En la última década hemos podido ser testigos del nacimiento, evolución y consolidación de los sistemas digitales de adquisición o reproducción de imágenes en color. Hoy día, todo el mundo sabe manejar una cámara digital, un escáner o un ordenador con pantalla de 16 millones de colores [Hardeberg 1999], y pocas veces nos planteamos cuestiones acerca del enorme desarrollo tecnológico que ello ha supuesto. La razón principal del éxito de esta floreciente industria reside en el hecho de que proporciona una notable calidad de imagen a un precio razonable. Además, las imágenes digitales pueden ser fácilmente procesadas, almacenadas o enviadas a través de internet a cualquier usuario del mundo de manera instantánea y segura.

Pero estas ventajas no sólo son percibidas y aprovechadas por los consumidores domésticos, sino también por las grandes empresas de industrias tan diversas como la del automóvil, prensa, publicidad, televisión, internet, textil o de impresión en papel. Todas ellas cuentan con un conjunto de herramientas e instrumentos que les permiten fácilmente obtener, procesar y reproducir imágenes en color con multitud de posteriores aplicaciones: producción de pinturas, catálogos, periódicos, revistas, muestras textiles, imágenes publicitarias en la red o en televisión, etc. Algunas, incluso, son especialmente sensibles y exigentes con respecto a la calidad de la adquisición y reproducción del color, como por ejemplo la industria del arte, impresión a color, o la fotografía profesional. Para todas estas ramas, el disponer de un sistema de adquisición de imágenes digitales en color ha traído como ventajas el disfrute de una elevada resolución espacial, alta eficiencia cuántica, amplia respuesta espectral, aceptable relación señal-ruido, linealidad, fidelidad geométrica, rápida respuesta, tamaño reducido y durabilidad [Holst 1996, Holst 2001, Janesick 2001].

Por estas razones que acabamos de argumentar, el empleo de las cámaras digitales también se ha extendido en el campo de la instrumentación científica. Sin embargo, cuando se pretende utilizar una cámara digital como instrumento para medidas radiométricas precisas hay que tener en cuenta que éstas no son detectores perfectos sino que existen diversas fuentes de ruido inherentes a su funcionamiento [Janesick 2001] que alteran los niveles digitales correspondientes a cada píxel, distorsionan de forma desconocida la imagen real adquirida y degradan la precisión radiométrica, la calidad de la imagen y la resolución.

Existe, además, el problema de las sensibilidades espectrales de la mayoría de cámaras de color comerciales (tres canales de adquisición) no verifican la condición de Luther, es decir, no son transformaciones lineales de las funciones de mezcla de la CIE [Wyszecki y Stiles 1982]. Esta propiedad limita seriamente las aplicaciones colorimétricas de los sistemas de imagen basados en cámaras digitales en color ya que da lugar a que la adquisición de la información del color de la escena dependa del iluminante. La única forma de asegurar una igualación del color para todos los observadores y bajo cambios en la iluminación es consiguiendo una igualación espectral. El método más directo para obtener información espectral de las imágenes adquiridas es incrementar el muestreo por encima de los tres canales RGB tradicionales, configuración que recibe el nombre de sistema de imagen multiespectral [Hardeberg 1999], ya que en ellas se registra la información espectral completa en el espectro visible para cada píxel de la imagen. Esto conlleva un gran aumento de la cantidad de información que debe ser almacenada para la correcta reproducción de la imagen digital en color, lo que ha dado lugar al nacimiento de técnicas específicas centradas en la obtención de bases lineales estadísticamente representativas de los espectros registrados que permiten reducir la dimensión de dicha imagen [Marimont y Wandell 1992].

La combinación de sistemas y algoritmos multiespectrales se ha convertido en una poderosa herramienta muy útil si se desean obtener medidas de distribución de potencia espectral (SPD, '*spectral power distribution*') de iluminantes, reflectancia espectral de objetos o señales espectrales de color [Ho *et al.* 1990]. A partir de las respuestas de unos pocos sensores optoelectrónicos, como pueden ser los de una matriz CCD ('*Charge-Coupled Device*') o CMOS ('*Complementary Metal-Oxide-Semiconductor*'), es posible obtener, mediante la aplicación de algún algoritmo de estimación espectral, la SPD en cada píxel de la imagen. Una vez conocidos estos espectros es posible llevar a cabo multitud de tareas basadas en las propiedades espectrales o colorimétricas de la escena, como -por ejemplo- reconocimiento de objetos o patrones [Chandra y Healey 2004], robots de búsqueda en bases de datos de imágenes, reproducción fiel del color en diferentes dispositivos, o simulación de cambios de iluminante en una escena [Hardeberg 1999], entre muchas otras [Haneishi *et al.* 2000, Shimano 2006].

Los sistemas multiespectrales, por ejemplo, han tenido una gran aplicación en el campo de la estimación de las reflectancias de diversas pinturas usadas en obras de arte [Haneishi 2000, Day 2003, Shimano 2005, Shimano 2006, Hardeberg 1999] con el fin de

restaurarlas adecuadamente o conseguir reproducciones digitales fieles. Sin embargo, son escasos los trabajos en que estos sistemas se aplican a la estimación espectral de algún tipo de iluminante, ya sea natural o artificial. En el seno del Departamento de Óptica de la Universidad de Granada se inició esta línea de investigación a finales de los años 1990 con una serie de medidas espectralradiométricas de luz-día y luz-cielo, y su caracterización con bases lineales extraídas del Análisis de Componentes Principales (PCA: ‘*Principal Components Analysis*’) [Romero *et. al.* 1997, Hernández-Andrés 1999], técnica que se propuso para el estudio de curvas de SPD previamente [Maloney y Wandell 1986, Marimont y Wandell 1992]. El estudio, la identificación y reconocimiento de todo tipo de iluminantes a partir de sus características espectrales ha demostrado ser un campo científicamente productivo, en el que nuestro grupo ha conseguido en la última década interesantes resultados [Hernández-Andrés *et.al.* 1998, Hernández-Andrés *et.al.* 2001, Hernández-Andrés *et.al.* 2004, Nieves *et.al.* 2005]

Continuando con esta línea, en este trabajo nos hemos centrado en el estudio de la luz-cielo (lo que en otras partes de la Física se conoce como *componente difusa* de la radiación procedente de la atmósfera), cuyo conocimiento espectralradiométrico permite obtener información sobre parámetros climáticos, tales como el espesor óptico o el exponente de Angström [Goody y Yung 1995], y podría asimismo utilizarse para detección de nubes y segmentación de zonas del cielo en zonas cubiertas o zonas despejadas. Estas curvas de SPD de luz-cielo generalmente se miden con espectralradiómetros, que son aparatos caros, pesados, poco portables y que sólo proporcionan una medida espectral para una región pequeña de la bóveda celeste. Una de las aportaciones más novedosas y de mayor utilidad práctica y experimental de esta tesis doctoral es el diseño y la posterior implementación de un sistema multispectral óptico de alta resolución espacial, ligero y portátil, que permite obtener de manera rápida y fiable una serie de curvas espectrales simultáneas de cualquier región o conjunto de puntos del cielo. El desarrollo de dicho sistema es completo, pues partimos de un modelo teórico que nos sirve para realizar simulaciones computacionales gracias a las cuales optimizamos una serie de parámetros del mismo para finalmente construir el sistema diseñado a partir de una cámara CCD monocromo y un filtro sintonizable de cristal líquido (LCTF, del inglés ‘*Liquid Crystal Tunable Filter*’). La cámara CCD debe ser previamente calibrada para poder ser utilizada correctamente en experiencias radiométricas [Ferrero *et al.* 2006b], y por ello se ha llevado a cabo también un arduo trabajo de calibración

completa de la misma, incluyendo estudio de los diversos tipos de ruido, linealidad frente a la radiancia recibida, no-uniformidad espacial en la respuesta y calibración espectral.

Los objetivos de este trabajo doctoral son, pues, los siguientes:

1.- Realizar una revisión teórica sobre los métodos matemáticos, dispositivos electrónicos fotosensibles, filtros y demás elementos fundamentales relacionados con los sistemas de adquisición de imágenes multispectrales. El estudio del ruido que afecta a estos sistemas será otro de los elementos fundamentales que se tendrán en cuenta. Esta completa revisión teórica debe servir para comprender las bases de los sistemas multispectrales y ayudar a desarrollar el objetivo número 2.

2.- Modelar computacionalmente el comportamiento de un sistema multispectral óptimo para la adquisición de imágenes de luz-cielo. Se tendrán en cuenta todas las variables que pueden influir en los resultados proporcionados por dicho sistema, como son la forma espectral de sus sensores, los distintos tipos de ruido, la base lineal empleada o el algoritmo de estimación espectral escogido para convertir las respuestas de los sensores en curvas espectrales. Posteriormente, en el objetivo 4, se intentarán utilizar los resultados de dichas simulaciones para llevar a la práctica la implementación de dicho sistema.

3.- Utilizar una cámara digital CCD de tres canales RGB acoplada a un objetivo ojo de pez para obtener estimaciones espectrales de luz-cielo en toda la bóveda celeste simultáneamente, que se puedan utilizar para aplicaciones en Meteorología o Climatología, como puede ser la detección de nubes o la estimación de parámetros climáticos como el exponente de Angström o el espesor óptico de aerosoles.

4.- Implementar un sistema multispectral basado en un filtro sintonizable de cristal líquido acoplado a una cámara CCD monocromática. Dicho sistema se utilizará de tres formas diferentes: como instrumento de muestreo radiométrico monocromático del espectro visible, como un sistema multispectral de 33 canales al que se aplicará un método de regresión para obtener los espectros, y como sistema multispectral óptimo

en los casos en los que es posible implementar directamente los sensores óptimos encontrados en el objetivo 2.

En el capítulo 2 de esta tesis doctoral presentamos toda la base de la teoría de los sistemas multiespectrales. Tras definir adecuadamente lo que es un sistema multiespectral, se hace un pequeño repaso de los tipos de fotosensores electrónicos más usados actualmente, que son la base de las cámaras digitales (elemento principal de un sistema multiespectral) Igualmente, se presenta un estudio teórico breve sobre los diferentes tipos de ruido que pueden afectar a los dispositivos electrónicos propios de estos sistemas, que ayudará a entender cómo se ha programado la simulación computacional del sistema multiespectral en un capítulo posterior. Más tarde, en el mismo capítulo 2, presentamos un resumen de los algoritmos o métodos multiespectrales más comúnmente utilizados en la bibliografía, que deberán servir más adelante para transformar las respuestas de los sensores de la cámara en curvas espectrales. Veremos una comparación formal y cuantitativa de los mismos a lo largo de este trabajo.

En el capítulo 3 abordamos la búsqueda de sensores óptimos para la tarea de adquisición de espectros de luz-cielo, utilizando para ello simulaciones computacionales en las que se implementa un modelo teórico de sistema multiespectral. Hemos preferido simular sensores de perfil espectral Gaussiano dentro del espectro visible, por ser este perfil el más parecido matemáticamente a la sensibilidad espectral real en los dispositivos CCD o a las transmitancias espectrales de filtros interferenciales [Hardeberg 1999]. Se ha llevado a cabo una simulación muy realista, incluyendo la influencia de los diversos tipos de ruido electrónico que pueden afectar al comportamiento de una cámara CCD. Para esta búsqueda, se ha implementado un algoritmo de ‘*simulated annealing*’ [Metropolis *et.al.* 1953] que acelera enormemente la minimización de una métrica usada como ‘función de coste’. Se ha propuesto una novedosa métrica combinada espectral y colorimétrica [López-Álvarez 2005] que ha demostrado ser una buena candidata a función de coste en la optimización de sistemas multiespectrales, y que está empezando a ser utilizada por otros autores [Huertas *et.al.* 2007] para la evaluación de las reconstrucciones espectrales de iluminantes naturales y artificiales.

En el capítulo 4 mostramos una aplicación experimental relacionada con el estudio teórico desarrollado en los capítulos precedentes. Se ha demostrado la capacidad de reconstruir de forma absoluta espectros de radiancia de luz-cielo a partir de las respuestas

RGB de una cámara CCD digital de uso científico general. Estas curvas espectrales se utilizan, por ejemplo, para obtener medidas de parámetros climáticos que dan información de la concentración y tamaño de aerosoles en la atmósfera.

En el capítulo 5 se presenta una segunda aplicación derivada directamente de los resultados del capítulo 3. Se ha llevado a cabo la implementación práctica de un sistema multiespectral óptimo utilizando un filtro LCTF y una cámara CCD monocromática, que ha necesitado ser completamente calibrada desde varios puntos de vista: radiométrico, espectral, y de ruido. Dadas las limitaciones experimentales impuestas por la naturaleza del filtro LCTF, sólo es posible llevar a cabo con él la implementación directa de algunos de los sensores óptimos encontrados en el capítulo 3, y serán los que estudiemos. En este mismo capítulo también se utilizan otras dos posibles configuraciones del sistema formado por la cámara monocromática y el LCTF, que resultan igualmente válidas para la adquisición de medidas espectrales de luz-cielo.

Para llevar a cabo el estudio de los capítulos 4 y 5 ha sido necesario realizar sendas campañas de medidas de curvas de radiancia espectral de luz-cielo en Granada durante unos 7 meses, que suponen una de las grandes aportaciones experimentales de esta tesis.

El resto de este trabajo de tesis doctoral trata de explicar las conclusiones más generales del estudio realizado, y aporta algunas ideas para un futuro trabajo (capítulo 6). Las referencias bibliográficas utilizadas y algunos anexos con material explicativo de la instrumentación y los sistemas electrónicos utilizados cierran este encuadrado.

## **2.- TEORÍA DE SISTEMAS MULTIESPECTRALES.**

### **2.1.- Definición de sistema multiespectral.**

Un sistema multiespectral es aquel capaz de proporcionar de forma instantánea información espectral completa en cada píxel de la imagen captada de una escena [Hardeberg 1999]. De esta forma, una imagen multiespectral posee una alta resolución espacial y en cada píxel de la misma se conoce la radiancia espectral del iluminante, la reflectancia espectral del objeto o la señal de color combinada. Conocidas las características espectrales de la escena se tiene información colorimétrica completa de la imagen, pues a partir de dichos espectros se pueden calcular valores triestímulo en cualquier sistema de color, como pueden ser el RGB, CIE-1931 XYZ, CIELAB o CIELUV por citar algunos. También es posible utilizar la información espectral para obtener impresiones o reproducciones de una escena con un colorido fiel al original, incluso evitando el metamerismo debido a los cambios de iluminante.

Hasta la aparición de estos sistemas, las medidas espectrales se hacían con espectrorradiómetros o espectrofotómetros, cuya principal desventaja es su lentitud y el hecho de que sólo proporcionan una única medida espectral a la vez. Por ejemplo, en el caso de una imagen de 640x480 píxeles es imposible, por tanto, obtener los 307200 espectros correspondientes a todos y cada uno de los puntos de la imagen de forma instantánea con los sistemas espectrométricos tradicionales.

El dispositivo principal de un sistema multiespectral es una cámara CCD o CMOS, cuya respuesta debe ser lineal frente a la radiancia recibida y al tiempo de exposición, lo que algunos autores llaman ley de reciprocidad [Ferrero *et al.* 2006]. Para componer la imagen multiespectral, cada píxel de dicha cámara debe registrar en tiempo real la información proveniente de las respuestas de sus sensores a la radiancia de la escena, correspondiendo cada una de ellas a una banda espectral o *canal*. Es común en la bibliografía [Imai *et al.* 2003, Imai y Berns 1999] encontrar la siguiente clasificación “orientativa” de los sistemas digitales de adquisición de imágenes en función del número de canales disponibles (ver tabla 2.1).

Número de canales	Denominación
1	Monocromático
3	RGB o tricromático
de 4 a 9	Multiespectral
De 10 a 100	Hiperespectral
Más de 100	Ultraespectral

Tabla 2.1.- Clasificación de los sistemas de adquisición de imágenes en función del número de canales.

Como vemos en la tabla 2.1, cada píxel de la imagen captada por un sistema multispectral contiene información de una serie pequeña de bandas espectrales o sensores (de 4 a 9) y es capaz de reconstruir, a partir de esta información, la distribución de potencia espectral en dicho píxel. La forma de implementar los sensores o canales espectrales del sistema multispectral dará lugar a una clasificación ulterior que detallaremos más adelante. Usualmente, y siguiendo las recomendaciones de la CIE para muestrear correctamente los espectros de iluminantes naturales [CIE 1994], un espectro en el visible debe medirse desde los 400nm hasta los 700nm con un intervalo no mayor de 10nm. De esta forma un espectro queda representado por 31 valores o muestras, y el sistema multispectral es capaz de obtener el valor de esas muestras a partir de un número sensiblemente menor de canales espectrales (de 4 a 9 según la tabla 2.1). Ello es posible mediante la utilización de algoritmos de estimación espectral, como veremos más adelante en este mismo capítulo.

Según hemos dicho, un sistema multispectral se caracteriza por proporcionar una curva de distribución de potencia espectral en cada píxel de la imagen. Está claro, pues, que debe usarse una cámara digital de alta resolución espacial para obtener la información separada en píxeles. La información espectral de cada píxel la proporciona el hecho de poder trabajar con diferentes bandas espectrales o canales a la vez. Las bandas espectrales o canales en un sistema multispectral pueden ser de dos tipos atendiendo a su perfil espectral: de banda ancha o de banda estrecha. Los primeros usualmente son sistemas basados en la utilización de filtros plásticos de color (de perfil espectral ancho) en combinación con una cámara tricromática. Los segundos suelen utilizar filtros interferenciales, cuya transmitancia espectral es una curva Gaussiana que está bastante localizada en torno a una longitud de onda central, en combinación con cámaras monocromáticas. En la figura 2.1 vemos sendos ejemplos de perfil de sensibilidad espectral de los canales en sistemas multispectrales de banda ancha y de banda estrecha.

El hecho de poder disponer de canales de banda ancha o banda estrecha nos lleva a que podamos distinguir, esencialmente, entre tres métodos de implementación práctica de un sistema multispectral, según utilicemos uno u otro tipo de banda o que podamos tener acceso a mezclar sensores de banda ancha y estrecha indistintamente en un mismo dispositivo. En las siguientes secciones describimos con más detalle las opciones disponibles.

### 2.1.1.- Sistema multispectral basado en una cámara RGB.

El sistema multispectral más sencillo, o de menor coste, es aquel que se basa en la utilización de una cámara RGB (de tres canales por tanto) a la que se van añadiendo sucesivamente diferentes filtros plásticos de banda ancha para tomar sucesivas imágenes. Este tipo de sistema ha sido muy ampliamente utilizado [Nieves *et al.* 2005, Imai y Berns 1999, Day 2003]. Cada imagen tomada con un nuevo filtro añade tres canales espectrales al sistema global. El número y forma de los filtros de banda ancha que se deben utilizar para que la estimación espectral sea óptima depende de la forma espectral de los propios canales RGB de la cámara, del ruido presente en la misma y de la forma de los espectros que se quieran reconstruir [Day 2003].

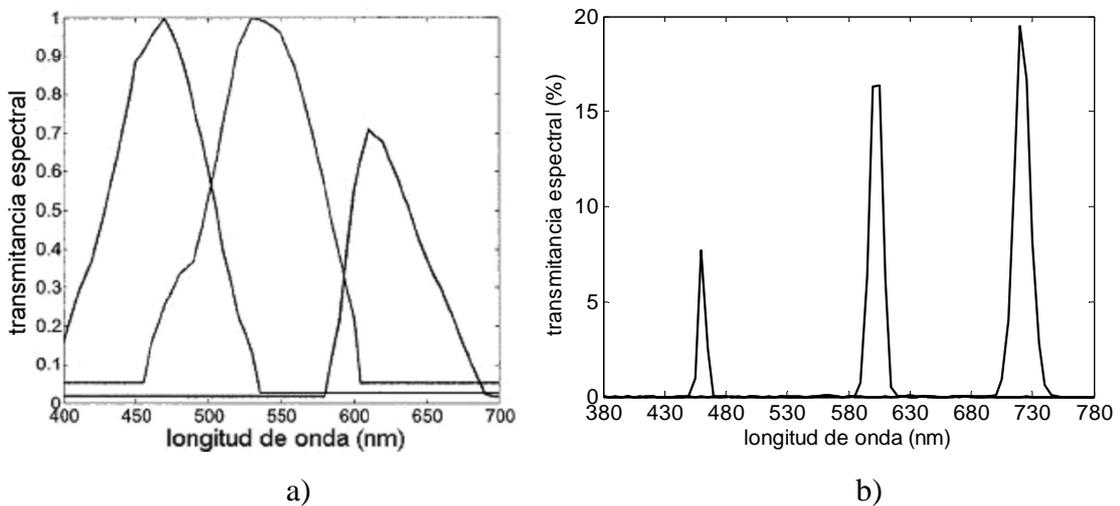


Figura 2.1.- Canales en un sistema multispectral: a) de banda ancha. b) de banda estrecha.

Para poder utilizar estos sistemas es imprescindible llevar a cabo un entrenamiento previo de los mismos, que describiremos con detalle en siguientes secciones de este mismo capítulo. Básicamente, el entrenamiento consiste en relacionar las respuestas de la cámara a espectros conocidos con la forma de dichos espectros, para poder así construir una matriz que

será después necesaria para aplicar algún algoritmo de estimación espectral. La fase de entrenamiento es, pues, necesaria para poder utilizar dichos algoritmos.

### **2.1.2.- Sistema multiespectral basado en una cámara monocromática y filtros de banda estrecha.**

Los filtros interferenciales (o los sintonizables, como el de cristal líquido LCTF) son de banda estrecha, como se ha comentado al hilo de la figura 2.1.b, y usualmente de perfil espectral Gaussiano. Esto permite poder utilizarlos de dos formas diferentes a la hora de tratar de conseguir medidas de curvas espectrales, pero siempre en conjunción con cámaras monocromáticas.

La primera de ellas consiste en utilizar un número reducido de canales o filtros y algún algoritmo de estimación espectral, del mismo modo que se hace con los sistemas de banda ancha, por lo que es necesario llevar a cabo una fase de entrenamiento previo del sistema.

La segunda opción es suponer que el filtro de banda estrecha es completamente monocromático, y que -por tanto- sólo proporciona información de aquella longitud de onda en la que dicho filtro presenta su máxima transmitancia. Si la cámara con la que se utilizan estos filtros está calibrada radiométricamente [Healey y Kondepudy 1994, Ferrero *et al.* 2006b] -como veremos en el capítulo 4-, y si se conoce la transmitancia del filtro, podemos entonces muestrear directamente en cada longitud de onda la radiancia incidente sobre el sistema. Si se desea obtener mayor resolución espectral que la dada por las posiciones de máximo de los filtros, siempre se pueden utilizar técnicas de interpolación [Vilaseca 2005] o un número mayor de filtros, en cuyo caso trataríamos ya con un sistema hiperespectral. Los sistemas multiespectrales o hiperespectrales de banda estrecha basados en muestreo no requieren entonces de la utilización de algoritmos de estimación espectral ni entrenamiento previo del sistema, sino que utilizan una calibración radiométrica previa del mismo. En la figura 2.2 podemos ver, por ejemplo, las transmitancias espectrales típicas de los filtros de banda estrecha que se usan en un sistema hiperespectral de 32 canales.

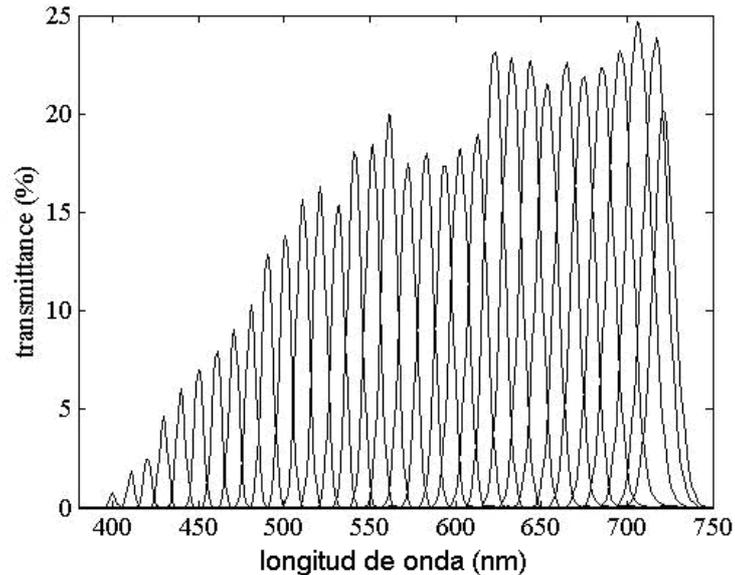


Figura 2.2.- Canales en un sistema hiperespectral.

### 2.1.3.- Sistema multispectral diseñado de forma óptima.

Hemos comentado dos posibilidades de obtener un sistema multispectral, a saber, usando una cámara RGB con filtros de color o con una cámara monocromática y filtros interferenciales. Aún hay una tercera vía para fabricar un sistema multispectral (que puede mezclar filtros de banda ancha o estrecha indistintamente), que consiste en diseñar *ad hoc* un conjunto de sensores óptimos que permitan reconstruir espectros con la mejor calidad posible. Distintos autores [López-Álvarez *et al.* 2005, López-Álvarez *et al.* 2007, Shimano 2006, Sharma *et al.* 1998, Hardeberg 1999, Connah *et al.* 2002] han estudiado el diseño óptimo de sensores, basándose en la posibilidad de poder fabricar casi cualquier respuesta espectral con semiconductores debidamente dopados [Lerch *et al.* 2001], o incluso usando métodos de fabricación o implementación de los sensores óptimos con dispositivos semiconductores de perfil espectral sintonizable electrónicamente gracias a las estructuras NiPiN [Yotter y Wilson 2003, Park y Eden 2002]. El capítulo 3 de este trabajo doctoral recoge este tópico con mayor detalle.

### 2.2.- Dispositivos electrónicos fotosensibles.

Como se mencionó en la sección anterior, la principal ventaja de los sistemas multispectrales reside en que proporcionan información espectral con una alta resolución

espacial. Es esta segunda característica la que los distingue de los sistemas espectrorradiométricos tradicionales. Para poder conseguir una alta resolución espacial es necesario disponer de información radiométrica en cada punto de la imagen registrada, para lo que las matrices de dispositivos fotosensibles CCD o CMOS resultan muy apropiadas.

En principio, ambos tipos de sensores son válidos para construir un sistema multiespectral, si bien se prefieren los CCD ya que su respuesta presenta una mayor linealidad frente a la radiancia y el tiempo de exposición [Ferrero *et al.* 2006] y un menor nivel de ruido. Por su parte, los dispositivos CMOS presentan una serie de características propias e interesantes derivadas de su diferente arquitectura y del hecho de que cada píxel de la matriz presenta una conexión eléctrica propia, al contrario que los CCD en los que los píxeles sólo son accesibles por filas o por columnas de manera secuencial [Ipson y Okereke 1999]. Por ejemplo, los tiempos de respuesta son menores en dispositivos CMOS, es decir, las frecuencias de lectura son mayores y ello permite adquirir un mayor número de imágenes por segundo. Al no haber transporte de carga entre píxeles adyacentes éstos pueden aislarse unos de otros, y se evita así de forma natural el problema del ‘blooming’ (traspaso de carga desde un píxel saturado a sus vecinos de fila o columna, según sea el sentido del transporte de carga durante la lectura). Otra ventaja adicional relacionada con la no interacción entre píxeles vecinos es que se puede trabajar directamente con una región de interés (ROI, del inglés ‘*region of interest*’) en lugar de tener que procesar la matriz completa, lo que -en algunas ocasiones- puede agilizar enormemente la velocidad de captura de imágenes. Sin embargo, el ‘rango dinámico’ (intervalo de valores entre el mínimo y máximo legible sin saturación en el sensor) en un sensor CMOS es sensiblemente menor [Imai *et al.* 2005], aproximadamente un factor 2. Los últimos avances en dispositivos fotosensibles CMOS van encaminados a programar en el propio chip algoritmos de corrección de no-linealidad y no-uniformidad espacial en la matriz, por lo que es de esperar que éstos acaben igualando en calidad de imagen a los CCD (preferidos hoy día para las aplicaciones científicas de altas prestaciones). En las siguientes secciones discutiremos más diferencias, ventajas y desventajas de cada tipo de sensor.

### 2.2.1.- Charge Coupled Devices CCD.

Un CCD [Sze 1981] es, básicamente, una matriz de estructuras Metal-Óxido-Semiconductor (MOS) equiespaciadas cuya principal utilidad es la del transporte controlado de carga. En este sentido, los CCD se diferencian de otros sistemas electrónicos que codifican la información en voltajes o corrientes, pues -al menos en esta primera etapa- la información de cada píxel del CCD está en forma de paquetes de carga. En la figura 2.3 podemos ver la estructura básica de un píxel o celda CCD.

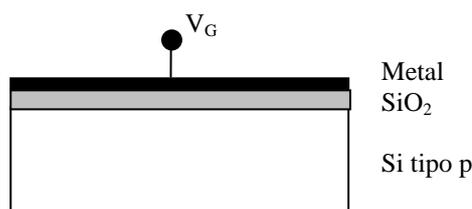


Figura 2.3. Estructura básica de un píxel CCD.

Si se aplica una tensión positiva a la puerta,  $V_G$ , los huecos mayoritarios en el sustrato tipo p son repelidos lejos del óxido, quedando en la interfaz óxido-silicio sólo las cargas negativas ionizadas fijas propias de los átomos aceptadores de la red cristalina dopada tipo p. Durante un cierto intervalo de tiempo, antes de que los electrones generados térmicamente sean atraídos hacia el óxido, la estructura MOS queda en *depleción profunda*, es decir, hay una gran zona del semiconductor que ha quedado desprovista de cargas móviles, y en la que hay un intenso campo eléctrico resultado de la enorme curvatura de bandas que ha provocado la aplicación del pulso de tensión en la puerta. En ese momento, cualquier fotón absorbido en la zona de depleción crea un par electrón-hueco -cargas móviles- que son desplazadas, gracias al campo eléctrico existente, llevando a los electrones a la interfaz con el óxido y a los huecos al fondo del sustrato. De esta forma, todos los electrones existentes en el silicio durante el tiempo que dure la depleción profunda serán debidos a la absorción de un fotón. Así es como se crean los paquetes de carga, proporcionales a la radiación incidente, en cada píxel del CCD. Debemos recordar que la generación  $G$  de pares electrón-hueco depende de la profundidad  $x$  en que nos adentremos en el semiconductor según la ley de Beer [Yotter y Wilson 2003]:

$$G(x) = \alpha \eta_i \phi_0 e^{-\alpha x} \quad (2.1)$$

donde  $\eta_i$  es la eficiencia cuántica interna (el cociente entre el número de pares electrón-hueco creados y el de fotones incidentes),  $\phi_0$  es el flujo de fotones incidente sobre la superficie del píxel CCD, y  $\alpha$  es el coeficiente de absorción para el silicio, que depende fuertemente de la longitud de onda de la radiación incidente de manera que los fotones de longitud de onda corta (azul) penetran en el semiconductor menos que los de longitud de onda más larga (rojo). Según la ecuación (2.1), y dado que podemos suponer que sólo se generan pares de carga en la zona de depleción del CCD por absorción de luz, controlando la extensión en profundidad de dicha zona se puede controlar la longitud de onda de los fotones que serán absorbidos en ella. Ésta es una forma de controlar, durante el proceso de fabricación del CCD y/o mediante la tensión aplicada en las puertas, la sensibilidad espectral de los fotosensores, que suele tener forma de Gaussiana como comentamos en la introducción. El sensor X3® de Foveon [Hubel *et al.* 2004], por ejemplo, utiliza la dependencia de la profundidad de absorción de los fotones con la longitud de onda de los mismos para crear tres canales diferentes RGB (en orden de profundidad) en el mismo píxel. En la figura 2.4 podemos ver la estructura de este nuevo sensor comparada con la de los sensores RGB clásicos basados en el patrón de Bayer, en los que cada píxel es sólo sensible a un canal de color, y luego se interpola espacialmente.

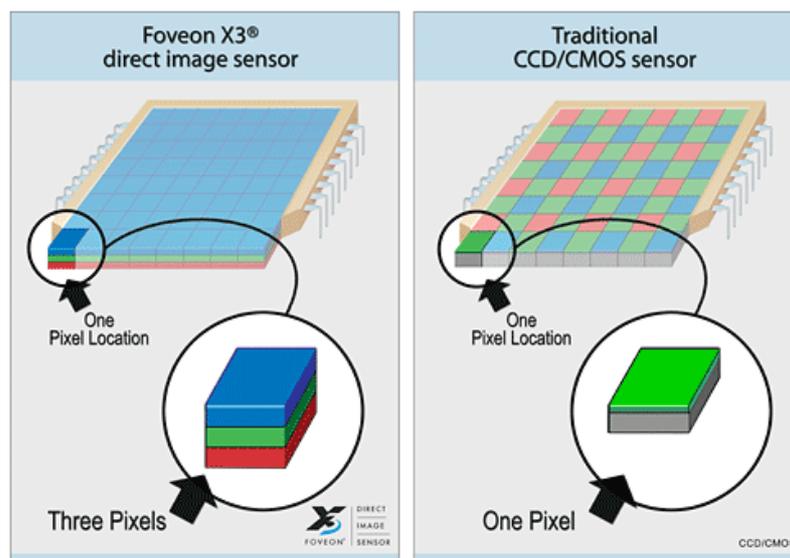


Figura 2.4. Estructura del sensor Foveon X3 y del pixelado clásico de Bayer.

Siguiendo con el proceso de funcionamiento del CCD, una vez que ha finalizado el tiempo de exposición a la luz, los paquetes de carga son transferidos de unos píxeles a otros a lo largo de filas o columnas. Esto se lleva a cabo mediante la aplicación de una serie de pulsos de voltaje adecuado en las puertas de cada celda o píxel del CCD, de manera que los paquetes de carga van siendo movidos hacia los píxeles vecinos en cada pulso y hacia fuera de la matriz CCD al final del proceso, como vemos en la figura 2.5. En la última celda de la matriz CCD existe una circuitería para amplificar la señal y convertirla en un valor de voltaje proporcional al paquete de carga registrado (*'readout amplifier'* en inglés), y más tarde un conversor analógico-digital.

Como vemos, la lectura de los valores de carga de cada píxel de la matriz CCD se hace celda a celda de forma secuencial. El transporte de carga en los CCD es bastante eficiente, pues apenas se pierde un 0.1% de la carga almacenada en las celdas hasta que es leída en el amplificador de salida. En los CCD de canal enterrado (en inglés *'buried channel CCD'*), donde se implanta lejos del óxido un canal tipo n de menor resistividad para que los paquetes de carga sean transportados a través de él (así se evitan las impurezas existentes en la superficie entre el óxido y el silicio), la eficiencia en el transporte puede llegar a ser hasta un orden de magnitud mayor.

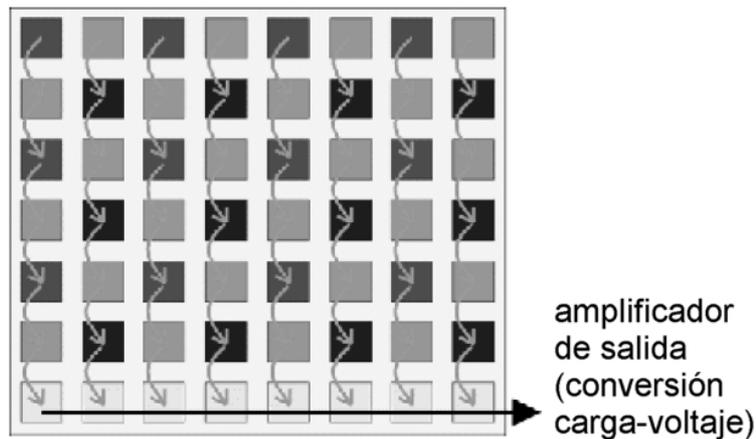


Figura 2.5. Transporte de carga en una matriz CCD.

La estructura CCD es bastante sencilla, y permite que toda la celda CCD sea útil para la recepción de fotones, pues la circuitería para el tratamiento de los paquetes de carga es externa a la matriz. Esto tiene varias ventajas [Yotter y Wilson 2003]: la primera es que el tratamiento electrónico de la información registrada es el mismo para todos los píxeles, y así

se evitan posibles inhomogeneidades espaciales en la respuesta del CCD debidas a este proceso. La segunda, es que el amplificador de salida no tiene limitaciones de espacio al construirse fuera de la matriz de píxeles o celdas, y se pueden diseñar y utilizar circuitos complejos de bajo ruido y alta efectividad, con un número de bits en la conversión analógico-digital que puede llegar a 16. Por otro lado, al poder aprovechar todo el tamaño del píxel para la absorción de fotones, los sensores CCD tienen un mayor rango dinámico, aproximadamente el doble que el de los sensores CMOS de igual tamaño. Otra ventaja del CCD frente al CMOS es que permite la utilización de puertas y óxidos muy finos, muy transparentes al paso de fotones a través de ellos.

Todas estas características hacen que en la actualidad se prefieran las cámaras CCD para aplicaciones de altas prestaciones, pues la calidad de imagen frente a las cámaras CMOS es aún notable, aunque su precio es más elevado. Sin embargo, los sensores CMOS presentan algunas ventajas frente a los CCD, como comentamos en la siguiente sección.

### 2.2.2.- Complementary Metal Oxide Semiconductor CMOS.

La estructura de un píxel CMOS es sensiblemente más compleja que la de una celda CCD, debido principalmente a que cada píxel CMOS incluye su propia circuitería de amplificación y conversión analógico-digital, gracias a que la tecnología CMOS permite la integración de dichos circuitos en un espacio reducido. El tener acceso individualizado a cada celda CMOS hace que en esta estructura no sea necesario el proceso de transporte de carga para la lectura de la información registrada en la matriz. En la figura 2.6 vemos un sencillo esquema de dicho dispositivo.

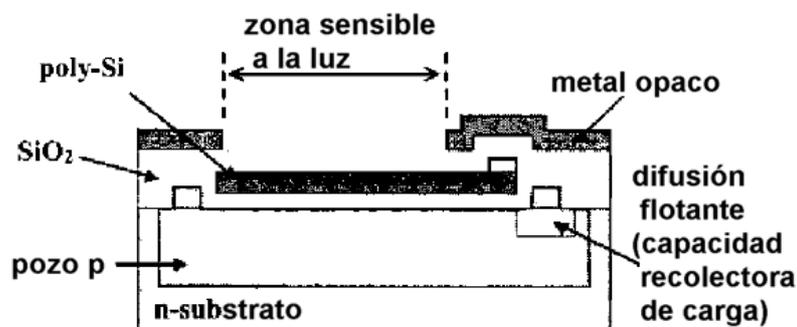


Figura 2.6. Esquema de un píxel correspondiente a un sensor CMOS.

Básicamente, el sensor CMOS consta de un sustrato tipo n sobre el que se inserta un pozo tipo p, dando lugar a un diodo. Si dicho diodo se polariza en inversa (con el lado p a una tensión menor que el lado n), se crea una zona de depleción donde se pueden absorber fotones de manera análoga a como se ha explicado para los sensores CCD. Esto se consigue aplicando una tensión negativa en el polisilicio de la puerta flotante que hay encima del óxido que a su vez está encima de la zona p (ver figura 2.6). Sin embargo, esta zona de depleción es sensiblemente menor a la creada en las celdas CCD, pues los campos eléctricos aquí son menores, lo que da lugar a que no puedan absorberse fotones con una longitud de onda mayor de 650nm típicamente en CMOS comerciales.

La carga generada por la absorción de fotones es después transportada hacia una zona lateral (aplicando una tensión adecuada en el metal opaco situado a la derecha en la figura 2.6) y depositada en un pozo de potencial, creado por una difusión flotante tipo n que hace las veces de capacidad, donde se almacena dicha carga para leer la diferencia de potencial provocada por la misma. De esta forma, se realiza la conversión de carga a voltaje en el propio píxel. De hecho, es posible añadir circuitos CMOS que realicen la posterior amplificación y conversión analógico-digital, como vemos en la figura 2.7.

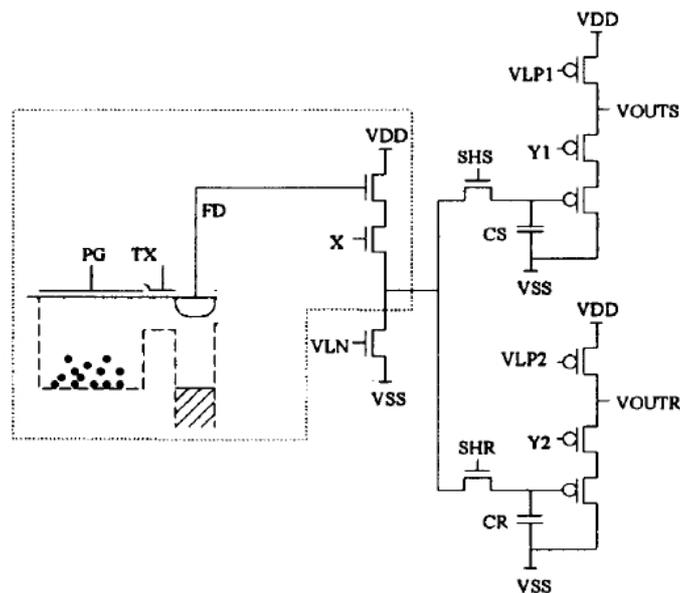


Figura 2.7. Píxel CMOS mostrando la zona sensible a la luz (en el recuadro de puntos) y la circuitería de amplificación.

De esta forma, el píxel CMOS queda ocupado en parte por toda esta circuitería, lo que hace que no toda la superficie del píxel sea apta para la recepción de fotones. Sin embargo, el

poder disponer de circuitos amplificadores CMOS para cada píxel tiene ciertas ventajas. Por ejemplo, los circuitos CMOS son reducidos (de menor coste por tanto) y de muy bajo consumo, lo que permite configurar los amplificadores de señal con muy alta ganancia, y eso se traduce en una mayor responsividad de los sensores CMOS frente a los CCD. También se consiguen sensores de menor coste, más ligeros y compactos que los CCD con igual número de píxeles, lo que los hace idóneos para su utilización como sensores biomédicos.

Sin embargo, la circuitería individualizada para cada píxel obliga a que dichos circuitos sean muy sencillos, y no puedan desarrollar tareas avanzadas como la eliminación de ruido, estabilización del *'offset'* (lo que da lugar a problemas al registrar imágenes oscuras o con bajo nivel de señal) o conversión analógico-digital con 16 bits. Estos circuitos pequeños son además muy frágiles y ocurre en sensores CMOS que a veces se estropean algunos píxeles. La desventaja principal de la amplificación en cada píxel reside en el hecho de que de esa forma se inducen inhomogeneidades espaciales en la imagen por las inevitables diferencias de ganancia entre amplificadores diferentes. Esto último se ha corregido introduciendo amplificadores realimentados, con menor ganancia y menor responsividad en los píxeles, por tanto.

### **2.2.3.- Ruido en dispositivos semiconductores para captura de imágenes.**

Una característica común a cualquier dispositivo electrónico es la presencia de ruido en su respuesta. Por ruido se entiende cualquier perturbación que interfiere con la señal eléctrica de interés [Franco 2002]. El efecto del ruido puede llegar a veces a ser tan perturbador que se pierde el acceso a la información contenida en las señales que se desean medir o registrar. Hay numerosas fuentes y tipos de ruido, y ello da lugar a múltiples clasificaciones del mismo. Por ejemplo, el ruido se puede clasificar atendiendo a su origen (interno o externo al dispositivo), a sus efectos sobre las señales (de alto o bajo nivel), a su estadística (según siga una distribución de Gauss, Poisson, etc), a su comportamiento temporal (de alta o baja frecuencia, o incluso blanco: independiente de la frecuencia) o a las fuentes que lo originan (térmico, *'shot'*: debido al carácter cuántico del electrón, etc). También es frecuente encontrar tratamientos formales diferentes para el ruido según éste se estudie desde el punto de vista de la microelectrónica o el de la formación de imágenes (incluimos bajo esta denominación el tratamiento del ruido que hacen los textos de Óptica,

Colorimetría y tratamiento de imágenes digitales). En este trabajo no se pretende hacer un estudio teórico con profundidad de todos los tipos de ruido que afectan a las cámaras digitales, pero sí que mencionaremos los más comunes y sus efectos sobre la calidad de la imagen obtenida.

2.2.3.a.- *Relación señal-ruido (SNR):*

Una magnitud muy utilizada [Franco 2002, Lathi 1989] para medir la influencia del ruido en la medida de señales eléctricas es la relación señal ruido (SNR, del inglés ‘*signal-noise ratio*’), que se define como el cociente entre la potencia media de una señal y la potencia media del ruido:

$$SNR = \frac{S}{N} = \frac{\langle P_{señal} \rangle}{\langle P_{ruido} \rangle} = \frac{\langle V_{señal}^2 \rangle}{\langle V_{ruido}^2 \rangle} \quad (2.2)$$

donde en la última igualdad se ha usado la ley de Ohm para relacionar la potencia de una señal y el voltaje de la misma (en la sección 2.2.3.b. se verá que la última igualdad es un cociente entre valores cuadráticos medios de voltajes). Es frecuente expresar la SNR en decibelios (dB), para lo cual se realiza la siguiente operación:

$$SNR_{dB} = 10 \log \left( \frac{S}{N} \right) = 10 \log \left( \frac{P_{señal}}{P_{ruido}} \right) = 20 \log \left( \frac{V_{señal}}{V_{ruido}} \right) \quad (2.3)$$

donde el logaritmo debe entenderse en base decimal. Por ejemplo, si una cámara CCD presenta, en promedio, una relación señal ruido de 40dB significa que el ruido que la afecta tiene una amplitud 100 veces menor que la señal registrada, es decir, el ruido es del 1% de la señal en amplitud (al elevar al cuadrado, se obtiene que la potencia media del ruido es  $10^4$  veces menor que la potencia media de la señal).

2.2.3.b.- Valor cuadrático medio y valor eficaz (rms). Adición de ruidos:

El valor cuadrático medio de una señal eléctrica  $x$  (voltaje o corriente, representada por su amplitud) se define como:

$$\langle X^2 \rangle = \frac{1}{T} \int_0^T x^2(t) dt \quad (2.4)$$

donde  $T$  representa un periodo de tiempo en el que, según las características de la señal, resulte adecuado calcular el anterior promedio (típicamente, un periodo al menos dos veces mayor que el correspondiente a la mínima componente en frecuencia con amplitud significativa según la transformada de Fourier de la señal). Esta expresión es muy útil en el caso en que queramos calcular, por ejemplo, la potencia media disipada en una resistencia  $R$  de un circuito eléctrico:

$$\langle P \rangle = \frac{1}{T} \int_0^T i(t)v(t) dt = \frac{1}{T} \int_0^T \frac{v^2(t)}{R} dt = \frac{\langle V^2 \rangle}{R} \quad (2.5)$$

Si tomamos la raíz cuadrada de la expresión (2.4), obtenemos el valor rms (del inglés ‘*root mean square*’) de la señal  $x$

$$X_{rms} = \sqrt{\langle X^2 \rangle} = \left( \frac{1}{T} \int_0^T x^2(t) dt \right)^{1/2} \quad (2.6)$$

que también es conocido como ‘valor eficaz’ [Franco 2002] de la señal en el caso de que ésta sea sinusoidal (los valores eficaces son muy útiles para el cálculo de potencias medias consumidas en circuitos eléctricos). Puede ocurrir que una señal tenga promedio nulo y sin embargo su valor rms sea considerable, que es lo frecuente en las señales de ruido. Por ejemplo, si el ruido en un dispositivo electrónico tiene un valor rms de voltaje igual a 0.2 V, aunque su promedio sea nulo, esto significa que las variaciones de esa señal provocan en los circuitos del dispositivo un gasto de potencia equivalente al de una señal constante de 0.2 V de amplitud.

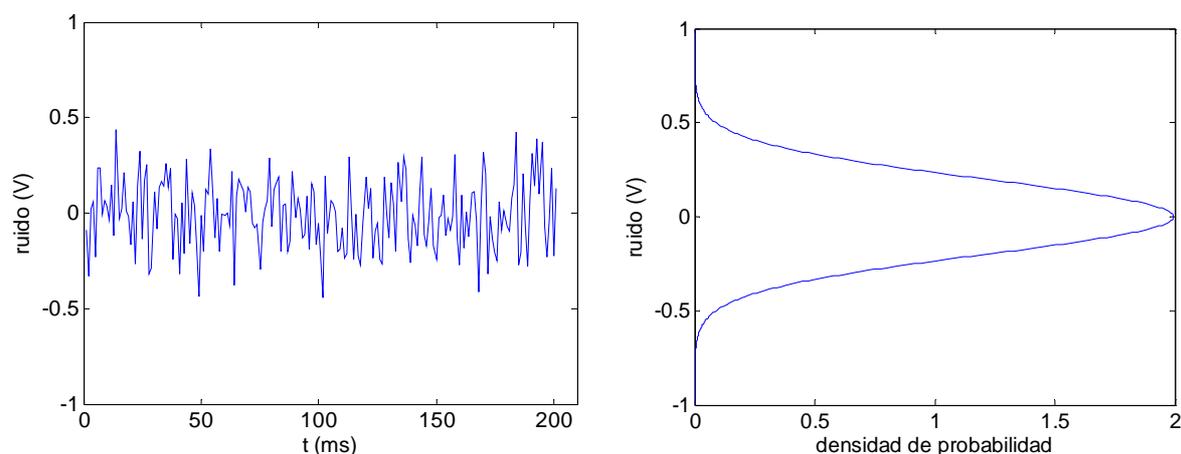


Figura 2.8. Señal de ruido Gaussiano y su función de densidad de probabilidad asociada.

Como veremos más adelante, uno de los tipos de ruido más frecuentes es el Gaussiano, denominado así porque la probabilidad de que el ruido tenga una amplitud  $x$  dada en un instante determinado sigue una distribución de probabilidad Gaussiana, cuya anchura o desviación estándar coincide con el valor rms de la señal  $X_{rms}$  (siempre que ésta tenga media nula). En la figura 2.8 vemos un ejemplo de señal de ruido cuyo valor rms es igual a 0.2V, y cuya función densidad de probabilidad asociada es una Gaussiana de desviación estándar 0.2V igualmente. En este caso, se puede calcular fácilmente [Franco 2002] que la probabilidad de que el ruido presente un valor mayor de 0.2V es del 32%, y apenas un 4.6% del tiempo dicha señal presenta un valor superior a 0.4V.

Si tenemos dos señales de ruido tipo Gaussiano que afectan a un dispositivo electrónico de manera independiente, es decir, que dichas señales no están correlacionadas entre sí (lo que es usual dado el carácter aleatorio del ruido), podemos calcular el efecto conjunto de ambas. Para ello, se calcula el valor rms de la suma de ambas señales:

$$X_{rms} = \left( \frac{1}{T} \int_0^T (x_1(t) + x_2(t))^2 dt \right)^{1/2} = \left( X_{1rms}^2 + X_{2rms}^2 + \frac{2}{T} \int_0^T x_1(t)x_2(t)dt \right)^{1/2} \quad (2.7)$$

y aplicando la suposición de que ambas señales están no correlacionadas, el tercer sumando es nulo, con lo cual los valores rms de las señales de ruido se suman de acuerdo al teorema de Pitágoras:

$$X_{rms} = \left( X_{1rms}^2 + X_{2rms}^2 \right)^{1/2} \quad (2.8)$$

El teorema del límite central [Pardo *et al.* 1975] establece que, bajo ciertas condiciones prácticas (referidas al número de señales que se suman), la adición de ruidos de tipo Gaussiano sigue siendo una señal de ruido de tipo Gaussiano con un valor rms dado por la ecuación (2.8). Eso ocurrirá en los CCD, donde los diferentes tipos de ruido existentes son de tipo Gaussiano o se pueden aproximar por él con bastante exactitud, permitiendo entonces que podamos simularlos todos ellos por un solo ruido cuyo valor rms es el dado por la ecuación (2.8).

### 2.2.3.c.- Densidad de potencia espectral del ruido:

Hasta ahora hemos visto que el ruido es una señal de variación temporal aleatoria de la que podemos estimar parámetros como su valor rms. Sería también interesante tratar de caracterizarla mediante algún otro parámetro que permita ver qué frecuencias (entendida ésta como la inversa de un periodo de tiempo) son las dominantes en una señal de este tipo. Esta información sería útil, por ejemplo, a la hora de diseñar los amplificadores de lectura de los píxeles de la matriz CCD o CMOS, pues la adición de filtros paso-baja o paso-alta puede reducir considerablemente el efecto de ciertos tipos de ruido, mejorando la calidad de los dispositivos.

Se define la *densidad de potencia espectral* de una señal [Franco 2002] como la derivada de la potencia media de dicha señal con respecto a la frecuencia (temporal en este caso). Dado que según la relación (2.5), la potencia media  $\langle P \rangle$  y el valor cuadrático medio del voltaje  $\langle V^2 \rangle$  son proporcionales, se suele expresar la densidad de potencial espectral del ruido según:

$$v_n^2(f) = \frac{d\langle V_n^2 \rangle}{df} \quad (2.9)$$

donde el subíndice  $n$  hace referencia al ruido (*'noise'* en inglés). La magnitud  $v_n^2(f)$  representa la potencia media del ruido en un intervalo de 1Hz centrado en torno a la frecuencia  $f$ , y sus unidades son voltios al cuadrado partido por hertzios ( $V^2/Hz$ ). Cuando este parámetro se representa frente a la frecuencia, da una idea de cómo se reparte la potencia del ruido sobre las diferentes frecuencias. Por otro lado, el parámetro  $v_n(f)$ , que no es más que la raíz cuadrada de la densidad de potencia espectral del ruido, se denomina *densidad espectral del ruido* y suele ser el especificado las hojas características de muchos dispositivos. Si se integra la expresión (2.9) entre dos frecuencias dadas, obtenemos el valor rms del ruido en ese ancho de banda:

$$V_{n_{rms}} = \left( \int_{f_1}^{f_2} v_n^2(f) df \right)^{1/2} \quad (2.10)$$

Hablando en términos de densidad espectral de ruido, es usual en casi todos los dispositivos electrónicos tener dos tipos de ruido: el blanco y el denominado  $1/f$ . El ruido blanco tiene el mismo valor para todas las frecuencias, mientras que el ruido  $1/f$  presenta una disminución de la amplitud con la frecuencia de acuerdo a la relación matemática que su propio nombre indica. Ambos ruidos se suman, y el resultado es una dependencia del ruido con la frecuencia tal y como vemos en la figura 2.9.

A partir de la ecuación (2.10) podríamos calcular el valor rms del ruido presente en una cámara CCD cuya frecuencia de lectura (*'readout frequency'*) es de 10MHz, y que toma imágenes con un tiempo de exposición de 1ms. En ese caso sería  $f_2 = 10^7$  Hz y  $f_1 = 10^3$  Hz y no habría más que calcular la integral correspondiente para una densidad espectral de ruido como la dibujada en la figura 2.9. Es interesante que  $f_2$  sea alta para que la cámara pueda capturar un gran número de imágenes por segundo, pero si  $f_1$  no es cercano a  $f_2$  ello implica integrar mayor ruido blanco en la ecuación (2.10). Por otro lado, si el tiempo de exposición es elevado, la frecuencia  $f_1$  es baja, y de esta forma se introduce principalmente ruido tipo  $1/f$  en el cálculo de (2.10) [López-Álvarez *et al.* 2007b].

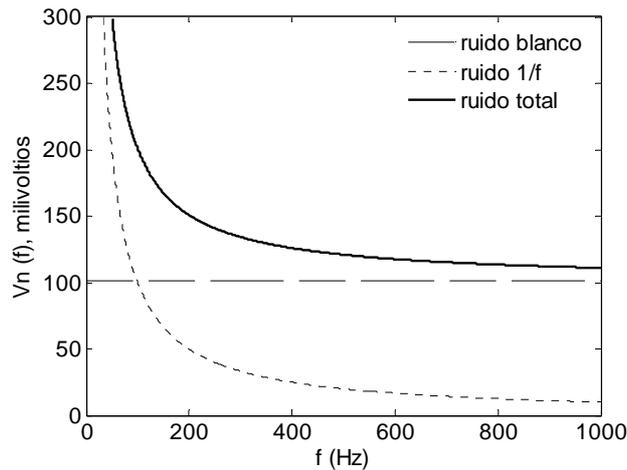


Figura 2.9. Densidad espectral del ruido blanco y ruido  $1/f$ .

#### 2.2.3.d.- Fuentes de ruido en CCD y CMOS:

En esta sección enumeraremos y describiremos ligeramente los diferentes tipos de ruido que más afectan a las estructuras CCD y CMOS [Franco 2002, Sze 1981] utilizadas en dispositivos de imagen digital. Hablaremos del ruido externo a la cámara (lo que usualmente se conoce como *interferencias*), ruido de corriente continua (*'dc-noise'* en inglés), ruido térmico, ruido *'shot'*, ruido *'flicker'*, y el ruido de cuantización.

El ruido externo es el causado por cualquier fuente de radiación electromagnética externa al dispositivo objeto de estudio. Las fluctuaciones de la red eléctrica, la presencia de cualquier otro material electrónico indebidamente aislado, las fuentes de luz artificiales conmutadas, o la presencia de teléfonos móviles o repetidores cercanos son fuentes usuales de ruido externo. Este ruido puede ser periódico, intermitente o completamente aleatorio [Franco 2002]. Usualmente se puede reducir o aislar mediante el diseño correcto de filtros eléctricos y electrónicos, contactos a tierra en buen estado, carcasas metálicas para el aislamiento electrostático, fuentes de alimentación debidamente aisladas y estabilizadas, etc.

El ruido de corriente continua es una señal constante que está presente en la salida de los amplificadores de lectura (*'readout amplifiers'*) dando lugar a valores no nulos en imágenes oscuras. Al ser un término constante, es fácilmente corregible mediante un calibrado correcto de la cámara. Este ruido se debe a las corrientes y voltajes de offset presentes siempre a la entrada de dichos amplificadores [Franco 2002] y que sólo son evitables mediante circuitería compleja que no siempre está disponible en el reducido espacio del chip.

El ruido térmico es la principal fuente interna de ruido en dispositivos electrónicos. Este ruido se debe a las fluctuaciones por agitación térmica que sufren los electrones, lo que provoca que –al paso por cualquier elemento resistivo– se produzca una corriente o caída de potencial parásitos causados por estas oscilaciones indeseadas. La densidad de potencia espectral del ruido térmico viene dada por:

$$v_n^2 = 4KTR \quad (2.11)$$

donde  $K$  es la constante de Boltzman,  $T$  es la temperatura absoluta y  $R$  es el valor de la resistencia donde la agitación térmica provoca la perturbación. Como vemos, este ruido no depende de la frecuencia, así que es de tipo blanco, y también es de tipo Gaussiano. Es proporcional a la resistencia  $R$  y a la temperatura  $T$ , y es por ello por lo que se busca siempre el diseño con menor resistencia posible (usando transistores en modo de carga activa que provoquen el efecto equivalente en tensión y corriente al de una resistencia) y tratando de refrigerar el dispositivo. Por ejemplo, las cámaras CCD de altas prestaciones siempre funcionan en entornos refrigerados (mediante cámaras Peltier, aletas térmicas disipadoras y ventiladores, en presencia de nitrógeno líquido, etc) para poder minimizar en la medida de lo posible este tipo de ruido.

El ruido ‘*shot*’ es debido al paso de un electrón a través de una barrera de potencial. Las corrientes que observamos macroscópicamente son debidas a la suma de las minúsculas corrientes provocadas por cada electrón individual al atravesar estas barreras de potencial. Es de esperar, por tanto, que debido al carácter cuántico de los electrones (tienen una carga dada no infinitesimal) se produzcan perturbaciones de ese orden de magnitud en las corrientes macroscópicas. El ruido ‘*shot*’ es proporcional a la corriente  $I$  que circula por el dispositivo y a la carga del electrón  $q$ , también es de tipo blanco y sigue una distribución de Poisson [Healey y Kondepudy 1994].

El ruido  $1/f$ , también llamado ‘*flicker*’, y está presente tanto en dispositivos activos (transistores, diodos, etc) como en dispositivos pasivos (resistencias, condensadores y bobinas). En los dispositivos activos su origen está en la presencia de trampas que atrapan electrones y los liberan más tarde, provocando fluctuaciones en las corrientes. Estas trampas están presentes, por ejemplo, en la interfaz entre el dióxido de silicio y el propio silicio, y es por esto por lo que se prefieren los CCD de canal enterrado a los de canal superficial (ver

sección 2.2.1). El ruido ‘*flicker*’ es proporcional a  $I^a$  (donde  $I$  es la corriente en el dispositivo y  $a$  una constante entre 0.5 y 2 dependiendo del material), e inversamente proporcional a la frecuencia de variación de las señales (por ello se prefiere trabajar a altas frecuencias de lectura para evitar este ruido).

Por último, el ruido de cuantización está presente en cualquier dispositivo digital que deba realizar una conversión desde datos analógicos. La cuantización consiste en ‘expresar’ el valor de una señal analógica (cuyo intervalo de variación o rango dinámico es conocido) en un instante determinado utilizando un número entero dentro de un conjunto de valores posibles. Por ejemplo, si se usan 8 bits para cuantizar, el número de posibles valores enteros que podremos usar para la representación de la información será 256 ( $2^n$  en general, siendo  $n$  el número de bits). Por tanto, estamos expresando los infinitos valores del continuo analógico en un número finito de valores del dominio digital, y por tanto se deben hacer algunas aproximaciones a la hora de cuantizar ciertos valores analógicos [Lathi 1989]. Por ejemplo, para cuantizar una señal analógica que puede variar entre 0 y 1V usando 8 bits, debemos discretizar ese intervalo en pasos de  $\Delta=1/256=0.0039V$  (si la cuantización es uniforme). Así, si la señal en un instante dado vale 0.2333V, el valor discreto más cercano es 0.234V, cometiendo un error de 0.0007V (un 0.3% en este caso). Como este error depende del valor analógico que se cuantiza y, si analizamos el error cometido a lo largo de muchas muestras cuantizadas, se observa que éste es completamente aleatorio (siguiendo una distribución uniforme en este caso), es por eso por lo que a este error de aproximación se le llama ruido de cuantización. Se puede demostrar que el ruido de cuantización (si la cuantización es uniforme) tiene un valor rms igual a  $\Delta^2/12$ , siendo  $\Delta$  el tamaño del cuanto que depende inversamente del número  $n$  de bits usados. Es por ello por lo que si se utilizan más bits para cuantizar, el error cometido es menor. En cualquier caso, cuando la cuantización es uniforme existe el problema de que si la señal es pequeña, el error relativo cometido es mayor que cuando la señal toma valores altos. Para evitar este problema se han propuesto [Lathi 1989] multitud de esquemas de cuantización no-uniforme (cuantización logarítmica, cuantización potencial, ley  $\mu$ , ley A) en los que el tamaño del cuanto es menor en la zona de valores bajos de señal, de manera que el error relativo se mantiene casi constante (esto se consigue haciendo una transformación previa de la señal que se pretende cuantizar). En este trabajo no daremos más detalles sobre cómo se implementan cada uno de los diferentes métodos de

cuantización, pero en el capítulo 3 veremos el efecto de usar uno u otro sobre los resultados de las estimaciones espectrales [López-Álvarez *et al.* 2007].

### **2.3.- Algoritmos de estimación espectral.**

Como se ha dicho en la sección 2.1, una curva de densidad de potencia espectral de un iluminante natural en el espectro visible (típicamente entre 400nm y 700nm) queda determinada a partir de un conjunto de muestras tomadas a intervalos de no más de 10nm. Dichas curvas, por tanto, se pueden tratar matemáticamente como vectores en un espacio  $N$ -dimensional con  $N = 31$  en este ejemplo. Si los valores extremos son ampliados, o si el intervalo espectral de muestreo se reduce,  $N$  puede llegar a tomar valores mayores (sirva de ejemplo el muestreo espectral que realiza el espectrorradiómetro utilizado en este trabajo doctoral: SpectraScan PR650, que mide desde 380nm hasta 780nm en intervalos de 4nm dando lugar a 101 muestras). La labor de un sistema multiespectral es tratar de estimar esas  $N$  muestras con la mayor exactitud posible, utilizando para ello la información obtenida a partir de un número  $k$  mucho menor de sensores ( $k = 4, \dots, 9$  como hemos indicado en la sección 2.1).

En el caso que nos ocupa, de determinación de la radiancia espectral de la luz-cielo, podemos modelar el problema [Hardeberg 1999] de acuerdo a la figura 2.10. En ella vemos que la radiancia proveniente de un punto del cielo  $E(\lambda)$  es registrada en la cámara gracias a la presencia de sensores en la misma cuya sensibilidad espectral es una función de la longitud de onda, que expresaremos por  $R_i(\lambda)$ , con  $i = 1, 2, \dots, k$  siendo  $k$  el número total de sensores de diferente respuesta espectral presentes en la cámara, es decir, el número de canales de nuestro sistema multiespectral. Podemos representar idealmente la respuesta  $\rho_i$  del sensor  $i$ -ésimo de la cámara asumiendo que dicha respuesta es lineal [Ferrero *et al.* 2006, Hardeberg 1999, Connah *et al.* 2002, Shimano 2002] con la radiancia recibida:

$$\rho_i = \int_{\lambda_1}^{\lambda_2} E(\lambda) R_i(\lambda) d\lambda \quad (2.12)$$

donde los límites de integración, definidos por  $\lambda_1$  y  $\lambda_2$ , corresponden con la mínima y máximas longitudes de onda a las que la cámara es sensible, y suelen corresponder con los límites del espectro visible (entre 380nm y 780nm típicamente).

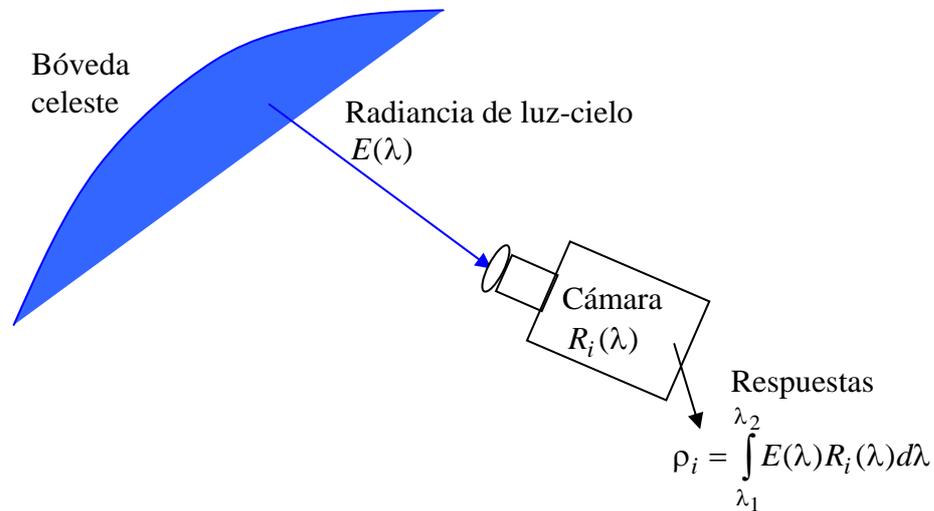


Figura 2.10. Esquema de la interacción de la luz-cielo con los sensores de la cámara.

El problema se entiende con claridad si utilizamos formulación matricial para simplificar la notación. Dado que las curvas de distribución de potencia espectral de luz-cielo,  $E(\lambda)$ , y las sensibilidades espectrales de la cámara,  $R(\lambda)$ , se muestrean en un número finito,  $N$ , de longitudes de onda a la hora de medirlas con cualquier instrumento espectralradiométrico, formalmente la ecuación (2.12) se puede expresar como un producto de matrices:

$$\rho = R^t E + \sigma \quad (2.13)$$

donde  $\rho$  es un vector columna de  $k$  componentes con las respuestas de cada uno de los sensores a la radiancia espectral recibida  $E$ , que queda representada por un vector columna de  $N$  componentes (tantas como longitudes de onda son muestreadas). La matriz  $R$  representa la sensibilidad espectral (para un tiempo de exposición fijo) de los  $k$  sensores de la cámara a cada una de las  $N$  longitudes de onda (es una matriz  $N \times k$ ), y el superíndice  $t$  significa transposición. El último sumando,  $\sigma$ , representa el ruido presente en el sistema ('*dc-noise*', ruido térmico, '*shot noise*', ruido '*flicker*' y ruido de cuantización) y para la finalidad de este

trabajo -más allá de las causas y descriptores que lo caracterizan- puede modelarse por un vector de  $k$  componentes independientes, aleatorias y no correlacionadas que se suma a la respuesta ideal de la cámara dada por (2.12) [Hardeberg 1999, López-Álvarez *et al.* 2005, Haneishi *et al.* 2000, Sze 1981, Franco 2002, Yotter y Wilson 2003]. Este término de ruido incluye también otros factores que modifican la respuesta teórica del sistema, como pueden ser errores experimentales o de calibración de los componentes del mismo [Shimano 2002].

En la ecuación (2.13) vemos claramente que la estimación espectral de  $E(\lambda)$  a partir de las respuestas de unos pocos sensores es un problema indeterminado: hay más incógnitas (longitudes de onda) que ecuaciones (sensores), y existen infinitas curvas espectrales que pueden dar lugar a las mismas respuestas de los sensores y -por tanto- serían indistinguibles para el sistema multiespectral (dando lugar a lo que se conoce como ‘metamerismo de la cámara’ [Hong *et al.* 2001]).

Los algoritmos de estimación espectral tratan de resolver la anterior indeterminación siguiendo usualmente criterios de mejor solución promedio (mínimos cuadrados, minimización de alguna métrica, etc) en algún subespacio englobado dentro del espacio de vectores que representan las curvas espectrales. Dichos algoritmos se basan en el conocimiento *a priori* del tipo de espectro que se desea recuperar o estimar, para así aportar soluciones con características espectrales similares a la solución deseada. Es frecuente utilizar algún método de extracción de información, como el Análisis de Componentes Principales (PCA, ‘*Principal Component Analysis*’) [Hardeberg 1999], o –más recientemente– la factorización no-negativa de matrices (NMF, ‘*Non-negative Matrix Factorization*’) [Buchsbaum y Bloch 2002, Hoyer 2004, Lee y Seung 1999] o el Análisis de Componentes Independientes (ICA, ‘*Independent Component Analysis*’) [Hyvärinen *et al.* 2001, Lee *et al.* 1999]. Estos métodos se caracterizan por proporcionar un conjunto de vectores base a partir de una serie de espectros ‘de entrenamiento’ cuyas características espectrales son similares a las de aquellos espectros que queremos recuperar. En el caso del PCA dichos vectores tienen la peculiaridad de ser ortonormales, y los primeros vectores base contienen casi toda la información estadísticamente representativa del conjunto de espectros del que se ha obtenido. En el caso del ICA los vectores base son independientes pero no necesariamente ortonormales ni con una importancia estadística marcada según el orden del vector, mientras que en el NMF los vectores base son independientes y además siempre positivos, lo que puede arrojar algunas ventajas en ciertos casos (como se comenta en la sección 3.3.3). La estimación espectral que

deberá proporcionar el sistema multiespectral será una combinación lineal de los vectores base así obtenidos. Podremos escribir, por tanto:

$$E = V\varepsilon \quad (2.14)$$

donde el vector de radiancia espectral  $E$  (con  $N$  componentes) se expresa como la combinación lineal de una base de vectores  $V$  (representada por una matriz  $N \times n$  de  $n$  vectores columna) con pesos o coeficientes dados por el vector  $\varepsilon$  (de dimensiones  $n \times 1$ ). El número  $n$  de vectores base utilizados típicamente es mucho menor que  $N$  (el número de muestras con las que se trabaja) y suele ser igual que  $k$  (el número de sensores), como veremos más adelante. De esta forma, los algoritmos de estimación espectral que utilizan bases lineales tratarán de encontrar  $n$  parámetros para la combinación lineal de los vectores base a partir de la respuesta de  $k$  sensores, lo que usualmente es un sistema de ecuaciones determinado. Si no lo fuera, la utilización de la pseudoinversa de Moore-Penrose [Hardeberg 1999] nos proporcionará una solución de mínimos cuadrados aceptable. De esta forma, la calidad de la estimación espectral proporcionada por el algoritmo que utiliza la base  $V$  queda supeditada –en primera instancia– a la ‘calidad’ con que dicha base representa a los espectros que queremos recuperar. El número de espectros de entrenamiento  $m$  que se utilizan para obtener la base  $V$  es un parámetro que afecta a la ‘calidad’ de la misma, como veremos en posteriores apartados.

Tres de los algoritmos estudiados en este trabajo utilizan vectores base obtenidos en la forma que acabamos de comentar, a saber: el algoritmo de Maloney-Wandell [Maloney y Wandell 1986] (que ha sido ampliamente utilizado por otros autores [López-Álvarez *et al.* 2005, Connah *et al.* 2002]), el algoritmo de Imai-Berns [Imai y Berns 1999], y el método de Shi-Healey [Shi y Healey 2002]. Los algoritmos de Wiener [Pratt y Mancill 1976, Haneishi *et al.* 2000, Stigell *et al.* 2005] y de regresión (lineal o no-lineal) [Nieves *et al.* 2005, Vilaseca *et al.* 2003, Hong *et al.* 2001], también hace uso del conocimiento *a priori* del tipo de espectro que queremos obtener, pero esta vez no para encontrar una base lineal de vectores espectralmente representativos, sino que construye una matriz a partir de la relación entre los espectros conocidos y las respuestas de los sensores a estos espectros. Dicha matriz más tarde es utilizada para obtener los espectros desconocidos a partir de la información obtenida de los sensores.

En los siguientes apartados estos cuatro métodos o algoritmos de estimación espectral se describen con cierto detalle. Nos hemos centrado en estos métodos en concreto porque sin duda son los más utilizados en la bibliografía de sistemas multiespectrales [Hardeberg 1999, López-Álvarez *et al.* 2005, Connah *et al.* 2002, Nieves *et al.* 2005, Shimano 2005, Shimano 2006, López-Álvarez *et al.* 2006, Cheung *et al.* 2005, Vilaseca *et al.* 2003, Connah *et al.* 2001] gracias a los buenos resultados que se obtienen con ellos. En la mayoría de casos, estos métodos se han aplicado casi siempre para estimación espectral de reflectancias de objetos, pero –como veremos aquí– son igualmente aplicables para el caso de iluminantes. En próximos capítulos indagaremos aún más en la comparación entre métodos, presentando los sensores óptimos que se obtienen con cada uno de ellos, así como algunos resultados sobre estimación espectral y velocidad de computación.

A modo de resumen, en la tabla 2.2 mostramos las principales características comparadas de cada uno de los métodos que presentamos con más detalle en las siguientes secciones. Es recomendable para el lector volver a leer esta tabla una vez que se han estudiado en detalle los algoritmos presentados.

	<b>Maloney-Wandell</b>	<b>Imai-Berns</b>	<b>Shi-Healey</b>	<b>Wiener</b>	<b>Regresión (lineal o no lineal)</b>
<b>Base lineal</b>	Sí	Sí	Sí	No	No
<b>Espectros de entrenamiento</b>	Sí (para la base lineal)	Sí (para la base lineal y la matriz de inversión)	Sí (para la base lineal y comparación exhaustiva)	Sí (para la matriz de inversión)	Sí (para la matriz de inversión)
<b>Conocimiento de las sensibilidades espectrales</b>	Sí	No	Sí	Sí	No
<b>Tiempo de computación</b>	Rápido y constante con $m$	Rápido y constante con $m$	Lento y creciente con $m$	Rápido y constante con $m$	Rápido y constante con $m$

Tabla 2.2: Resumen de las principales características de cada uno de los algoritmos de estimación espectral. El parámetro  $m$  es el número de espectros de entrenamiento.

### 2.3.1. Algoritmo de Maloney-Wandell.

Este método simplemente sustituye la ecuación (2.14) en la ecuación (2.13) para obtener:

$$\rho = R^t V \epsilon = \Lambda \epsilon \tag{2.15}$$

donde se ha despreciado el efecto del ruido,  $\sigma$ , o se ha considerado que no se puede estimar (como veremos en el capítulo 3, el que este método no tenga en cuenta el ruido hace que sus estimaciones espectrales empeoren considerablemente cuando el ruido presente en el sistema es alto). La matriz  $\Lambda$  (de dimensiones  $k \times n$ ) relaciona directamente los pesos  $\varepsilon$  de la combinación lineal con las respuestas de los sensores  $\rho$ . Dicha matriz se obtiene a partir del conocimiento de las sensibilidades espectrales de la cámara y de la base de vectores representativos de los espectros de entrenamiento (en adelante, indicados mediante el subíndice  $ts$ , ‘*training set*’ en inglés) que se obtienen a partir de éstos mediante PCA, ICA o NMF, es decir:

$$\Lambda = R'V(E_{ts}) \quad (2.16)$$

Una vez calculada  $\Lambda$ , podemos obtener los coeficientes  $\varepsilon$  para la estimación espectral a partir de las respuestas de los sensores de una curva SPD desconocida, de acuerdo con (en lo sucesivo, la pseudoinversa de Moore-Penrose de una matriz la denotaremos con el superíndice +):

$$E_R = V\Lambda^+\rho \quad (2.17)$$

Según este método, la información *a priori* proporcionada por los espectros de entrenamiento está contenida en la matriz  $V$ , y por tanto también en la matriz  $\Lambda$ . Notemos que para poder aplicar la ecuación (2.17) es necesario conocer las sensibilidades espectrales de los sensores del sistema (la matriz  $R$ ), y no se hace uso alguno de la estimación del ruido, lo que hace que este algoritmo sea muy poco robusto frente a dicho ruido y que cualquier pequeño error en la estimación de  $R$  se traduzca en un error en la recuperación del espectro  $E_R$ .

### 2.3.2. Algoritmo de Imai-Berns.

F. H. Imai y R. S. Berns desarrollaron un método [Imai y Berns 1999] para recuperar reflectancias espectrales de objetos buscando una relación directa entre las respuestas de los

sensores  $\rho$  y los coeficientes de la combinación lineal  $\varepsilon$ , definidos en la ecuación (2.14). Si tenemos un conjunto de  $m$  espectros o vectores de entrenamiento, podemos relacionar ambos parámetros según:

$$\varepsilon_{ts} = G\rho_{ts} \quad (2.18)$$

siendo  $G$  una matriz  $n \times k$  que es formalmente similar a la matriz  $\Lambda$  del método de Maloney-Wandell, pero que se calcula de forma diferente ya que en esta ocasión también necesitamos información sobre las respuestas de los sensores a los espectros de entrenamiento  $\rho_{ts}$ . Como estas respuestas están afectadas por ruido, al utilizar la matriz  $G$  como veremos a continuación ya estamos teniendo en cuenta, de alguna forma, el ruido presente en el sistema. La matriz  $G$  se calcula por pseudoinversión:

$$G = \varepsilon_{ts}\rho_{ts}^+ \quad (2.19)$$

Una vez obtenida  $G$ , podemos recuperar el espectro deseado a partir de las respuestas que los sensores registran de dicho espectro:

$$E_R = VG\rho \quad (2.20)$$

De esta forma, la información sobre los espectros de entrenamiento se encuentra tanto en  $V$  como en  $G$ , que también contiene información del ruido presente en el sistema. Para probar esa afirmación no hay más que ver, a partir de las ecuaciones (2.12) y (2.18) que:

$$G = \varepsilon_{ts} \left( R^t E_{ts} + \sigma \right)^+ \quad (2.21)$$

que incluye el efecto del ruido registrado con los espectros de entrenamiento, y por tanto hace que este método sea robusto frente al ruido. Al igual que con el método de Maloney-Wandell, la calidad de la base  $V$  es crucial para obtener buenas recuperaciones espectrales.

### 2.3.3. Algoritmo de Shi-Healey.

Los algoritmos de Maloney-Wandell y de Imai-Berns han sido utilizados en multitud de trabajos de recuperación espectral de reflectancias de todo tipo de objetos [Cheung 2005, Connah 2001, Connah 2002, Hardeberg 1999, Imai y Berns 1999, López-Álvarez *et al.* 2005, López-Álvarez *et al.* 2007, Vilaseca *et al.* 2003] e incluso de iluminantes [Hernández-Andrés *et al.* 2004, Nieves *et al.* 2005]. Un resultado común en todos ellos se refiere al número  $n$  óptimo de vectores base utilizados para la recuperación de los espectros, que en todos los casos resultó ser igual al número  $k$  de sensores utilizados en el sistema. Pese a que ambos algoritmos permiten la utilización de un número de vectores mayor que el de sensores, ello implica tener que aplicar operaciones de pseudoinversión a la hora de operar con las matrices  $\Lambda$  y  $G$ , en lugar de poder utilizar inversas sencillas en el caso en que  $n = k$  [Hernández-Andrés *et al.* 2004], en el que la solución es unívoca. El resultado de utilizar la pseudoinversa de Moore-Penrose no es más que la solución de mínimos cuadrados a un problema con más incógnitas que ecuaciones que, por tanto, tiene infinitas soluciones posibles [López-Álvarez *et al.* 2007]. Esta ambigüedad en el conjunto de soluciones posibles a la hora de resolver estos algoritmos con  $n > k$ , unido al hecho de que el ruido presente en el sistema afecta más a los resultados obtenidos cuanto mayor es la dimensión de las matrices utilizadas [López-Álvarez *et al.* 2005, Shimano 2002], es lo que hace disminuir la calidad de las reconstrucciones espectrales en esos casos. Si, por desgracia, el conjunto de espectros que queremos recuperar no queda bien descrito por un número  $n$  de vectores base inferior al de sensores  $k$ , los anteriores algoritmos limitan la máxima exactitud alcanzable en las reconstrucciones espectrales a la calidad con que  $n = k$  vectores describen a dichos espectros.

Shi y Healey presentaron en 2002 [Shi y Healey 2002] un método muy original que trataba de resolver este problema y permitía utilizar más vectores que sensores en las reconstrucciones espectrales sin disminuir por ello –y como ocurría con los dos métodos anteriores– la calidad de las mismas.

Si trabajamos con un modelo lineal de representación de espectros, en el que utilizamos  $n$  vectores y  $k$  sensores siendo  $n > k$ , existirá un subespacio de espectros  $E$  (generados al variar los  $n$  parámetros  $\varepsilon$  con que son representados dichos espectros en la base) que registrarán las mismas  $k$  respuestas de los sensores  $\rho$  (de nuevo, *metamerismo de la cámara* [Hong *et al.* 2001]), siendo uno de los espectros de dicho conjunto el que se ha captado con el sistema multiespectral y que –por tanto– debemos tratar de recuperar

espectralmente con la mayor exactitud posible. Llamaremos  $S_E$  a ese conjunto o subespacio de espectros compatibles con unas respuestas dadas de los sensores y con el modelo lineal de representación en la base  $V$  de  $n$  vectores. El método de Shi-Healey tratará de elegir como solución a aquel espectro de  $S_E$  que sea el óptimo según algún criterio (se supone que la solución aportada según este criterio debe mejorar la reconstrucción espectral proporcionada por pseudoinversión, que es lo que hacían los dos métodos anteriores).

Para asociar un único vector  $E_R$ , perteneciente a  $S_E$ , a unas respuestas dadas de los sensores  $\rho$ , elegiremos aquel vector que minimice el error cuadrático medio calculado a lo largo de todos los espectros de entrenamiento  $E_{ts}$  (que es una matriz  $N \times m$ ). En otras palabras,  $E_R$  será el vector de  $S_E$  que más se parezca espectralmente a alguno de los  $m$  espectros de entrenamiento [López-Álvarez *et al.* 2007], es por ello por lo que la cantidad y calidad (parecido con los espectros que se pretenden reconstruir o estimar) de dichos espectros es crucial en este método.

Dado que el sistema multiespectral tiene  $k$  sensores, dada una dimensionalidad  $n$  para el modelo lineal, separaremos las contribuciones de los últimos  $k$  vectores (que notaremos con el subíndice 2) de las de los primeros  $n-k$  vectores restantes (subíndice 1) en la ecuación (2.15):

$$\rho = R^t (V_1 \varepsilon_1 + V_2 \varepsilon_2) \quad (2.22)$$

Donde  $V_1$  contiene los vectores base  $1, \dots, n-k$  y  $V_2$  contiene los vectores base  $n-k+1, \dots, n$ . Los vectores columna  $\varepsilon_1$  y  $\varepsilon_2$  contienen los correspondientes coeficientes para la estimación lineal. A partir de la ecuación (2.22) podemos despejar  $\varepsilon_2$  en función de  $\varepsilon_1$ :

$$\varepsilon_2 = (R^t V_2)^{-1} (\rho - R^t V_1 \varepsilon_1) \quad (2.23)$$

y si sustituimos la última relación en la ecuación (2.14) obtenemos:

$$E = V_1 \varepsilon_1 + V_2 (R^t V_2)^{-1} (\rho - R^t V_1 \varepsilon_1) \quad (2.24)$$

A partir de la ecuación (2.23), podemos construir una matriz de dimensiones  $N \times m$  (que llamaremos  $E^*$ ) de vectores columna de espectros pertenecientes a  $S_E$  para más tarde tratar de escoger aquel vector o espectro óptimo según el criterio anteriormente explicado. Para ello, buscamos una solución por pseudoinversión para calcular  $\varepsilon_1$  a partir del conocimiento de los  $m$  espectros de entrenamiento:

$$\varepsilon_1^* = \left( V_1 - V_2 (R^t V_2)^{-1} R^t V_1 \right)^+ \left( E_{ts} - V_2 (R^t V_2)^{-1} \rho^* \right) \quad (2.25)$$

donde  $E_{ts}$  es una matriz  $N \times m$  con los  $m$  espectros de entrenamiento en sus columnas,  $\rho^*$  es una matriz  $k \times m$  con las respuestas de los sensores al espectro que queremos estimar  $E$  repetidas en sus  $m$  columnas, y  $\varepsilon_1^*$  es una matriz  $(n-k) \times m$  que será la que nos genere los  $m$  espectros de  $S_E$  a partir de los cuales buscaremos la estimación espectral  $E_R$  deseada.

$$E^* = V_1 \varepsilon_1^* + V_2 (R^t V_2)^{-1} (\rho^* - R^t V_1 \varepsilon_1^*) \quad (2.26)$$

De esta forma hemos generado en la matriz  $E^*$  un conjunto de  $m$  espectros, de todos los posibles pertenecientes a  $S_E$ , uno de los cuales será la estimación espectral deseada. Como cada columna de  $E^*$  está relacionada con cada columna de  $E_{ts}$ , la estimación espectral elegida será aquella columna de  $E^*$  que cumpla la condición de mínima distancia euclídea dada por  $\|E_i^* - E_{ts_i}\| = \text{mínimo}$ , donde el índice  $i$  varía a lo largo de las  $m$  columnas de ambas matrices, es decir:

$$E_R = E_i^* \quad (2.27)$$

para aquel  $i$  que cumpla la anterior condición de mínimo.

La principal desventaja de este método reside en el hecho de que para cada vector de respuestas  $\rho$  debemos calcular  $m$  espectros y buscar el mínimo según (2.27). Si  $m$  es grande, el método es extremadamente lento, como veremos en el capítulo siguiente. También es imprescindible conocer la sensibilidad espectral  $R$  de los canales de la cámara para poder utilizar este algoritmo. Debemos notar que el algoritmo de Shi-Healey coincide con el de

Maloney-Wandell en el caso en que  $n = k$ , pues la matriz  $V_1$  sería nula y la ecuación (2.26) coincidiría con la ecuación (2.17) con una matriz  $\Lambda$  que sería cuadrada  $k \times k$ .

#### 2.3.4. Algoritmo de Wiener.

El algoritmo de estimación espectral de Wiener es de los más ampliamente utilizados por numerosos autores [Haneishi *et al.* 2000, Pratt y Mancill 1976, Shimano 2002, Shimano 2005]. Al igual que en el método de Maloney-Wandell, necesitamos conocer la sensibilidad espectral de los sensores de la cámara, y un conjunto de espectros de entrenamiento, pero no se utiliza base lineal de representación de dichos espectros, como veremos a continuación. Además, es necesario estimar de forma correcta el ruido que afecta a los sensores de la cámara, como veremos enseguida.

Partiendo de la ecuación (2.13), que repetimos a continuación por comodidad,

$$\rho = R^t E + \sigma \quad (2.13)$$

trataremos de obtener las curvas espectrales  $E$  a partir de las respuestas de la cámara  $\rho$  siguiendo un criterio de mínimo error cuadrático medio [Haneishi *et al.* 2000]. Esto se consigue aplicando un operador  $W$  a las respuestas de los sensores  $\rho$  para obtener las estimaciones espectrales  $E_R = W\rho$ , e imponiendo que

$$\langle \|E - E_R\|^2 \rangle = \langle \|E - W\rho\|^2 \rangle \text{ sea mínimo} \quad (2.28)$$

donde  $\langle \rangle$  hace referencia al promedio sobre todos los espectros de entrenamiento y  $\|\cdot\|^2$  a la norma euclídea [Shimano 2007]. Se puede demostrar [Pratt 1991] que la forma del operador  $W$ , expresado como una matriz  $N \times k$ , que cumple la condición impuesta por (2.28) es la siguiente:

$$W = E_{ts} E_{ts}^t R (R^t E_{ts} E_{ts}^t R + \sigma_{ts} \sigma_{ts}^t)^{-1} \quad (2.29)$$

donde  $E_{ts}$  es la misma matriz  $N \times m$  de la ecuación (2.25) y  $\sigma_{ts}$  es una matriz  $k \times m$  con el ruido de cada uno de los  $k$  sensores al registrar cada uno de los  $m$  espectros de entrenamiento. Está claro, a la vista de (2.29), que el producto  $\sigma_{ts} \sigma_{ts}^t$  representa la matriz de autocorrelación del ruido, y si aceptamos la suposición de que el ruido registrado para sensores diferentes en imágenes diferentes no está correlacionado, se puede sustituir la siguiente ecuación en (2.29),

$$\sigma_{ts} \sigma_{ts}^t = \sigma^2 I_k \quad (2.30)$$

donde  $\sigma^2$  es la varianza del ruido en la cámara (la suma al cuadrado de todos los valores rms de los diferentes tipos de ruido existentes, ver sección 2.2.3.b), y la matriz  $I_k$  es la identidad de dimensiones  $k \times k$ . Shimano [Shimano 2005] demostró que si el valor de  $\sigma^2$  que se introduce en la ecuación (2.30), y por tanto en la (2.29) también, es justamente el medido para la cámara en cuestión, los resultados de las reconstrucciones espectrales obtenidas con este método son óptimos. Esto significa que, para aplicar este método correctamente, se debe haber medido con exactitud el ruido que afecta a la cámara que forma el sistema multiespectral. El propio Shimano [Shimano 2005] propuso un método experimental sencillo para estimar este valor de  $\sigma^2$  óptimo que se debe introducir en (2.29) a partir del análisis de las reconstrucciones espectrales del conjunto de espectros de entrenamiento.

### 2.3.5.- Algoritmo de regresión lineal.

Este algoritmo es llamado por algunos autores [Vilaseca *et al.* 2003, López-Álvarez *et al.* 2007] como el anterior, método de estimación de Wiener, ya que la semejanza matemática entre ambos es grande. Sin embargo, la información necesaria para aplicar cada uno de ellos es claramente distinta –como veremos en breve–, así como los resultados que se obtienen al aplicar cada uno de ellos [Shimano 2007].

El algoritmo de regresión lineal es formalmente similar al de Imai-Berns, pero directamente relaciona las respuestas de los sensores  $\rho_{ts}$  a los espectros de entrenamiento  $E_{ts}$  para construir una matriz  $W_L$  de la forma [Day 2003, Nieves *et al.* 2005]:

$$W_L = E_{ts} \rho_{ts}^+ \quad (2.31)$$

La semejanza con el método de Wiener queda de manifiesto si en la ecuación (2.31) sustituimos la (2.13) y desarrollamos la operación de pseudoinversión adecuadamente [Hardeberg 1999], ya que en el caso en que  $\sigma=0$  ambos métodos coincidirían y las ecuaciones (2.31) y (2.29) serían idénticas.

Una vez que tenemos la matriz  $W_L$  obtenida a partir de los espectros de entrenamiento y sus respuestas registradas en la cámara, podemos estimar otros espectros a partir de las imágenes que nos da el sistema multiespectral:

$$E_R = W_L \rho \quad (2.32)$$

En este método no se necesita conocer la sensibilidad espectral de los sensores, como en el de Imai-Berns, y ya se incluye el efecto del ruido presente en el sistema en el cálculo de la matriz  $W_L$ . Pero a diferencia de aquél, éste algoritmo no necesita calcular ninguna base lineal  $V$  de vectores representativos de los espectros que queremos estimar. Debemos notar que, si en el algoritmo de Imai-Berns utilizamos todos los vectores de la base  $V$  disponibles, de manera que la representación de un espectro de entrenamiento en dicha base completa es - entonces- exacta,

$$V \varepsilon_{ts} = E_{ts} \quad (2.33)$$

los métodos de regresión lineal y de Imai-Berns son idénticos, como mostramos en la ecuación (2.34), que resulta de manipular la (2.19), (2.20), (2.31), (2.32) y (2.33).

$$E_R = VG\rho = V\varepsilon_{ts}\rho_{ts}^+ = E_{ts}\rho_{ts}^+ = W_L\rho \quad (2.34)$$

### 2.3.6.- Algoritmos de regresión no-lineal.

El método de estimación de regresión lineal visto en el apartado anterior, dada su sencillez matemática y su robustez frente al ruido, ha sido utilizado por multitud de autores [Shimano 2007, López-Álvarez *et al.* 2007, Vilaseca *et al.* 2003, Nieves *et al.* 2005, Stigell *et al.* 2005] para reconstruir espectros de reflectancias de objetos y de iluminantes. Se han

utilizado algunas variantes del mismo método en diversos experimentos, siendo lo más usual el tratar de combinar, en forma de polinomios de mayor o menor orden, las respuestas individuales de cada sensor para tratar de obtener mayor información de las imágenes registradas y así aumentar la precisión de las reconstrucciones obtenidas [Vilaseca *et al.* 2003, Stigell *et al.* 2005, Hong *et al.* 2001]. Un ejemplo podría ser el siguiente, para el polinomio  $1 + x + x^2$  y tres sensores (con sus posibles términos cruzados):

$$W_{NL} = E_{ts} \begin{bmatrix} 1 \\ \rho_1 \\ \rho_2 \\ \rho_3 \\ \rho_1\rho_2 \\ \rho_1\rho_3 \\ \rho_2\rho_3 \\ \rho_1^2 \\ \rho_2^2 \\ \rho_3^2 \end{bmatrix}^+ \quad (2.35)$$

En cualquier caso, los resultados no son excesivamente superiores a los conseguidos con el método de regresión lineal [Stigell *et al.* 2005], sobre todo en el caso de que se estudien curvas espectrales suaves o de baja dimensionalidad (que quedan bien descritas con pocos vectores PCA). Dichos resultados varían mucho según la aplicación concreta que se esté estudiando y –sobre todo– con el ruido presente en el sistema ya que, como se ha dicho anteriormente, al aumentar la dimensionalidad del problema (y el añadir términos polinomiales lo hace) el ruido afecta en mayor medida a la estimación espectral proporcionada por el algoritmo [Stigell *et al.* 2005].

### **3.- BÚSQUEDA DE SENSORES ÓPTIMOS PARA MEDIDAS ESPECTRALES DE LUZ-CIELO.**

#### **3.1.- Introducción al problema.**

En esta sección veremos cómo el tópico de la búsqueda de sensores óptimos se ha abierto camino dentro del campo de la investigación en sistemas multiespectrales gracias al aporte fundamental del ordenador como herramienta científica de cálculo avanzado, que permite simular el comportamiento real de un sistema multiespectral con gran exactitud, de manera fiable y rápida. Esto nos permite, en este caso, simular el efecto de utilizar diferentes sensores, pudiendo así en la práctica elegir o fabricar aquel que arroje los mejores resultados en la simulación.

#### **3.1.1.- Interés histórico por la optimización de sensores.**

Tras los trabajos de Maloney, Wandell y Marimont [Maloney y Wandell 1986, Marimont y Wandell 1992] en los que se comprobó que era posible reconstruir espectros de reflectancias con alta calidad a partir del conocimiento de un número pequeño de parámetros (los coeficientes  $\epsilon$  del desarrollo lineal visto en la ecuación (2.13)), se vio la posibilidad de obtener el valor de dichos parámetros a partir de las respuestas de un número pequeño de sensores. A finales de la década de 1990 empezaron a publicarse trabajos en los que se analizaba la influencia de la forma espectral de los sensores de una cámara en los resultados de las reconstrucciones espectrales conseguidas a partir de las respuestas de los mismos [Yokoyama *et al.* 1997, Sharma *et al.* 1998]. Estos autores hallaron que era posible diseñar un sistema multiespectral con sensores óptimos en lugar de utilizar cámaras con un gran número de ellos, obteniéndose excelentes reconstrucciones espectrales de reflectancias con no más de 8 canales (dicho número depende, claro está, del tipo de espectro que se pretenda reconstruir). Estas aportaciones abrieron todo un campo de investigación en el ámbito de los sistemas multiespectrales. Se propusieron algunas funciones (*figuras de mérito*) [Sharma *et al.* 1998] que evaluaban la calidad de un conjunto de sensores en función del tipo de espectros que se trataban y del ruido presente en el sistema, y se buscaban aquellas curvas de sensibilidad espectral que otorgaban el mejor valor de dicha función, dando como resultado muchas veces formas espectrales difícilmente obtenibles en la práctica [Hardeberg 1999].

Sin embargo, la técnica que finalmente se impuso en los estudios sobre búsqueda de sensores óptimos se centró en tratar de seleccionar el mejor conjunto, dentro de una amplia variedad de sensores disponibles (ya fuesen de banda ancha o estrecha, como se discutió en el capítulo 2), de manera que las reconstrucciones espectrales que se obtenían a partir de sus respuestas otorgasen -en promedio sobre un conjunto de espectros de entrenamiento- los mejores valores para alguna métrica espectral o colorimétrica [Yokoyama *et al.* 1997, Hardeberg 1999, Haneishi *et al.* 2000, Connah *et al.* 2001, Connah *et al.* 2002, Shimano 2002]. Pocos autores [Day 2003, Hernández-Andrés *et al.* 2004] utilizaron varias métricas en sus estudios (imponiendo sucesivos umbrales para cada métrica por separado en las iteraciones de búsqueda) a la hora de evaluar la calidad de las reconstrucciones y así obtener los sensores óptimos de acuerdo a las métricas usadas. Éste fue un paso clave, ya que -como veremos más adelante en este mismo capítulo- algunos estudios han demostrado la enorme dependencia de la forma de los sensores óptimos con la métrica utilizada para evaluar la calidad de las reconstrucciones [López-Álvarez *et al.* 2005, Connah *et al.* 2002]. Sin embargo, hasta el momento no se han estudiado las propiedades de los sensores óptimos necesarios para la reconstrucción espectral de iluminantes naturales, ni se ha tenido en cuenta que la evaluación de la calidad de dichas reconstrucciones debe realizarse con varias métricas simultáneamente en lugar de secuencialmente. Tampoco se ha comparado en un mismo estudio el efecto del ruido, o la influencia del método de estimación espectral en conjunción con la base lineal elegida o el tamaño de la misma.

### **3.1.2.- Parámetros de la simulación.**

El hecho de que las cámaras CCD, utilizadas para construir los sistemas multispectrales, cumplan en la práctica la relación teórica dada por la ecuación (2.12), permite utilizar modelos computacionales en los que es sencillo estudiar el efecto que diferentes perfiles espectrales tienen sobre la calidad final de las reconstrucciones obtenidas con dicho sistema. Esto permite obtener *a priori* la forma de los sensores óptimos que deberemos buscar para nuestro sistema, y ahorrar así dinero y tiempo de experimentación probando con diferentes sensores. Algunos autores [Hardeberg 1999, Haneishi *et al.* 2000, Day 2003, Shimano 2005] han logrado implementar en la práctica sistemas multispectrales, para diferentes propósitos, que están basados en estudios computacionales previos. En casi

todos los casos la calidad de las reconstrucciones espectrales predichas por el modelo computacional es muy similar a la alcanzada por el sistema real posteriormente implementado, siempre que se simule correctamente la influencia del ruido presente en el sistema [Shimano 2006].

En este capítulo explicaremos detalladamente cómo hemos llevado a cabo la simulación computacional de un sistema multispectral para adquisición de imágenes de luz-cielo. En dicha simulación tenemos en cuenta todos los parámetros que influyen sobre el comportamiento del sistema, para obtener así un modelo lo más realista posible del sistema práctico que implementaremos en el siguiente capítulo. Las simulaciones computacionales nos ayudarán, por tanto, a elegir o fijar los valores óptimos de dichos parámetros que nos permitan obtener curvas espectrales de luz-cielo con la máxima calidad posible [López-Álvarez *et al.* 2007]. Algunos de esos parámetros son el algoritmo de estimación espectral (capítulo 2), el número y forma espectral de los sensores, los espectros de entrenamiento, la base lineal representativa de dichos espectros (como se explicó en la ecuación (2.13)), o el tipo de cuantización llevada a cabo. Todas estas variables dependen, por supuesto, del ruido presente en el sistema.

Parámetro	Valores
Posición central del sensor en el espectro	Desde 380nm hasta 780nm, cada 5 nm
Anchura a mitad de pico (FWHM) del sensor	Desde 10nm hasta 250nm, en pasos de 5nm
Máxima sensibilidad espectral	Desde 0.5 a 1 en pasos de 0.1
Número de sensores	3, 4, 5
Niveles de ruido	40dB, 30dB, 26dB
Número de vectores base	3, 4, 5 (en algunos casos puntuales se usan más vectores)
Algoritmo de estimación espectral	Maloney-Wandell, Imai-Berns, Shi-Healey, Regresión lineal
Bases lineales	PCA, ICA, NMF
Tamaño del conjunto de entrenamiento	1567, 156, 20
Número de bits	8, 10, 12
Tipo de cuantización	Uniforme, ley $\mu$ , potencial

Tabla 3.1. Resumen de los parámetros tenidos en cuenta en la simulación del sistema multispectral.

Llevar a cabo una simulación computacional en la que se pretendan estudiar simultáneamente todos los efectos de las anteriores variables es una tarea ardua con un coste computacional muy elevado. En las siguientes secciones veremos que pretendemos encontrar

el mejor conjunto de 3, 4 y 5 sensores Gaussianos cuyas posiciones centrales puedan variar entre 380nm y 780nm cada 5nm, cuyas anchuras a mitad de pico (FWHM, del inglés '*Full Width at Half Maximum*') varíen entre 10nm y 250nm cada 5nm, con el valor máximo de la sensibilidad espectral entre 0.5 y 1 en pasos de 0.1, simulando tres situaciones de ruido diferentes (representadas por valores de la SNR de 40dB, 30dB y 26dB), utilizando en las reconstrucciones tres tamaños diferentes del conjunto de entrenamiento (1567, 156 y 20 espectros), tres bases lineales (obtenidas mediante PCA, ICA y NMF), cuatro algoritmos de estimación espectral, tres tamaños de la base lineal empleada y tres esquemas diferentes de cuantización (uniforme, ley  $\mu$  y potencial) cada uno de ellos con 8, 10 y 12 bits. En la tabla 3.1 se resumen los parámetros que variaremos en nuestras simulaciones y los valores que podrán tomar. Trataremos ahora de justificar el porqué de la elección de los valores presentados en la tabla 3.1 para las diferentes variables implicadas en la simulación. Por ejemplo, ya se dijo en el capítulo 2 que los cuatro algoritmos de estimación espectral más comúnmente utilizados en la bibliografía [Shimano *et al.* 2007, López-Álvarez *et al.* 2007, Cheung *et al.* 2005] son los que aquí compararemos, y lo mismo ocurre con los esquemas utilizados para la obtención de bases lineales (PCA, NMF e ICA). El número de vectores base y de sensores de 3 a 5 se ha elegido así porque por encima de estos números de sensores se consigue poca mejora en la calidad de las reconstrucciones espectrales de luz-cielo [Hernández-Andrés *et al.* 2004], lo que no ocurre cuando se diseñan sistemas multispectrales para otro tipo de fines [Shimano 2005, Connah *et al.* 2002, Haneishi *et al.* 2000, Vilaseca 2005]. También resulta, casi siempre, ventajoso utilizar el mismo número de vectores y sensores, como también tendremos ocasión de comprobar al final de este capítulo. Las situaciones de ruido simuladas abarcan los casos típicos de ruido presente en sistemas digitales de adquisición de imágenes [Hardeberg 1999, Day 2003, Haneishi *et al.* 2000, Shimano 2005]. Por último, los tamaños del conjunto de espectros de entrenamiento se han elegido así partiendo del total de medidas disponibles (1567) y tratando de estudiar casos con un orden de magnitud menor en cada caso (156 es el 10% y 20 el 1% del total de medidas, aproximadamente).

Para el caso de 3 sensores, si queremos llevar a cabo una búsqueda exhaustiva del mejor conjunto de sensores (probando uno a uno cada posible conjunto), deberíamos simular del orden de  $10^{16}$  experimentos de recuperación espectral diferentes, lo que implica varios días de cálculo en un PC actual. Este número se multiplica aproximadamente por  $10^4$  y  $10^9$

para el caso de 4 y 5 sensores respectivamente. Como veremos más adelante, en estos casos resulta especialmente indicada la utilización de algoritmos de '*simulated annealing*', que son capaces de obtener resultados similares a los alcanzados con búsquedas exhaustivas, pero probando un número mucho menor de conjuntos. La sección 3.2 describe en detalle este algoritmo.

Las 1567 medidas experimentales de radiancia espectral de luz-cielo que utilizamos en este capítulo como conjunto de test y de entrenamiento (del que se han extraído aleatoriamente los dos subconjuntos de 156 y 20 medidas a los que hace referencia la tabla 3.1) pertenecen a una campaña realizada por el prof. D. Javier Hernández-Andrés como parte de su tesis doctoral [Hernández-Andrés 1999]. Estas medidas se tomaron en la Facultad de Ciencias de Granada ( $37^{\circ} 11'N$ ,  $3^{\circ} 37'W$ , altitud 680 m) con elevaciones solares muy diversas, en diferentes épocas del año y siempre con cielo despejado. Cada espectro se midió entre 380 nm y 780 nm en intervalos de 5 nm. La variabilidad tanto espectral como cromática del conjunto original de 1567 medidas, así como de los dos subconjuntos de 156 y 20 medidas que se han extraído de él, queda demostrada en la figura 3.1. En ella mostramos el diagrama deromaticidad CIE-1931 y el lugar Planckiano [Hernández-Andrés 1999], y sobre ellos las coordenadas deromaticidad de cada uno de los tres conjuntos. Podemos apreciar que el intervalo de valores abarcado por estos conjuntos de medidas espectrales es bastante amplio a pesar de corresponder todas las medidas a situaciones con cielo totalmente despejado. Baste decir, igualmente, que la dimensión del conjunto de 1567 espectros (entendida ésta como el número de vectores base obtenidos mediante PCA para que el error de la representación teórica de los espectros con dichos vectores sea menor del 0.1%) es igual a 6 [Hernández-Andrés 1999].

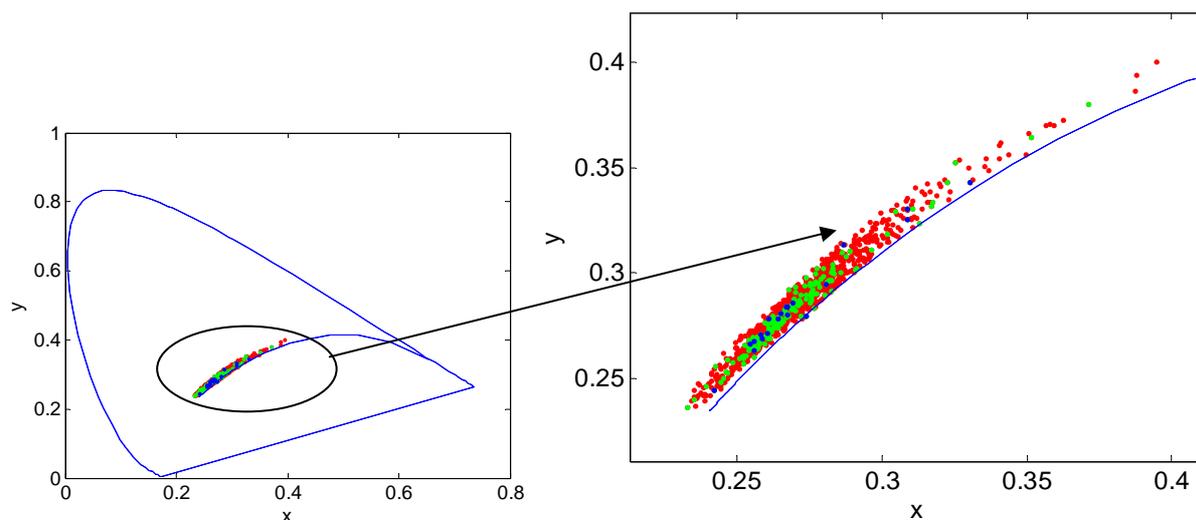


Figura 3.1: Coordenadas de cromaticidad en el espacio CIE-1931 del conjunto original de 1567 espectros de luz cielo (en rojo), y de los subconjuntos de 156 (en verde) y 20 (en azul) medidas extraídos aleatoriamente de él.

### **3.2.- Búsqueda de los sensores óptimos.**

Como ya se ha comentado unos párrafos atrás, a raíz de la tabla 3.1, la búsqueda de sensores óptimos para el diseño de un sistema multiespectral de adquisición de imágenes de luz-cielo es una tarea ardua si se pretenden simular todos los parámetros que teóricamente pueden afectar al comportamiento del mismo. Pese a la existencia de computadores cada vez más veloces y programas de cálculo científico cada vez más desarrollados, se hace necesario utilizar algoritmos que aceleren la búsqueda de dichos sensores reduciendo el tiempo de computación necesario para llevar a cabo las simulaciones que hemos presentado.

En esta sección se explicará con cierto detalle cómo se ha implementado una versión del algoritmo ‘*simulated annealing*’ para nuestro caso de búsqueda de sensores óptimos. Dado que este algoritmo persigue la minimización de una métrica o función de coste que evalúe la calidad de la solución buscada, detallaremos las cualidades de la métrica combinada espectral y colorimétrica (CSCM) que hemos propuesto para este fin [López-Álvarez *et al.* 2005b]. Finalmente, presentamos un pequeño estudio donde se muestra una comparativa entre el ‘*simulated annealing*’ y la búsqueda exhaustiva, así como entre la métrica CSCM y otras métricas conocidas en el contexto de los sistemas multiespectrales.

### 3.2.1.- El algoritmo de ‘*simulated annealing*’.

En la década de los años 50, en la que comenzaban a surgir los primeros computadores para cálculo avanzado (enormes máquinas eléctricas que apenas superaban en prestaciones a una calculadora de ingeniero actual [Prieto *et al.* 2002]), Metropolis [Metropolis *et al.* 1953] publicó un ingenioso método computacional para encontrar la mínima energía de un sistema macroscópico sin tener que evaluar la energía de todos y cada uno de los microestados posibles del sistema [Pathria 1996], compatibles con unas condiciones de contorno impuestas. El algoritmo pretende simular el comportamiento de un sistema real, que ha sido previamente calentado, y que se deja enfriar lentamente hasta alcanzar el estado de equilibrio o mínima energía que buscamos a una temperatura dada, pasando en el proceso por numerosos estados de equilibrio a temperaturas sucesivamente menores. La palabra ‘*annealing*’ significa en inglés ‘enfriamiento’. Se trata –por tanto– de situar al sistema en un estado de alta energía (elevada temperatura), elegir al azar un posible microestado de dicho sistema, evaluar la energía de ese microestado y ver si el sistema podría evolucionar hasta ese microestado, lo que puede ocurrir con una probabilidad que es proporcional a  $e^{-\frac{\Delta E}{kT}}$ , siendo  $\Delta E$  la diferencia entre la energía actual del sistema y la del microestado que estamos evaluando,  $k$  la constante de Boltzmann y  $T$  la temperatura absoluta. Entonces, si la energía del nuevo microestado es menor que la del estado actual, existe una mayor probabilidad de que el sistema evolucione hasta ese microestado que si dicha energía es mayor. Así, de la misma forma que los sistemas termodinámicos realmente cambian de estado al ir enfriándose, vamos a ir encontrando sucesivos microestados de energía cada vez menor para el sistema. A medida que, tras cada iteración, la temperatura del sistema es disminuida paulatinamente, se producen cada vez menos transiciones hacia microestados de energía mayor que la del estado actual, hasta que llega un momento en que el algoritmo converge en un microestado y no evoluciona más. En ese momento, si bien es probable que el algoritmo no arroje el microestado de mínima energía absoluta del sistema, sí que se alcanza un estado de mínima energía relativa (un mínimo local en la energía) cuyo valor es bastante cercano al de mínimo absoluto, y que –a efectos macroscópicos– resulta un microestado equivalente al buscado (el macroestado del sistema sería el mismo en ambos casos). Esto ocurre con más exactitud cuanto más lento es el enfriamiento.

En definitiva, lo que Metropolis y sus colegas propusieron es un algoritmo para encontrar el mínimo de una función (desconocida analíticamente) llamada aquí energía

$E(\Omega, T)$ , donde  $\Omega$  representa un microestado del sistema, sin tener que evaluar dicha función en todos los posibles puntos de su dominio de entrada, esto es, sin tener que realizar una búsqueda exhaustiva, lo que acelera enormemente la obtención de resultados aceptables. La aplicación de este algoritmo de búsqueda en diversas partes de la Física ha sido de lo más extensa, e incluso décadas después se han seguido publicando mejoras del mismo [Kirpatrick *et al.* 1983, Alotto *et al.* 1996]. Si se desea encontrar el mínimo de una función que se desconoce o no se desea evaluar en todo su dominio (por el elevado coste computacional), no hay más que saber traducir  $\Omega$  y  $E$  por las variables adecuadas al contexto en que se trabaje. En diversos estudios de sistemas multiespectrales se ha utilizado este método para encontrar los sensores óptimos del sistema [Haneishi *et al.* 2000, Connah *et al.* 2002], ya que en este caso es inmediato identificar  $\Omega$  con el microestado representado por los parámetros descriptivos de un conjunto de sensores dado (posición central, anchura espectral, valor de pico, etc. de todos los sensores del conjunto), y  $E$  con alguna métrica colorimétrica [Hunt 1998, Luo *et al.* 2001] (como CIELAB  $\Delta E_{ab}^*$ , CIE94, CIEDE2000) o espectral [López-Álvarez *et al.* 2005b] (RMSE ‘*Root Mean Square Error*’, GFC ‘*Goodness Fit Coefficient*’) de las comúnmente utilizadas para evaluar la calidad de las reconstrucciones espectrales obtenidas a partir de las respuestas de los sensores incluidos en  $\Omega$ .

Estudiando en detalle la figura 3.2 podemos entender mejor cómo funciona el algoritmo de ‘*simulated annealing*’. En dicha figura se representa la energía de todos y cada uno de los microestados  $\Omega$  de un sistema (etiquetados en abscisas con un número entero de manera totalmente arbitraria), y se aprecia claramente que el estado de mínima energía está en el valle señalado con un círculo en la figura. Esta estructura representada en la figura 3.2 es de tipo fractal, es decir, si ampliamos cualquier sub-zona de la gráfica, seguirá apareciendo la misma secuencia de picos en la energía entre estados vecinos. En la figura 3.3 mostramos una ampliación de la zona señalada con un círculo en la figura 3.2, y se aprecia claramente que tienen una apariencia similar.

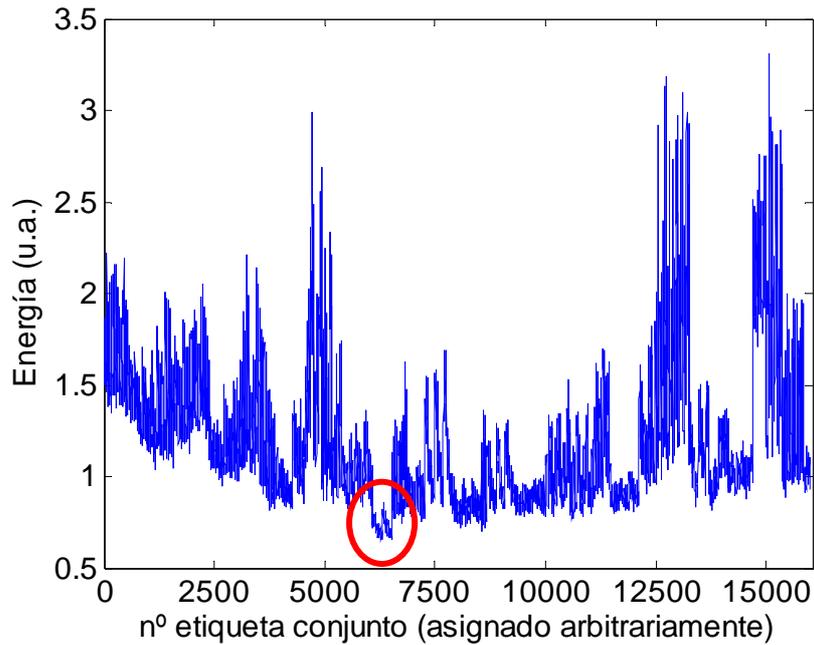


Figura 3.2: Energía de cada uno de los microestados  $\Omega$  de un sistema.

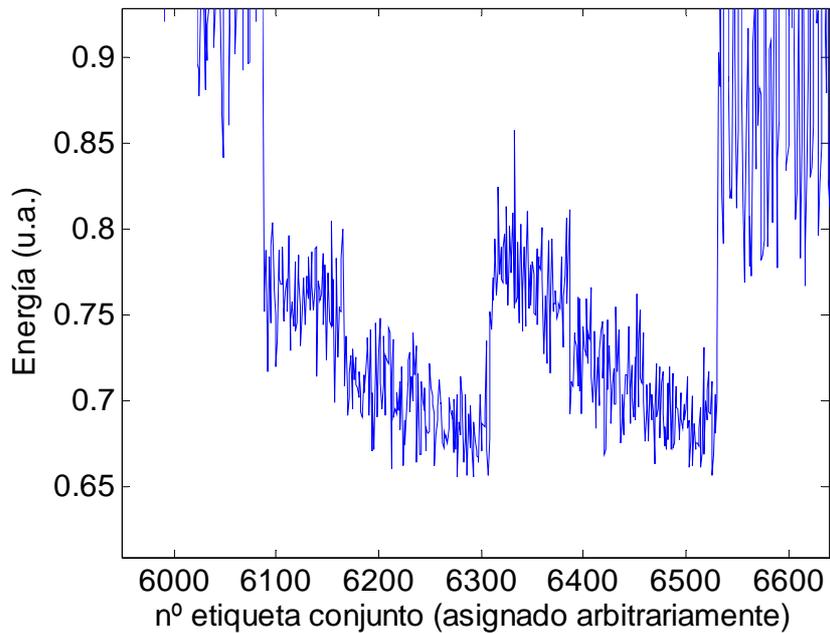


Figura 3.3: Detalle del mínimo de energía mostrado en la figura 3.2.

El algoritmo de ‘*simulated annealing*’ escoge al azar uno de los microestados, evalúa su energía y la compara con la del siguiente microestado elegido al azar. Este segundo microestado es fijado como el definitivo (hasta esa iteración) con una probabilidad proporcional a  $e^{-\frac{\Delta E}{kT}}$ , como hemos dicho anteriormente. Este ciclo se repite, a la vez que se va

disminuyendo la temperatura  $T$  en cada paso, hasta que transcurre un número razonable de iteraciones sin que el sistema cambie de microestado definitivo, alcanzando así la convergencia. La disminución paulatina de la temperatura hace que cada vez sea menos probable que el sistema ‘salte’ de un valle de energía de los mostrados en la figura 3.2 a otro valle vecino. Al presentar la energía una estructura fractal, los saltos entre valles vecinos se siguen repitiendo, cada vez con temperaturas más bajas, en estructuras de menor nivel (como la mostrada en la figura 3.2). De esta forma, la probabilidad de encontrar el estado de mínima energía, o uno con una energía muy similar, es bastante alta, y tanto más cuanto más lentamente se disminuya la temperatura en la simulación.

### 3.2.2.- La métrica combinada espectral y colorimétrica (CSCM).

La primera cuestión que se nos plantea, a la hora de intentar implementar un algoritmo de ‘*simulated annealing*’ para búsqueda de sensores óptimos, es qué métrica vamos a utilizar como función energía. Está claro que dicha métrica debe tender hacia cero en el caso de reconstrucciones espectrales perfectas, para poder equipararse a la función energía descrita en el párrafo anterior. No debemos perder de vista que el objetivo de este apartado es encontrar el conjunto de sensores  $\Omega$  que minimice una métrica (la energía) utilizada para evaluar la calidad de las reconstrucciones espectrales obtenidas con dichos sensores. La cuestión es qué métrica elegir, puesto que ésta debe ser única para poder utilizarla en el proceso de ‘*simulated annealing*’.

En el contexto de los sistemas multispectrales se utilizan, esencialmente, dos tipos de métricas: colorimétricas y espectrales [López-Álvarez *et al.* 2005, Imai *et al.* 2002]. Las métricas colorimétricas son aquellas formuladas por la CIE, como por ejemplo CIELUV  $\Delta E_{uv}^*$ , CIELAB  $\Delta E_{ab}^*$ , CIE94 o CIEDE2000 [CIE 2004, Kuehni 2003, Luo *et al.* 2001]. Estas métricas cuantifican distancias en sus respectivos espacios de color cuasi-uniformes, y tratan de aproximar las diferencias de color observadas por el sistema visual humano. Para calcular estas métricas sólo necesitamos conocer los valores triestímulo [Wyszecki y Stiles 1982] de una señal de color dada, y esto tiene una importante consecuencia: no podemos distinguir entre espectros metámeros. Por otro lado, las métricas espectrales son aquellas que miden la distancia entre dos curvas espectrales, como pueden ser el error RMSE o el coeficiente de bondad del ajuste GFC [Hernández-Andrés *et al.* 2001b, Imai *et al.* 2002, Viggiano 2004] que

mide el coseno del ángulo entre dos curvas espectrales, entendidas éstas como vectores en un espacio euclídeo. Estas métricas distinguen entre metámeros, pero no tienen en cuenta las características de la visión humana. Se han propuesto algunas otras métricas espectrales que sí tienen en cuenta estas propiedades, como la métrica WRMSE (del inglés ‘*Weighted Root Mean Square Error*’) [Imai *et al.* 2002] que es una medida del error espectral en la que se dan mayores pesos a aquellas longitudes de onda en las que el ojo humano es más sensible, o el índice de comparación espectral de Viggiano [Viggiano 2002] SCI (del inglés ‘*Spectral Comparison Index*’) como una métrica espectral que tiene en cuenta algunas características del espacio CIELAB. En el contexto de las medidas de radiación solar se usan otro tipo de métricas que tienen en cuenta la energía total integrada a lo largo del espectro visible, como la métrica IRE(%) (del inglés ‘*Integrated Radiance Error*’) [Michalsky 1985].

Como hemos dicho anteriormente, son numerosos los trabajos en los que se trata de buscar los sensores óptimos para un sistema multispectral utilizando sólo una de las métricas que acabamos de explicar [Yokoyama *et al.* 1997, Hardeberg 1999, Haneishi *et al.* 2000, Connah *et al.* 2001, Connah *et al.* 2002, Shimano 2002]. Como veremos más adelante, los resultados obtenidos al usar sólo un tipo de métrica dependen enormemente de las características de dicha métrica. Imai [Imai *et al.* 2002] sugirió que debe evitarse la ‘mononumerosis’ a la hora de evaluar la calidad de las reconstrucciones espectrales, esto es, que sería deseable usar diversas métricas para asegurar que la calidad al reconstruir una curva espectral tiene en cuenta tanto el punto de vista espectral como el colorimétrico. Como también hemos indicado ya, otros autores [Day 2003, Hernández-Andrés *et al.* 2004] sí que han intentado buscar los sensores óptimos evaluando la calidad de las reconstrucciones espectrales con dos o más métricas distintas e imponiendo sucesivos umbrales para cada una de ellas.

El problema surge al tener que utilizar una sola métrica con el algoritmo de ‘*simulated annealing*’. Parece imposible no romper las tesis de Imai y evitar la ‘mononumerosis’ en este caso. Sin embargo, podemos intentar construir una sola métrica que tenga en cuenta a la vez las características de varias métricas diferentes. En este trabajo hemos tratado de combinar una métrica espectral como el GFC, una métrica colorimétrica como puede ser CIELAB  $\Delta E_{ab}^*$ , y una métrica integrada como el IRE(%) muy utilizada para comparar espectros de iluminantes naturales.

El GFC (del inglés, ‘*Goodness Fit Coefficient*’) entre el espectro original,  $E(\lambda)$ , y el reconstruido según alguno de los algoritmos de estimación espectral,  $E_R(\lambda)$ , se calcula según la relación siguiente:

$$GFC = \frac{\left| \sum_j E(\lambda_j) E_R(\lambda_j) \right|}{\left| \sum_j [E(\lambda_j)]^2 \right|^{1/2} \left| \sum_j [E_R(\lambda_j)]^2 \right|^{1/2}} \quad (3.1)$$

que no es más que el coseno del ángulo que forman los vectores representativos de sendos espectros en el espacio euclídeo de  $N$  dimensiones que se puede utilizar para identificarlos. En la figura 3.3 podemos ver un ejemplo del significado de esta métrica.

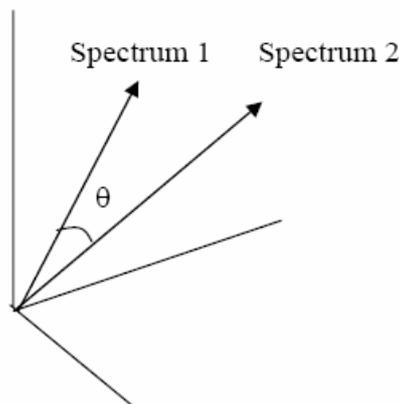


Figura 3.4: El GFC como coseno del ángulo entre los vectores representativos de dos espectros.

La distancia CIELAB  $\Delta E_{ab}^*$  entre dos espectros de luz-cielo no está propiamente definida, es decir, no es posible utilizar la definición literal de la CIE para aplicar esta fórmula de diferencia de color en este caso ya que no se pueden calcular las coordenadas  $L^* a^* b^*$  de un iluminante (sólo de una reflectancia de un objeto bajo un iluminante dado). Para solventar este inconveniente, lo que hacemos en este caso -con el fin de poder utilizar una métrica colorimétrica a la hora de comparar espectros de iluminantes naturales- es normalizar dichos espectros a su norma  $L^2$ , suponer que dichas curvas espectrales corresponden a reflectancias, y calcular así sus valores  $L^* a^* b^*$  en el supuesto de que se trabaja con el iluminante

equienergético. Siguiendo este criterio, se pueden calcular las coordenadas  $L^* a^* b^*$  y aplicar la fórmula de diferencia de color:

$$\Delta E_{ab}^* = \sqrt{(L^* - L_R^*)^2 + (a^* - a_R^*)^2 + (b^* - b_R^*)^2} \quad (3.2)$$

Por último, la IRE(%) se calcula según la relación:

$$IRE(\%) = 100 \frac{\left| \sum_{j=1}^N E(\lambda_j) - E_R(\lambda_j) \right|}{E(\lambda_j)} \quad (3.3)$$

y se puede interpretar como el área de la diferencia entre las dos curvas espectrales que estamos comparando, expresada en tanto por ciento. En la figura 3.4 se aprecia claramente su significado.

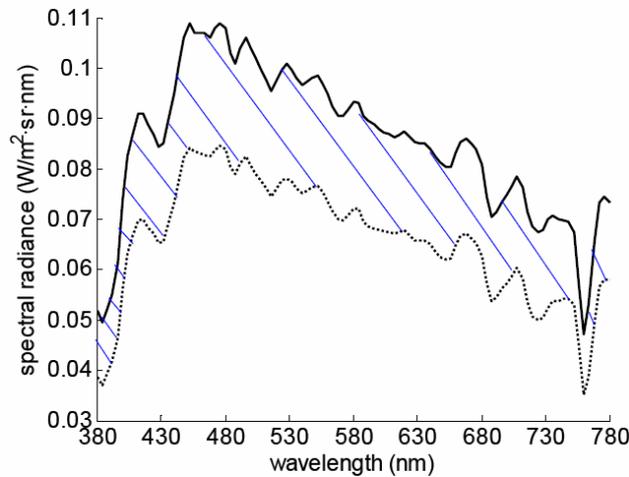


Figura 3.5: Interpretación del IRE(%)

En principio, esta nueva métrica que combine las tres que acabamos de explicar debe tender a cero en el caso de que los ajustes espectrales sean perfectos (estado de mínima energía), lo que no pasa con el GFC (que vale 1 para espectros idénticos). Al mismo tiempo, debemos intentar dar el mismo peso a los tres componentes (GFC,  $\Delta E_{ab}^*$  y IRE(%)) para que los tres puntos de vista que intentamos tener en cuenta tengan la misma importancia. Tras

analizar los casos típicos de reconstrucciones espectrales de luz-cielo con sistemas multispectrales disponibles en laboratorio, se decidió construir la métrica combinada espectral y colorimétrica CSCM (del inglés, ‘*Colorimetric and Spectral Combined Metric*’) de la siguiente forma:

$$CSCM = Ln(1 + 1000(1 - GFC)) + \Delta E_{ab}^* + IRE(\%) \quad (3.4)$$

Los pesos asignados a cada uno de los sumandos de la ecuación (3.4) no son arbitrariamente la unidad, sino que se eligieron así tras probar que de esta forma los tres sumandos daban resultados del mismo orden de magnitud en reconstrucciones espectrales de luz-cielo [López-Álvarez *et al.* 2005b], lo cual no significa que los tres sumandos estén correlacionados, pues cada uno de ellos evalúa diferentes características de similitud o diferencia entre curvas espectrales. La ecuación (3.4) define una métrica combinada que tiende a cero para ajustes perfectos entre el espectro original  $E(\lambda)$  y el reconstruido  $E_R(\lambda)$ , y por tanto cumple uno de los requisitos antes citados para ser función energía en un algoritmo de ‘*simulated annealing*’. La principal ventaja de esta métrica es que tiene en cuenta a la vez las diferencias espectrales entre metámeros, diferencias perceptuales que valoran las características del sistema visual humano, y diferencias en cantidades radiométricas como la irradiancia integrada. Al usar esta métrica no evitamos la ‘mononumerosis’, como se dijo más arriba, pero sí que combinamos en un solo valor las propiedades de varias métricas útiles en el estudio de espectros de luz-cielo.

### 3.2.3.- Utilidad del ‘*simulated annealing*’ y la métrica CSCM.

En esta sección veremos, en primer lugar, un pequeño estudio comparativo de los sensores óptimos que se obtienen al utilizar un algoritmo de ‘*simulated annealing*’ y una búsqueda exhaustiva para un caso en el que ésta última es factible. La finalidad es mostrar que los resultados obtenidos con ambos algoritmos son comparables, siendo la búsqueda exhaustiva mucho más lenta, como se detallará en breve. Más adelante mostramos la influencia de usar una u otra métrica en la búsqueda de sensores óptimos, para así mostrar que la métrica CSCM consigue, de forma aproximada, minimizar al mismo tiempo las tres métricas que la forman.

### 3.2.3.a.- ‘*Simulated annealing*’ vs. *búsqueda exhaustiva*.

Con el fin de poder comparar la velocidad del algoritmo de ‘*simulated annealing*’ con respecto a una búsqueda exhaustiva, y para ver si las soluciones aportadas por ambos algoritmos eran similares, programamos sendas opciones de búsqueda de sensores óptimos para un caso con pocos grados de libertad en el que la realización de una búsqueda exhaustiva no necesitase excesivo tiempo de cálculo. En concreto, se intentó buscar mediante ambos métodos el conjunto de 3 sensores gaussianos óptimos variando los parámetros de la tabla 3.1 excepto: el máximo de la sensibilidad espectral (que se impuso igual a 1 para todos los sensores), el algoritmo de estimación espectral (se utilizó únicamente el de Maloney-Wandell), la base lineal (sólo se utilizó PCA), el número de bits (fue 12 en todos los casos), el tamaño del conjunto de entrenamiento (1567 espectros) y el algoritmo de cuantización (uniforme en este apartado). Con estas restricciones [López-Álvarez *et al.* 2005], el experimento computacional diseñado consiste en encontrar el conjunto de sensores, de entre aproximadamente  $10^{10}$  disponibles, que arroje el mínimo valor de la métrica CSCM promediada al reconstruir los 1567 espectros de luz-cielo medidos en Granada. Esta tarea puede llevarse a cabo mediante búsqueda exhaustiva en un PC actual en tiempo de 90 horas aproximadamente, mientras que el tiempo de computación máximo para el algoritmo de ‘*simulated annealing*’ (que depende del ritmo al que se programe el paulatino descenso de la temperatura) se fijó en 12 horas para el mismo PC.

En la tabla 3.2 podemos ver los resultados de dichas simulaciones. En la mayoría de los casos el resultado alcanzado por ambos algoritmos de búsqueda fue exactamente el mismo (se muestra en **negrita** en la tabla), con una diferencia de 78 horas en el tiempo de cálculo a favor del ‘*annealing*’ (7.5 veces más rápido). En los casos en que la solución no fue la misma, se puede afirmar que la aportada por el ‘*simulated annealing*’ es bastante aceptable por dos razones: el valor encontrado para la métrica CSCM es prácticamente el mínimo hallado en la búsqueda exhaustiva, y los conjuntos de sensores óptimos encontrados son muy parecidos.

SNR	Búsqueda	Número de autovectores	Posición central del sensor óptimo (nm)			FWHM (nm)			CSCM±SD
			1er sensor	2do sensor	3er sensor	1er sensor	2do sensor	3er sensor	
40dB	Exhaustiva	3	380	465	615	250	80	210	2.4±1.1
	'Annealing'		380	460	630	180	80	120	2.4±1.1
	Exhaustiva	4	<b>380</b>	<b>465</b>	<b>635</b>	<b>280</b>	<b>70</b>	<b>190</b>	<b>2.4±1.2</b>
	'Annealing'		<b>380</b>	<b>465</b>	<b>635</b>	<b>280</b>	<b>70</b>	<b>190</b>	<b>2.4±1.2</b>
	Exhaustiva	5	<b>395</b>	<b>475</b>	<b>630</b>	<b>260</b>	<b>60</b>	<b>250</b>	<b>2.5±1.2</b>
	'Annealing'		<b>395</b>	<b>475</b>	<b>630</b>	<b>260</b>	<b>60</b>	<b>250</b>	<b>2.5±1.2</b>
30dB	Exhaustiva	3	<b>380</b>	<b>465</b>	<b>595</b>	<b>170</b>	<b>90</b>	<b>120</b>	<b>4.8±2.2</b>
	'Annealing'		<b>380</b>	<b>465</b>	<b>595</b>	<b>170</b>	<b>90</b>	<b>120</b>	<b>4.8±2.2</b>
	Exhaustiva	4	395	470	620	250	80	190	5.0±2.3
	'Annealing'		395	470	620	230	70	180	5.0±2.3
	Exhaustiva	5	<b>395</b>	<b>465</b>	<b>615</b>	<b>250</b>	<b>80</b>	<b>190</b>	<b>4.9±2.1</b>
	'Annealing'		<b>395</b>	<b>465</b>	<b>615</b>	<b>250</b>	<b>80</b>	<b>190</b>	<b>4.9±2.1</b>
26dB	Exhaustiva	3	<b>395</b>	<b>460</b>	<b>550</b>	<b>100</b>	<b>60</b>	<b>90</b>	<b>7.3±4.1</b>
	'Annealing'		<b>395</b>	<b>460</b>	<b>550</b>	<b>100</b>	<b>60</b>	<b>90</b>	<b>7.3±4.1</b>
	Exhaustiva	4	<b>385</b>	<b>460</b>	<b>605</b>	<b>200</b>	<b>70</b>	<b>150</b>	<b>7.1±3.2</b>
	'Annealing'		<b>385</b>	<b>460</b>	<b>605</b>	<b>200</b>	<b>70</b>	<b>150</b>	<b>7.1±3.2</b>
	Exhaustiva	5	395	470	605	220	70	160	6.7±3.0
	Annealing		400	465	605	200	70	160	6.9±2.8

Tabla 3.2. Comparación de la búsqueda exhaustiva y el 'simulated annealing' al recuperar los 1567 espectros de luz-cielo de Granada con los 3 sensores óptimos obtenidos en cada caso para diferentes valores de ruido. Se utilizó cuantización uniforme con 12 bits. Los casos en los que el 'annealing' y la búsqueda exhaustiva encontraron la misma solución se muestran en negrita.

### 3.2.3.b.- Comparación entre métricas.

En otra simulación similar a esta que acabamos de describir, se intentó estudiar la bondad de la métrica CSCM como función energía en el algoritmo de 'simulated annealing'. Se hicieron búsquedas, mediante dicho algoritmo, de los tres sensores óptimos para reconstruir los 1567 espectros de luz-cielo del conjunto original en condiciones análogas a las del experimento anterior, pero en esta ocasión utilizando como función energía o métrica cada uno de los sumandos (por separado) que constituyen la métrica CSCM. En la tabla 3.3 podemos ver claramente cómo tanto la forma de los sensores óptimos encontrados como los resultados estadísticos de las reconstrucciones dependen fuertemente de la métrica utilizada como función de coste, resultado que han encontrado también otros autores en experimentos de diseño de sistemas multiespectrales óptimos para reconstrucción de reflectancias de objetos [Connah *et al.* 2002, Day 2003], que han mostrado cómo el uso de métricas puramente espectrales (como el GFC o el RMSE) producen sensores óptimos equiespaciados en el espectro visible, mientras que el uso de métricas puramente colorimétricas produce

sensores óptimos muy parecidos a las sensibilidades espectrales del sistema visual humano, lo que también ha ocurrido en nuestro caso (ver figura 3.6).

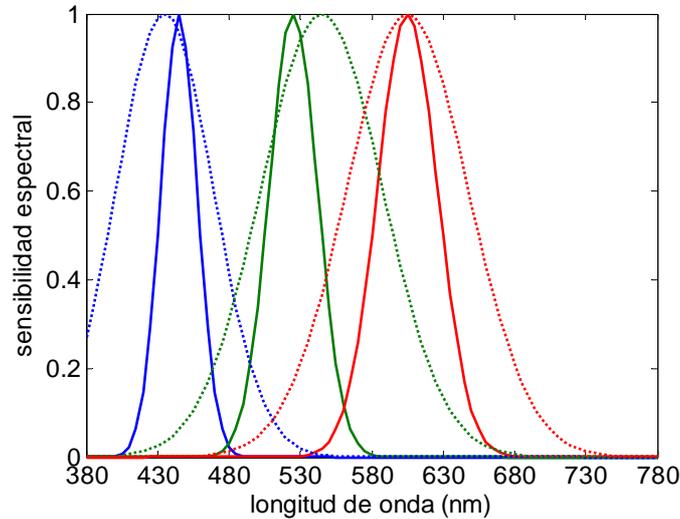


Figura 3.6: Sensores óptimos encontrados al utilizar la distancia CIELAB como función de coste (en línea continua) comparados con las sensibilidades espectrales de los fotorreceptores L, M y S de la retina humana (en línea discontinua [Hunt 1998]).

A la vista de la tabla 3.3, podemos concluir que el uso de una sola métrica como función energía en el algoritmo de ‘*simulated annealing*’ produce buenos resultados para esa métrica, pero muy pobres para las demás. Esto ocurre en particular al utilizar la distancia CIELAB  $\Delta E_{ab}^*$  como función de coste, ya que –aunque produce valores bajos para dicha métrica– el valor del resto de métricas es excesivamente alto. Al usar la métrica CSCM se consigue un equilibrio entre los valores de las diferentes métricas, como es deseable si se persigue evitar la ‘mononumerosis’.

Función energía	Posición central del sensor (nm)			FWHM (nm)			GFC ± SD	$\Delta E_{ab}^*$ ± SD	IIE(%) ± SD	CSCM ± SD
	1er sensor	2do sensor	3er sensor	1er sensor	2do sensor	3er sensor				
GFC	400	470	645	50	40	60	<b>0.9994±0.0012</b>	0.8±0.6	1.3±0.7	2.5±1.1
$\Delta E_{ab}^*$	445	525	605	30	40	50	0.9923±0.0131	<b>0.3±0.2</b>	2.3±1.6	4.3±2.3
IIE(%)	470	475	720	20	250	290	0.9972±0.0040	1.3±0.8	<b>0.7±0.5</b>	3.2±1.4
CSCM	380	460	630	180	80	120	0.9993±0.0012	0.7±0.5	1.3±0.7	<b>2.4±1.1</b>

Tabla 3.3. Comparación de los 3 sensores óptimos encontrados usando ‘*simulated annealing*’ con varias métricas como función de coste (energía). La SNR fue de 40dB en esta simulación, y se usó una cuantización uniforme de 12 bits. El mejor resultado para cada métrica se muestra en negrita, que fue cuando dicha métrica se utilizó como función de coste en el algoritmo de ‘*simulated annealing*’.

### **3.3.- Resultados de la búsqueda de sensores óptimos.**

En primer lugar mostramos, en la sección 3.3.1, la forma espectral (posición central, anchura y altura) de los sensores óptimos encontrados al variar todos los parámetros mostrados en la tabla 3.1 excepto el tipo de base lineal (que será por ahora PCA para aquellos métodos que la necesitan, como se indicó en la tabla 2.2). Nos centraremos especialmente en estudiar la dependencia de dichos sensores óptimos con el algoritmo de recuperación espectral y el ruido. Elegimos por ahora utilizar sólo PCA por ser éste el esquema de obtención de bases lineales más ampliamente utilizado en el contexto de los sistemas multiespectrales.

En la sección 3.3.2 comparamos la calidad de las reconstrucciones espectrales obtenidas con cada uno de los conjuntos de sensores óptimos presentados anteriormente, usando por ahora sólo PCA como esquema de obtención de bases lineales estadísticamente representativas del tipo de espectros que queremos recuperar. Vemos que todos los métodos de estimación espectral estudiados proporcionan, al utilizar los correspondientes sensores óptimos, buenas reconstrucciones espectrales y valores excelentes para las métricas utilizadas, incluso en presencia de ruido.

En la sección 3.3.3 estudiamos cuál es el número óptimo de vectores base PCA que debe usarse con cada método de estimación espectral en función del ruido presente en el sistema, y también presentamos un pequeño estudio comparativo entre el PCA y otros dos esquemas de obtención de bases lineales como son el ICA [Hyvärinen *et al.* 2001, Lee *et al.* 1999] y el NMF [Buchsbaum y Bloch 2002, Hoyer 2004, Lee y Seung 1999]. En esta misma sección describiremos algunas de las peculiaridades de los tres esquemas mencionados de obtención de bases lineales, pero no entraremos en detalles de cómo se calculan pues creemos que todos ellos son suficientemente conocidos y están ampliamente descritos en la bibliografía citada al efecto.

Finalmente, en la sección 3.3.4 hacemos un pequeño estudio de la velocidad de cada algoritmo de estimación espectral en función del tamaño del conjunto de espectros de entrenamiento. También comparamos en esta última sección el comportamiento de varios esquemas de cuantización con diferentes números de bits.

### 3.3.1.- Forma espectral de los sensores óptimos.

En la figura 3.7 mostramos la forma espectral de los sensores óptimos encontrados para el método de Maloney-Wandell usando vectores base PCA (ver ecuación (2.14)) y variando todos los demás parámetros de la tabla 3.1, con ayuda del algoritmo de ‘*simulated annealing*’. Debemos indicar que la forma de dichos sensores óptimos apenas depende del número de vectores PCA utilizados, del esquema de cuantización o del número de bits, ni del tamaño del conjunto de espectros de entrenamiento, lo cual es deseable a la hora de desarrollar un sistema multispectral real. Sin embargo, sí que encontramos –al igual que otros autores [López-Álvarez *et al.* 2005, Connah *et al.* 2002, Shimano 2002, Shimano 2005, Shimano 2006]– que los sensores óptimos se estrechan ligeramente conforme el nivel de ruido aumenta (o disminuye la relación señal-ruido SNR). No debe sorprendernos que las curvas también sean más estrechas y equiespaciadas en el visible conforme aumentamos el número de sensores  $k$  puesto que entonces el sistema se va aproximando a lo que hemos descrito como sistema hiperespectral de banda estrecha (ver capítulo 2). Todas estas propiedades que acabamos de comentar para el algoritmo de Maloney-Wandell se aprecian en la figura 3.7 para los casos  $m = 1567$  y cuantización uniforme con 12 bits.

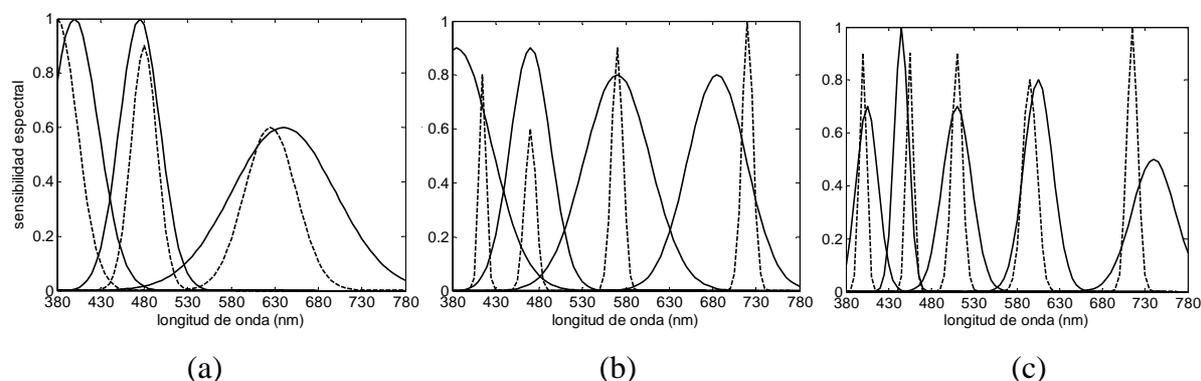


Figura 3.7: Conjuntos de (a) 3, (b) 4 y (c) 5 sensores óptimos para el algoritmo de Maloney-Wandell con  $m=1567$  espectros de entrenamiento. Se usó en cada caso el mismo número de vectores base PCA que de sensores por obtenerse así los mejores resultados. Las curvas de trazo continuo representan el caso  $SNR=40$  dB, mientras que las curvas en trazo discontinuo representan el caso  $SNR=26$  dB.

En el caso del algoritmo de Imai-Berns, utilizando vectores base PCA como acabamos de hacer con el de Maloney-Wandell, los sensores óptimos presentan un comportamiento diferente según el número de ellos,  $k$ , sea tres, cuatro o cinco (ver figura 3.8, para  $m = 1567$  espectros de entrenamiento), aunque de nuevo no hay cambios significativos en su forma espectral si cambiamos  $m$  para cada valor de  $k$ . Con cuatro sensores, al disminuir la SNR (al

aumentar el ruido) no hay ningún cambio significativo en la forma de los sensores óptimos salvo el ligero estrechamiento observado también en la figura 3.7 para el algoritmo de Maloney-Wandell. Sin embargo, con tres sensores -al aumentar el ruido- se produce un ensanchamiento notable de los sensores óptimos y un desplazamiento de algunos de ellos hacia la zona azul del espectro visible. Un aumento similar del ruido, en el caso de cinco sensores, apenas produce ningún cambio en la anchura FWHM debido a que este parámetro ya tiene un valor pequeño de por sí, pero sí que se produce un desplazamiento hacia el azul como en el caso de tres sensores.

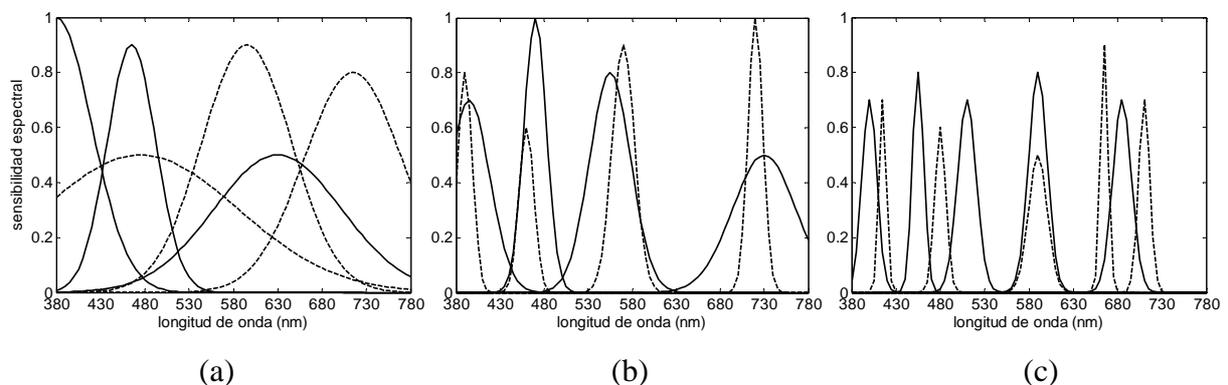


Figura 3.8. Conjuntos de (a) 3, (b) 4 y (c) 5 sensores óptimos para el algoritmo de Imai-Berns con  $m=1567$  espectros de entrenamiento. Se usó en cada caso el mismo número de vectores base PCA que de sensores por obtenerse así los mejores resultados. Las curvas de trazo continuo representan el caso  $SNR=40$  dB, mientras que las curvas en trazo discontinuo representan el caso  $SNR=26$  dB.

Algunos autores [Day 2003, Shimano 2002, Shimano 2005, Shimano 2006, Shimano *et.al.* 2007] han demostrado que la combinación óptima de sensores debe buscarse para el nivel de ruido concreto en el que trabaje la cámara digital. Esto es debido a que los sensores óptimos encontrados para bajos niveles de ruido dan resultados pésimos si el ruido real de la cámara es superior (es lo que se suele denominar como falta de ‘robustez’ frente al ruido). En otras palabras, la forma de los sensores óptimos puede cambiar de forma notable si el ruido aumenta. Podemos encontrar algunos trabajos en los que se intenta medir la robustez frente al ruido de un conjunto dado de sensores. Por ejemplo, Hardeberg [Hardeberg 1999] calculaba el ‘*condition number*’ (el cociente entre el mayor y el menor de los valores singulares de una matriz) de la matriz de transformación entre las respuestas de los sensores,  $\rho$ , y los espectros,  $E_R$ , que depende, además del conjunto de sensores, del método de estimación espectral elegido (por ello la forma de los sensores óptimos es diferente para los diferentes algoritmos de estimación espectral, como estamos comprobando en este apartado). En esta misma línea,

Shimano [Shimano 2002, Shimano 2005, Shimano 2006] calculaba los valores singulares de la matriz conocida como  $SLV\Lambda^{1/2}$ , donde  $S$  representa las sensibilidades espectrales de la cámara,  $L$  es una matriz diagonal con el iluminante,  $V$  es una matriz compuesta de los autovectores PCA de los espectros de entrenamiento y  $\Lambda$  es una matriz diagonal con los correspondientes autovalores. Estos valores singulares son mayores para los conjuntos de vectores óptimos más robustos frente al ruido, y Shimano fue capaz de demostrar teóricamente que el efecto del ruido era atenuado cuando esto ocurría. Por último, Day [Day 2003] estudió empíricamente la robustez frente al ruido de la matriz de transformación  $VG$  del método de Imai-Berns (ver ecuación (2.20)) representando cada columna de dicha matriz en función de la longitud de onda. Debemos recordar que la matriz  $VG$  del método de Imai-Berns tiene dimensiones  $N \times k$  y transforma directamente las respuestas de los sensores en curvas de distribución de potencia espectral, con lo cual cada muestra en cada longitud de onda de dicho espectro se obtiene sumando el resultado de multiplicar los coeficientes de cada fila (que dependen de la longitud de onda) por su correspondiente respuesta del sensor  $\rho_i$ . En la ecuación (3.5) se explica este proceso con mayor detalle partiendo de la ecuación (2.20).

$$E_R = \begin{pmatrix} E_{R_1} \\ \dots \\ E_{R_N} \end{pmatrix}_{N \times 1} = VG\rho = \begin{pmatrix} C_{11} & C_{21} & \dots & C_{k1} \\ C_{12} & C_{22} & \dots & C_{k2} \\ \dots & \dots & \dots & \dots \\ C_{1N} & C_{2N} & \dots & C_{kN} \end{pmatrix}_{N \times k} \begin{pmatrix} \rho_1 \\ \dots \\ \rho_k \end{pmatrix}_{k \times 1} = \begin{pmatrix} C_{11}\rho_1 + \dots + C_{k1}\rho_k \\ C_{12}\rho_1 + \dots + C_{k2}\rho_k \\ \dots \\ C_{1N}\rho_1 + \dots + C_{kN}\rho_k \end{pmatrix}_{N \times 1} \quad (3.5)$$

Está claro entonces que podríamos estudiar la robustez frente al ruido de la matriz  $VG$  estudiando la dependencia espectral de cada una de las columnas de dicha matriz de transformación. Esto fue lo que propuso Day [Day 2003]. En la figura 3.9 mostramos cómo esta transformación, para el caso de bajo ruido (SNR de 40dB) y con tres sensores óptimos (en línea continua), está compuesta de cambios pronunciados (entonces el valor absoluto de su derivada sería elevado), con lo cual cualquier pequeña diferencia en la respuesta de los sensores causada por el ruido resultaría amplificada. La transformación obtenida para alto ruido (SNR de 26dB) y tres sensores óptimos (línea discontinua) es más suave, lo que da lugar a una matriz con mayor robustez frente al ruido.

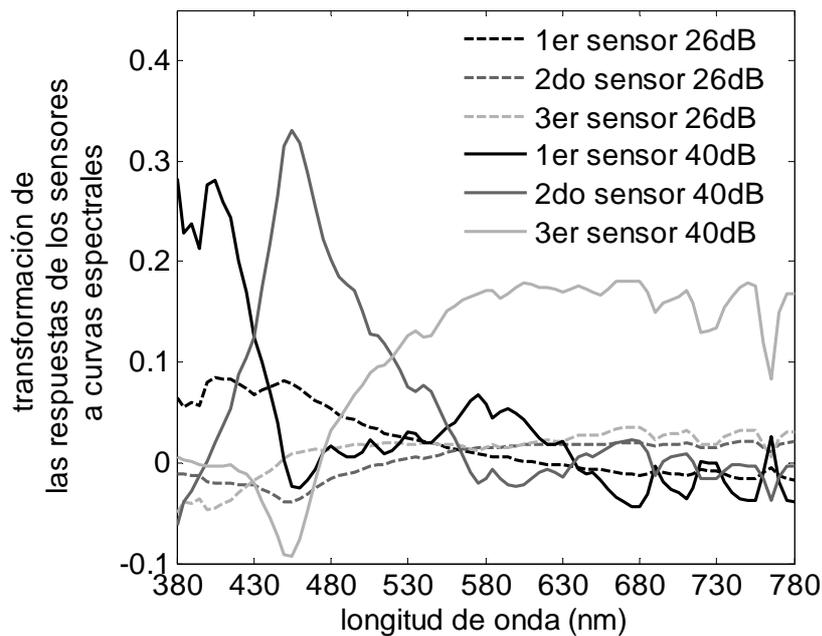


Figura 3.9: Representación gráfica de las columnas de la matriz de transformación frente a la longitud de onda para dos niveles de ruido. Las curvas corresponden a los tres sensores óptimos del método de Imai-Berns con tres vectores base PCA y  $m = 1567$  espectros de entrenamiento.

En la figura 3.10 vemos representados los sensores óptimos encontrados para el método de Shi-Healey al utilizar vectores base PCA y  $m = 1567$  espectros de entrenamiento, aunque la única dependencia significativa de estas sensibilidades espectrales óptimas al disminuir  $m$  fue un pequeño estrechamiento de las mismas (menos notable que el producido al aumentar el ruido en el sistema). Los sensores óptimos para este método son muy peculiares dado que parecen estar equidistantes entre sí en el espectro visible, y son muy estrechos, lo que indica que podrían ser fácilmente implementables usando un filtro sintonizable de cristal líquido (LCTF), como se detalla en el capítulo 5. En este método de Shi-Healey también aparece el estrechamiento de los sensores óptimos al aumentar el ruido (como en el método de Maloney-Wandell), y con cinco sensores algunos de ellos se desplazan hacia la parte azul del espectro (figura 3.10 c), como ocurriera en el método de Imai-Berns.

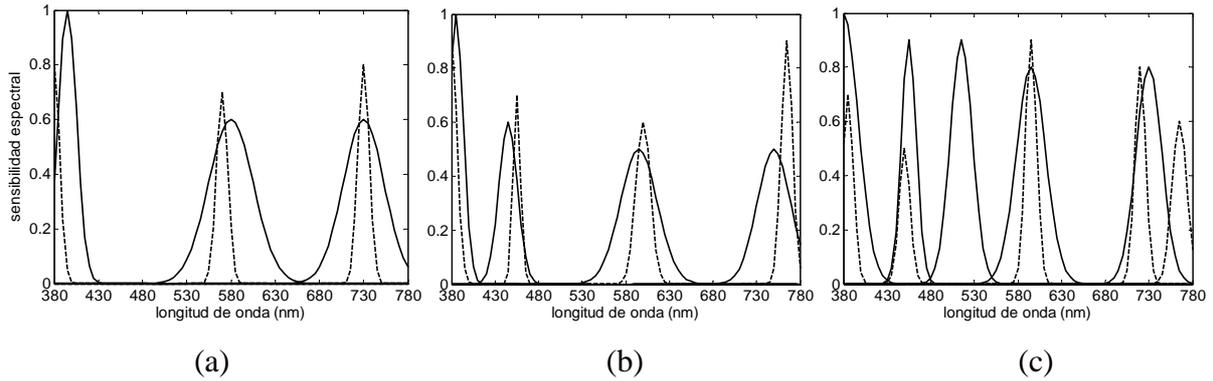


Figura 3.10: Conjuntos de (a) 3, (b) 4 y (c) 5 sensores óptimos para el algoritmo de Shi-Healey con  $m=1567$  espectros de entrenamiento. Se usaron  $n = k+2$  vectores base PCA en cada caso. Las curvas de trazo continuo representan el caso SNR=40 dB, mientras que las curvas en trazo discontinuo representan el caso SNR=26 dB

Finalmente, los sensores óptimos encontrados para el algoritmo de regresión lineal son bastante parecidos a los del método de Maloney-Wandell en todas las situaciones, aunque este método requiere de la utilización de una base lineal y del conocimiento de las sensibilidades espectrales mientras que aquel no, como ya se discutió en el capítulo 2. El estrechamiento de los sensores óptimos al aumentar el ruido vuelve a ser una característica en este caso, como vemos en la figura 3.11 para  $m = 1567$  espectros de entrenamiento, y -de nuevo- no hay importantes cambios en la forma de estos sensores al utilizar valores menores de  $m$ .

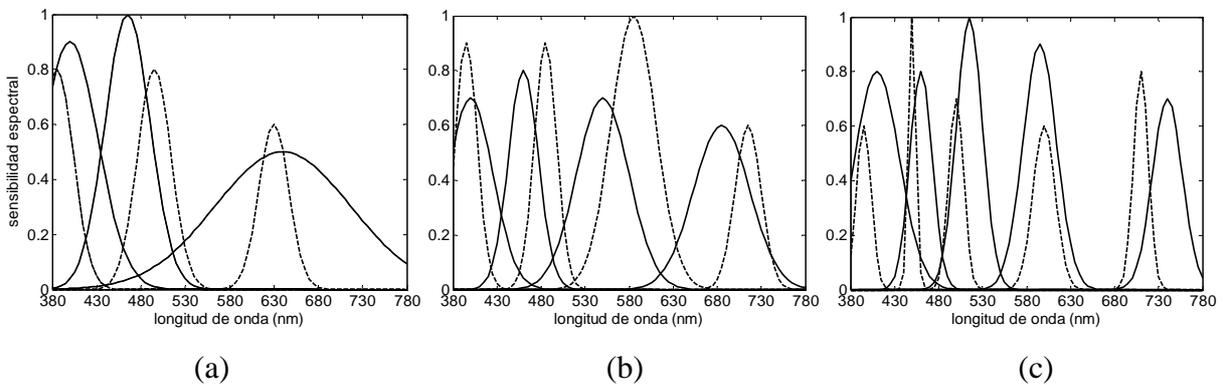


Figura 3.11: Conjuntos de (a) 3, (b) 4 y (c) 5 sensores óptimos para el algoritmo de regresión lineal con  $m=1567$  espectros de entrenamiento. Las curvas de trazo continuo representan el caso SNR=40 dB, mientras que las curvas en trazo discontinuo representan el caso SNR=26 dB.

método	sensores	métrica	40 dB			30 dB			26 dB		
			$m = 1567$	$m = 156$	$m = 20$	$m = 1567$	$m = 156$	$m = 20$	$m = 1567$	$m = 156$	$m = 20$
Maloney-Wandell	3 <sup>a</sup>	GFC	0.9994±0.0012	0.9994±0.0012	0.9993±0.0018	0.9988±0.0014	0.9986±0.0015	0.9986±0.0020	0.9978±0.0022	0.9976±0.0026	0.9979±0.0027
		$\Delta E_{ab}^*$	0.8100±0.5652	0.8253±0.5475	0.8471±0.5780	1.1128±0.6554	1.1930±0.7290	1.1729±0.6518	1.5283±0.9397	1.5020±0.8601	1.4408±0.7580
		CSCM	2.0125±1.0836	2.0887±1.1111	2.0375±1.1637	4.0604±2.1096	4.1479±2.1333	4.0540±2.1303	6.1107±3.2926	6.2546±3.3288	6.1138±3.3531
	4 <sup>a</sup>	GFC	0.9997±0.0003	0.9997±0.0003	0.9997±0.0003	<b>0.9992±0.0006</b>	0.9991±0.0006	0.9991±0.0006	0.9980±0.0016	0.9982±0.0014	0.9980±0.0015
		$\Delta E_{ab}^*$	0.6033±0.3512	0.5991±0.3445	0.5829±0.3335	0.9522±0.5032	0.9567±0.5286	0.9877±0.5482	1.3533±0.7084	1.3320±0.6958	1.3348±0.7011
		CSCM	1.4725±0.6926	1.4846±0.7046	1.4831±0.7208	3.4594±1.7657	3.4385±1.6999	3.4594±1.7007	5.4057±2.8011	5.4808±2.8623	5.4401±2.7033
	5 <sup>a</sup>	GFC	<b>0.9998±0.0001</b>	<b>0.9998±0.0001</b>	<b>0.9998±0.0001</b>	<b>0.9992±0.0006</b>	0.9991±0.0006	<b>0.9992±0.0006</b>	0.9980±0.0015	0.9980±0.0014	<b>0.9981±0.0015</b>
		$\Delta E_{ab}^*$	0.3496±0.1830	0.3397±0.1764	<b>0.3370±0.1749</b>	0.9247±0.4694	0.9183±0.4821	<b>0.9032±0.4594</b>	<b>1.3957±0.6956</b>	1.4943±0.7619	1.4447±0.7647
		CSCM	<b>1.0701±0.4956</b>	1.1235±0.5539	1.0804±0.5352	<b>3.1745±1.4771</b>	3.2934±1.6028	3.2405±1.5367	5.2575±2.4056	5.2783±2.4434	<b>5.2395±2.4878</b>
Imai-Berns	3 <sup>a</sup>	GFC	0.9993±0.0012	0.9993±0.0012	0.9993±0.0018	0.9981±0.0022	0.9982±0.0021	0.9980±0.0026	0.9972±0.0030	0.9970±0.0030	0.9972±0.0031
		$\Delta E_{ab}^*$	0.7725±0.5104	0.8484±0.5946	0.8415±0.5890	1.1219±0.6580	1.1195±0.6270	1.1848±0.6931	1.4748±0.9059	1.5389±0.9456	1.4868±0.8635
		CSCM	2.0089±1.0866	2.0685±1.1334	2.0534±1.2000	3.6348±1.8038	3.6257±1.7812	3.6670±1.8030	5.1959±2.8922	5.3481±2.8313	5.4909±2.7111
	4 <sup>a</sup>	GFC	0.9997±0.0003	0.9997±0.0003	0.9997±0.0003	0.9992±0.0006	0.9991±0.0007	0.9990±0.0007	0.9982±0.0020	0.9982±0.0014	0.9982±0.0020
		$\Delta E_{ab}^*$	0.5721±0.3276	0.5669±0.3225	0.5846±0.3209	0.9591±0.5161	0.9723±0.5077	1.0356±0.5906	1.2780±0.6927	1.4028±0.7768	1.4630±0.7856
		CSCM	1.4730±0.7046	1.4791±0.7269	1.4987±0.7289	3.4413±1.7031	3.4844±1.7002	3.5106±1.6668	5.2884±2.8253	5.4192±2.8545	5.2509±2.5917
	5 <sup>a</sup>	GFC	<b>0.9998±0.0001</b>	<b>0.9998±0.0001</b>	<b>0.9998±0.0001</b>	<b>0.9992±0.0005</b>	<b>0.9992±0.0005</b>	<b>0.9992±0.0006</b>	0.9979±0.0017	0.9982±0.0014	<b>0.9985±0.0012</b>
		$\Delta E_{ab}^*$	<b>0.3571±0.1792</b>	0.3645±0.1892	0.3816±0.2032	0.9291±0.4478	0.9319±0.4815	<b>0.9084±0.4539</b>	<b>1.4078±0.7814</b>	1.4489±0.7758	1.4400±0.7935
		CSCM	<b>1.1034±0.5340</b>	1.1365±0.5725	1.1356±0.5581	<b>3.1452±1.4183</b>	3.3012±1.6668	3.2431±1.5515	5.1244±2.4092	5.1662±2.4734	<b>5.1072±2.5020</b>
Shi-Healey	3 <sup>b</sup>	GFC	0.9997±0.0003	0.9996±0.0005	0.9987±0.0017	0.9991±0.0010	0.9990±0.0016	0.9988±0.0023	0.9981±0.0020	0.9981±0.0021	0.9981±0.0028
		$\Delta E_{ab}^*$	0.5730±0.4611	0.6967±0.5384	0.6316±0.4208	<b>0.8832±0.4889</b>	0.8890±0.4967	1.1735±0.8138	1.3389±0.7019	1.3161±0.7102	1.4832±0.9410
		CSCM	1.1727±0.7586	1.4901±1.0324	2.0429±1.0811	2.5490±1.4844	2.6150±1.5585	3.0210±1.6681	3.8812±2.1784	3.8049±2.0534	3.9562±2.0785
	4 <sup>b</sup>	GFC	0.9998±0.0001	0.9998±0.0004	0.9997±0.0013	0.9992±0.0006	0.9992±0.0007	0.9990±0.0023	<b>0.9984±0.0011</b>	0.9983±0.0013	0.9981±0.0027
		$\Delta E_{ab}^*$	0.3669±0.2180	0.4456±0.3094	0.5420±0.4360	0.8840±0.4819	0.8894±0.4970	0.8991±0.5929	<b>1.3024±0.6822</b>	1.3096±0.7299	1.3241±0.7802
		CSCM	0.9346±0.4894	1.0987±0.7234	1.5045±1.3626	2.4704±1.2324	2.5011±1.2186	2.6105±1.3912	<b>3.6070±1.7733</b>	3.6710±1.8168	3.8736±2.0198
	5 <sup>b</sup>	GFC	<b>0.9999±0.0001</b>	0.9998±0.0005	0.9997±0.0009	<b>0.9993±0.0005</b>	0.9992±0.0005	0.9988±0.0025	0.9981±0.0013	0.9982±0.0011	0.9970±0.0024
		$\Delta E_{ab}^*$	<b>0.3615±0.1983</b>	0.3791±0.2046	0.4646±0.2711	<b>0.9109±0.5045</b>	0.9337±0.5440	1.0216±0.5914	1.3725±0.7638	1.3308±0.7277	1.5407±0.8005
		CSCM	<b>0.8575±0.4171</b>	1.0537±0.6105	1.3610±0.7250	<b>2.2915±1.0790</b>	2.4337±1.1714	3.0265±1.4449	3.9762±1.8952	3.9648±1.8174	4.7803±2.1479
Regresión lineal	3	GFC	0.9994±0.0012	0.9993±0.0012	0.9992±0.0018	0.9985±0.0013	0.9985±0.0014	0.9985±0.0017	0.9973±0.0021	0.9974±0.0025	0.9977±0.0027
		$\Delta E_{ab}^*$	0.7873±0.5240	0.7740±0.5051	0.8757±0.5760	1.1093±0.6222	1.0559±0.5711	1.0172±0.5413	1.6387±0.9101	1.4439±0.7997	1.4872±0.7656
		CSCM	1.9882±1.0422	2.0499±1.1038	2.1259±1.1779	3.9327±1.8896	3.8940±1.8102	3.8921±1.9276	5.9300±2.7607	6.0421±3.1725	5.9929±3.2187
	4	GFC	0.9997±0.0003	0.9997±0.0003	0.9997±0.0003	0.9992±0.0006	0.9992±0.0006	0.9992±0.0006	0.9980±0.0016	<b>0.9982±0.0013</b>	<b>0.9982±0.0014</b>
		$\Delta E_{ab}^*$	0.5683±0.3159	0.5717±0.3251	0.5735±0.3181	0.9542±0.5096	0.9592±0.5014	0.9657±0.5169	1.4628±0.8502	1.3707±0.7364	<b>1.3288±0.7035</b>
		CSCM	1.4539±0.6839	1.4604±0.7041	1.4537±0.6898	3.4429±1.7070	3.4186±1.7301	3.3701±1.6212	5.3745±2.6812	5.3681±2.7878	5.3167±2.6276
	5	GFC	<b>0.9998±0.0001</b>	<b>0.9998±0.0001</b>	<b>0.9998±0.0001</b>	<b>0.9993±0.0006</b>	<b>0.9993±0.0005</b>	<b>0.9993±0.0006</b>	0.9980±0.0014	0.9981±0.0014	<b>0.9982±0.0012</b>
		$\Delta E_{ab}^*$	<b>0.3446±0.1795</b>	0.3661±0.1967	0.3626±0.1935	<b>0.8302±0.4275</b>	0.8813±0.4377	0.8884±0.4614	1.4010±0.7082	1.4392±0.7196	1.3577±0.6695
		CSCM	1.0983±0.5165	<b>1.0928±0.5311</b>	1.1181±0.5445	3.1439±1.6343	3.1311±1.5465	<b>3.0790±1.5236</b>	<b>5.0855±2.5114</b>	5.3258±2.5206	5.1500±2.4326

Tabla 3.4. Valores medios±desviaciones estándar -para varias métricas, situaciones de ruido y tamaño del conjunto de entrenamiento  $m$ - al recuperar el conjunto completo de 1567 espectros de luz-cielo usando los sensores óptimos encontrados en cada caso. Se usaron 12 bits para la cuantización. Los mejores resultados para cada métrica dentro de cada método y situación de ruido se muestran en negrita. <sup>a</sup>Igual número de vectores base PCA que de sensores. <sup>b</sup>Se usaron  $n = k + 2$  vectores base PCA.

### 3.3.2.- Calidad de las reconstrucciones espectrales.

En la tabla 3.4 mostramos los valores de las métricas GFC, CIELAB  $\Delta E_{ab}^*$  y CSCM obtenidos en las reconstrucciones espectrales del conjunto completo de 1567 espectros de luz-cielo, usados como test en todas las simulaciones, con los cuatro algoritmos de estimación espectral vistos en el capítulo 2 y usando los sensores óptimos correspondientes a cada caso. Se ha usado cuantización uniforme con 12 bits en toda la sección. Para los algoritmos de Maloney-Wandell y de Imai-Berns se usó el mismo número de vectores PCA que de sensores, ya que de esta forma se obtenían los mejores valores para las métricas evaluadas, como veremos más tarde y como ya han encontrado otros autores independientemente [López-Álvarez 2005, Maloney y Wandell 1986, Connah *et.al.* 2002, Imai y Berns 1999, Shi y Healey 2002, Cheung *et.al.* 2005]. Dado que el método de Shi-Healey está diseñado para trabajar con una dimensión mayor, se deben usar más vectores base que sensores (en este caso mostramos los resultados para el caso  $n = k + 2$  que es el óptimo en casi todas las ocasiones, como también estudiaremos posteriormente). El algoritmo de regresión lineal, recordemos, no necesita usar vectores base. En cada fila de la tabla 3.4 se presentan los resultados de las métricas mencionadas para los diferentes números de sensores utilizados, mientras que en columnas se muestran los tres casos simulados de ruido y la dependencia con el número de espectros de entrenamiento  $m$ .

Podemos ver, para el método de Maloney-Wandell, cómo al aumentar el número de sensores de tres a cinco los valores de las métricas estudiadas mejoran en todas las situaciones de ruido. Sin embargo, con valores bajos de la SNR la mejora obtenida al aumentar el número de sensores,  $k$ , es menor al pasar de cuatro a cinco sensores óptimos que al pasar de tres a cuatro. Esta misma tendencia al aumentar  $k$  aparece en el método de Imai-Berns, como también podemos ver en la tabla 3.4 (la justificación a este fenómeno reside en el hecho de que la dimensión del conjunto de medidas experimentales es reducida, como se comentó anteriormente, y cuando el número de sensores,  $k$ , se acerca a dicho límite la mejora aportada por los nuevos sensores es menor que el efecto del ruido que introducen en el algoritmo de estimación espectral [Shimano 2005, López-Álvarez *et al.* 2005, López-Álvarez *et al.* 2007]). Este último método arroja mejores resultados que el de Maloney-Wandell cuando el ruido aumenta, de manera más notable para el caso de tres sensores. El método de Imai-Berns tiene la ventaja adicional de no necesitar conocer las sensibilidades espectrales de la cámara para poder aplicarlo, lo que usualmente es una tarea ardua y en la que pueden aparecer errores sistemáticos que den lugar a empeorar aún más la calidad de las reconstrucciones espectrales

con aquellos métodos que precisen de ellas (como el de Maloney-Wandell o el de Shi-Healey). Tanto en el método de Maloney-Wandell como en el de Imai-Berns, el valor de  $m$  tiene poca relevancia sobre los resultados (al igual que ocurría en la forma espectral de los sensores óptimos). Hemos podido comprobar [López-Álvarez *et.al.* 2005] que, para el método de Maloney-Wandell, los sensores óptimos encontrados al usar los 1567 espectros de entrenamiento medidos en Granada proporcionaban buenos resultados en la recuperación de 240 espectros de luz-cielo medidos en Owings (Maryland, EE.UU.) en colaboración con el Prof. Raymond L. Lee Jr. Dicho conjunto de medidas experimentales también presenta un amplio intervalo de valores de cromaticidad y recoge incluso medidas de luz-cielo en días parcialmente cubiertos. En la tabla 3.4 se aprecian los mismos resultados para los diferentes valores de  $m$ , excepto para el método de Shi-Healey, lo que demuestra la bondad de los resultados incluso para espectros no incluidos en el conjunto de entrenamiento y, por tanto, para espectros que podrían estar medidos en otro lugar.

Los resultados referidos al método de Shi-Healey se muestran también en la tabla 3.4 para un número de vectores base PCA de  $n = k + 2$ . Este método proporciona las mejores reconstrucciones espectrales de luz-cielo comparado con los otros tres métodos estudiados, pero, sin embargo, es extremadamente lento en el cálculo, como veremos más adelante. Debido a que realiza una comparación espectro a espectro con todos los del conjunto de entrenamiento, como se explicó en el capítulo 2, siempre es mejor usar el mayor conjunto de espectros posible, mientras que con los otros métodos los resultados obtenidos apenas varían con el valor de  $m$ . También podemos ver que, para el método de Shi-Healey, un aumento en el número de sensores,  $k$ , no proporciona mejores reconstrucciones espectrales cuando el ruido presente en el sistema es alto (SNR baja), resultado también encontrado por otros autores y utilizando otros métodos de reconstrucción [López-Álvarez *et.al.* 2005, Shimano 2005, Connah *et.al.* 2001]. Este hecho se puede comprender fácilmente viendo cómo, en simulaciones sin ruido añadido [Hernández-Andrés *et.al.* 2004, Shimano 2004], la mejora obtenida al aumentar el número de sensores,  $k$ , del sistema multiespectral es despreciable si  $k$  alcanza un cierto valor que depende del tipo de espectro que se quiera recuperar y de las características electrónicas del sistema multiespectral concreto que se esté diseñando, pero que normalmente queda comprendido entre cuatro y siete en el caso de reflectancias [Shimano 2005, Connah *et.al.* 2001]. Por tanto, al añadir ruido a la respuesta individual de cada sensor, y aumentar el número de estos por encima de ese límite en el que los resultados sin ruido no mejoran, el efecto del ruido total (formado por el que aporta cada sensor) hace que los resultados empeoren en lugar de mejorar al aumentar el número de sensores.

Por último, respecto al método de regresión lineal, en la tabla 3.4 se aprecia que produce resultados ligeramente mejores que los métodos de Maloney-Wandell o Imai-Berns en prácticamente todas las situaciones simuladas. Este método tiene la ventaja adicional de no tener que calcular ninguna base lineal de vectores representativos de los espectros, ni de conocer las sensibilidades espectrales de los sensores de la cámara  $R$ . El comportamiento de este método de regresión lineal cuando el ruido aumenta es el mismo que el encontrado para el método de Maloney-Wandell y -por tanto- la discusión anteriormente presentada para ese método es válida ahora también. También vemos poca dependencia en los resultados con este último método frente al tamaño del conjunto de espectros de entrenamiento,  $m$ .

En la figura 3.12 mostramos un ejemplo de espectro de luz-cielo reconstruido usando los respectivos cinco sensores óptimos encontrados con cada uno de los cuatro métodos estudiados aquí, para un valor de  $m=156$ , una SNR de 30dB y cuantización con 12 bits. También se representa en la misma figura, para cada método, el doble del error espectral respecto a la curva original. El ejemplo de espectro reconstruido en dicha figura es el percentil 95 para la métrica CSCM y el método de Maloney-Wandell (usando también cinco vectores base PCA). Elegimos esta curva en particular porque el método de Maloney-Wandell es el que arroja el valor más alto (el peor) para el mejor promedio de la métrica CSCM (ver tabla 3.4). En la construcción de la figura 3.12 se usaron cinco vectores base PCA para los métodos de Maloney-Wandell y de Imai-Berns, mientras que se usaron seis vectores base PCA para el método de Shi-Healey dado que, como veremos más adelante, con estos números de vectores se obtienen los mejores resultados. Podemos ver en la figura 3.12 que todas las curvas espectrales reconstruidas en estas simulaciones a partir de las respuestas de cinco sensores óptimos son muy fieles a la curva original medida con el espectrorradiómetro, especialmente aquellas aportadas por los métodos de Shi-Healey y regresión lineal. En concreto, podemos ver cómo todas ellas conservan las bandas de absorción típicas de los espectros de luz-cielo. Podemos confiar, por tanto, en que todos los métodos estudiados proporcionan reconstrucciones espectrales de gran calidad para la luz-cielo, utilizando los sensores óptimos para el sistema multiespectral simulado.

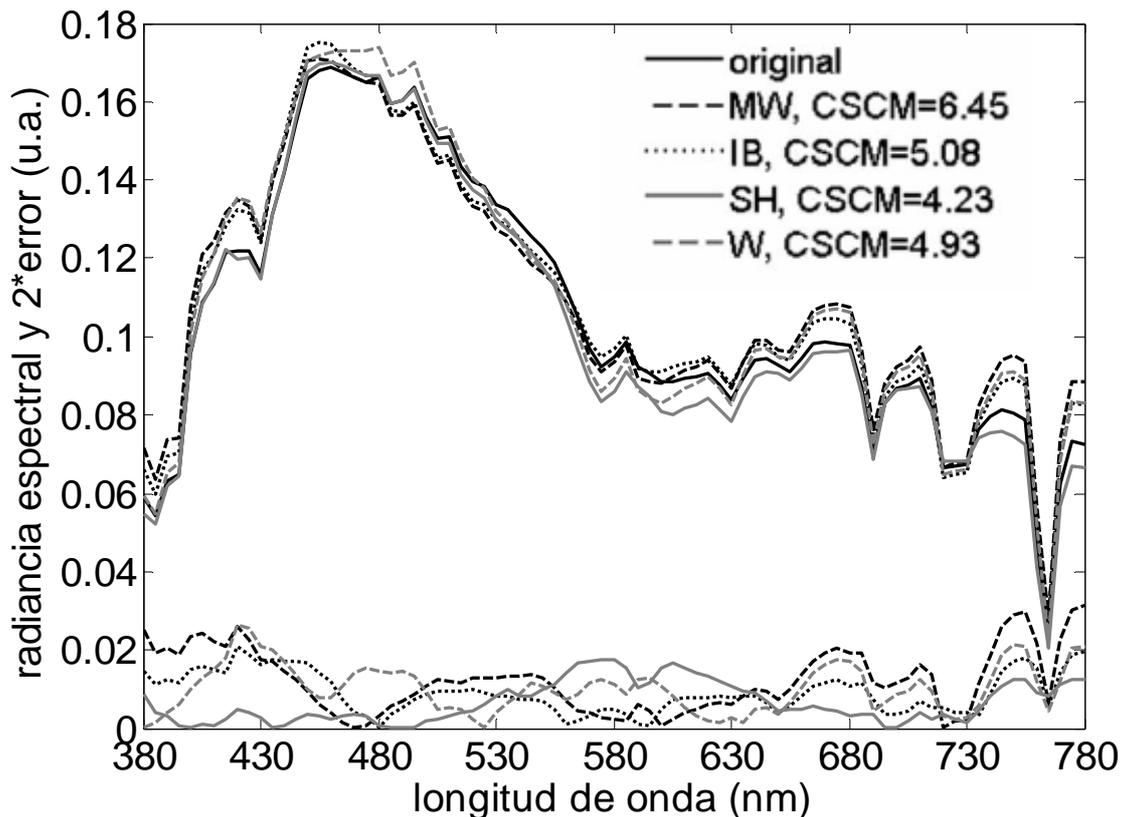


Figura 3.12: Se muestra la radiancia espectral y el doble del error espectral para el percentil 95 de la métrica CSCM y el método de Maloney-Wandell. Dicha curva es reconstruida a partir de las respuestas de los correspondientes sensores óptimos encontrados para cada uno de los cuatro métodos estudiados (MW, Maloney-Wandell; IB, Imai-Berns; SH, Shi-Healey; W, regresión lineal). Se usaron cinco sensores, SNR de 30dB, 12 bits en la cuantización y  $m = 156$ . También se usaron cinco vectores base PCA para los métodos de Maloney-Wandell e Imai-Berns, mientras que se usaron seis vectores base PCA para el método de Shi-Healey.

### 3.3.3.- Vectores base.

En esta sección estudiamos el número óptimo de vectores base PCA,  $n$ , que se deben usar con cada método de reconstrucción (excepto el método de regresión lineal que no necesita utilizar base alguna) en función del número de sensores,  $k$ , y del ruido presente en el sistema. Estudiaremos los casos  $k = 3, 4, 5$  como venimos haciendo en las secciones anteriores, mientras que  $n$  tomará los valores  $n = 3, 4, 5$  para los métodos de Maloney-Wandell y de Imai-Berns, mientras que valdrá  $n = 4, \dots, 8$  para el método de Shi-Healey. Con estos valores es suficiente para mostrar la dependencia que queremos. En la figura 3.13 mostramos el valor medio, sobre el conjunto completo de 1567 espectros de luz-cielo como conjunto de test, de la métrica CSCM en función de  $k - n$ , la diferencia entre el número de sensores y el número de vectores base utilizados. Los valores de la métrica CSCM mostrados en la figura 3.13 se obtuvieron tras calcular todas las reconstrucciones espectrales del conjunto de test usando los sensores óptimos encontrados en cada caso, utilizando  $m = 156$  espectros de

entrenamiento y en las tres situaciones ya descritas de ruido añadido. Se puede comprobar cómo con los métodos de Maloney-Wandell y de Imai-Berns, los valores más bajos para la métrica CSCM se obtienen casi siempre que  $n = k$ , particularmente cuando el ruido presente en el sistema es bajo. Para el método de Shi-Healey, el aumentar el número de vectores,  $n$ , por encima del número de sensores,  $k$ , mejora los resultados hasta un cierto límite, que suele ser  $n = 7$  para altas SNR y  $n = 6$  cuando el ruido aumenta, independientemente del número de sensores usados. También puede verse en la figura 3.13 que, con el método de Shi-Healey, un aumento en el número de sensores no mejora el valor de la métrica CSCM cuando el ruido es alto (baja SNR), dado que los valores de dicha métrica con cuatro o cinco sensores son peores que los obtenidos con sólo tres sensores, como ya discutimos en la sección 3.3.2.

También hemos realizado un pequeño estudio comparativo entre la calidad de las reconstrucciones obtenidas al utilizar otro tipo de bases lineales, como las proporcionadas por ICA [Hyvärinen *et al.* 2001, Lee *et al.* 1999] (del inglés, ‘*Independent Component Analysis*’) y NMF [Buchsbaum y Bloch 2002, Hoyer 2004, Lee y Seung 1999] (del inglés, ‘*Non-negative Matrix Factorization*’), para el caso de 3 sensores ( $k = 3$ ). En la figura 3.14 mostramos la forma espectral de los tres sensores óptimos obtenidos con cada uno de los tres métodos de recuperación espectral que utilizan bases lineales, al utilizar las bases correspondientes a PCA, NMF e ICA con una SNR de 30dB, y con un tamaño del conjunto de espectros de entrenamiento  $m = 156$ . Utilizamos  $n = 3$  vectores base NMF y PCA para los métodos de Maloney-Wandell y de Imai-Berns, y  $n = 5$  vectores de este tipo para el método de Shi-Healey, dado que los resultados obtenidos al utilizar los vectores proporcionados por el NMF y el PCA -como veremos- son muy parecidos. En el caso de vectores base ICA debemos utilizar un número mayor de los mismos para poder estudiar la dependencia de los resultados con  $n$ , ya que las reconstrucciones mejoran notablemente si usamos valores más altos de  $n$ , como veremos a continuación al compararlos con los casos de PCA y NMF. En la tabla 3.5 mostramos algunos resultados numéricos de todas estas simulaciones comentadas. La figura 3.14 está dibujada para  $n = 9$  en el caso de vectores base ICA, aunque se pudo comprobar que la forma de los sensores óptimos es prácticamente la misma para cualquier valor de  $n$ .

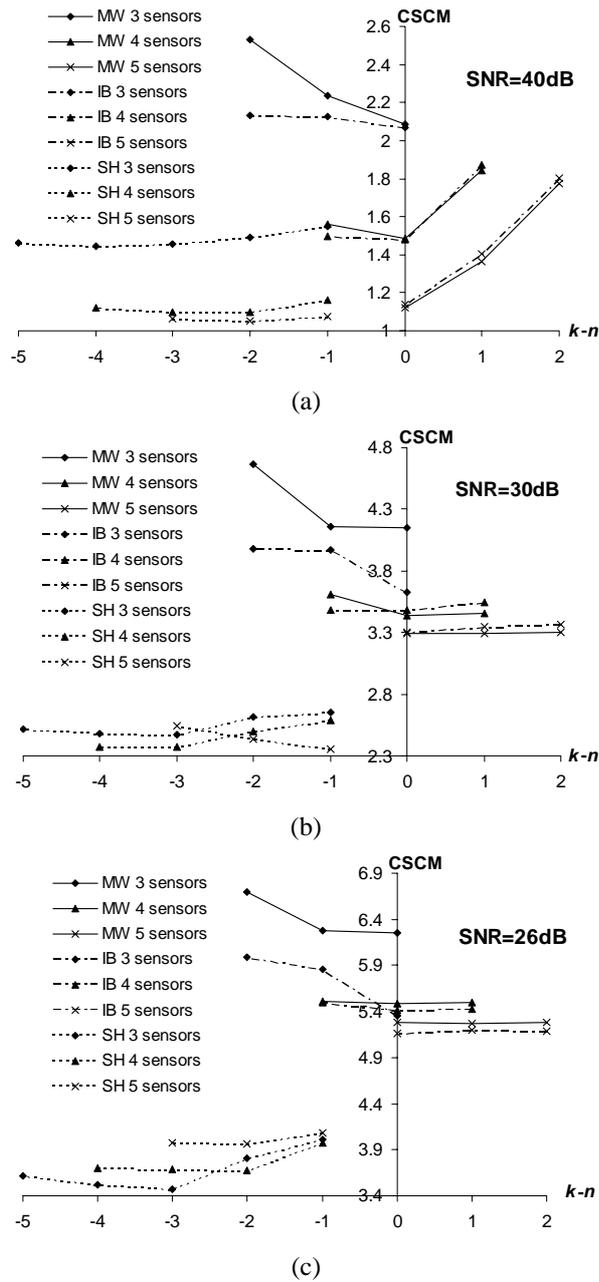


Figura 3.13: Valores medios para la métrica CSCM cuando se reconstruye el conjunto completo de 1567 espectros de luz-cielo con los sensores óptimos para  $m = 156$  y con diferentes números de vectores base PCA con los tres métodos que utilizan bases lineales (MW, Maloney-Wandell; IB, Imai-Berns; SH, Shi-Healey). Se usó cuantización uniforme con 12 bits. (a) SNR = 40dB, (b) SNR = 30dB, (c) SNR = 26dB. Nótese la diferencia de escala en el eje vertical en cada caso.

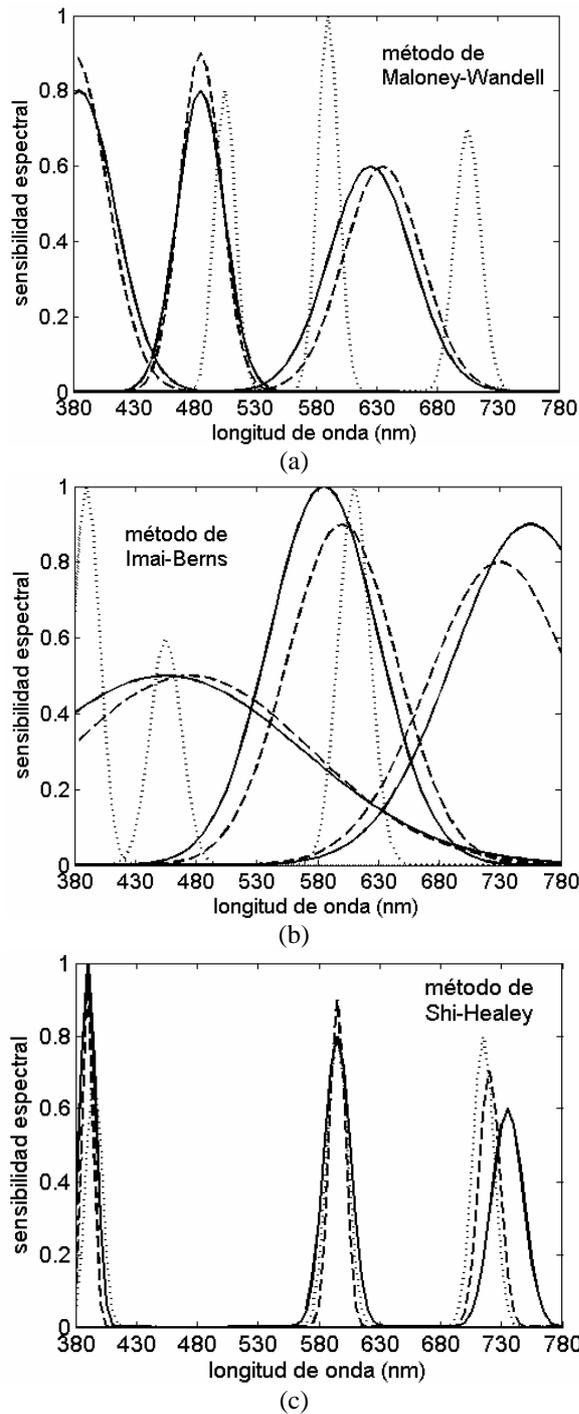


Figura 3.14: Tres sensores óptimos para los métodos de (a) Maloney-Wandell, (b) Imai-Berns y (c) Shi-Healey con  $m = 156$  espectros de entrenamiento, una SNR de 30dB y 12 bits para la cuantización uniforme. En (a) y (b) las curvas en línea continua denotan el caso de tres vectores base PCA, mientras que las curvas discontinuas son para el caso con tres vectores base NMF. En (c) la curva continua es para cinco vectores base PCA, mientras que la curva en línea discontinua es para cinco vectores base NMF. Las curvas de puntos se refieren al caso de nueve vectores base ICA en las tres subfiguras.

método	base lineal	$n$	GFC	$\Delta E_{ab}^*$	CSCM
<b>Maloney-Wandell</b>	PCA	3	0.9986±0.0015	1.1930±0.7290	4.1479±2.1333
	NMF	3	0.9986±0.0013	1.2389±0.6804	4.0643±2.1118
	ICA	3	0.9984±0.0015	1.0861±0.6449	3.1473±1.4617
		6	0.9990±0.0025	1.0174±0.6905	2.6387±1.8315
		9	0.9990±0.0027	1.0125±0.7166	2.6255±1.9525
		12	0.9990±0.0019	0.9935±0.6471	2.6249±1.8808
<b>Imai-Berns</b>	PCA	3	0.9982±0.0021	1.1195±0.6270	3.6257±1.7812
	NMF	3	0.9982±0.0019	1.2389±0.7691	3.7764±1.9498
	ICA	3	0.9949±0.0119	1.6535±1.5041	5.1594±3.4341
		5	0.9965±0.0082	1.3930±1.2161	4.2487±2.7396
		9	0.9971±0.0048	1.0853±0.7866	3.6178±2.1217
		15	0.9982±0.0035	0.9473±0.6240	3.0226±1.8637
		18	0.9983±0.0033	0.8998±0.5769	2.8879±1.8294
		21	0.9986±0.0029	0.9116±0.5551	2.7692±1.7772
		24	0.9987±0.0026	0.9135±0.5443	2.6930±1.6982
<b>Shi-Healey</b>	PCA	5	0.9990±0.0016	0.8890±0.4967	2.6150±1.5585
	NMF	5	0.9990±0.0010	0.9723±0.6065	2.6697±1.4481
	ICA	5	0.9991±0.0010	1.0498±0.6831	2.6955±1.5323
		6	0.9991±0.0012	1.0334±0.6865	2.5142±1.4284
		9	0.9989±0.0021	1.0210±0.7334	2.4980±1.5535
		12	0.9990±0.0013	1.0401±0.6970	2.4978±1.5208
		15	0.9990±0.0014	1.0258±0.6888	2.4389±1.4649
		18	0.9990±0.0012	1.0167±0.6708	2.4206±1.3843
		21	0.9990±0.0014	1.0051±0.6772	2.3725±1.4810

Tabla 3.5. Valores promedio ± desviaciones estándar para varias métricas cuando se recupera espectralmente el conjunto completo de test de 1567 medidas de luz-cielo usando para ello los tres sensores óptimos encontrados en cada caso. \*SNR = 30 dB y cuantización uniforme con 12 bits;  $m = 156$  espectros de entrenamiento. Los mayores valores de  $n$  mostrados para el caso de ICA fueron los óptimos encontrados para cada método, de acuerdo a la métrica CSCM.

Los sensores óptimos encontrados al usar la base de vectores NMF son realmente parecidos a los obtenidos al usar la base PCA, para los tres métodos de estimación espectral ahora estudiados, como vemos en la figura 3.15. También la calidad de las reconstrucciones obtenidas usando PCA y NMF es comparable (ver tabla 3.5). Siguiendo con las semejanzas, incluso se encontró que los mejores resultados obtenidos al usar NMF ocurrían si el número de sensores y de vectores coincidían (tres en este caso), exactamente como con PCA, para los métodos de Maloney-Wandell y de Imai-Berns. Podemos concluir que no encontramos, en este estudio, ninguna ventaja o desventaja práctica a la hora de usar NMF en lugar de PCA para obtener una base lineal espectralmente representativa de las curvas de luz-cielo que tratamos, excepto que se necesita un mayor tiempo de computación para calcular las bases NMF que las bases PCA, y que es obligatorio en NMF elegir el número de vectores que se desean generar antes de hacerlo (la forma de los vectores base depende del número de ellos que se van a generar [Buschbaum y Bloch 2002], lo que no ocurre para el PCA). Algunos autores [Buschbaum y Bloch 2002, Xiong y Funt 2005] afirman que NMF tiene dos ventajas sobre PCA. En primer lugar, las bases NMF están formadas por vectores estrictamente

positivos y pueden entenderse éstos como espectros aditivos físicamente realizables. En segundo lugar, sus pseudoinversas truncadas positivas [Xiong y Funt 2005] podrían representar las sensibilidades espectrales de los sensores cuyas respuestas,  $\rho$ , serían directamente los pesos,  $\varepsilon$ , en la combinación lineal de la ecuación (2.14). Sin embargo, la forma espectral de estos vectores base NMF no es tan fácilmente realizable en la práctica como lo es la de los sensores gaussianos (ver figura 3.15).

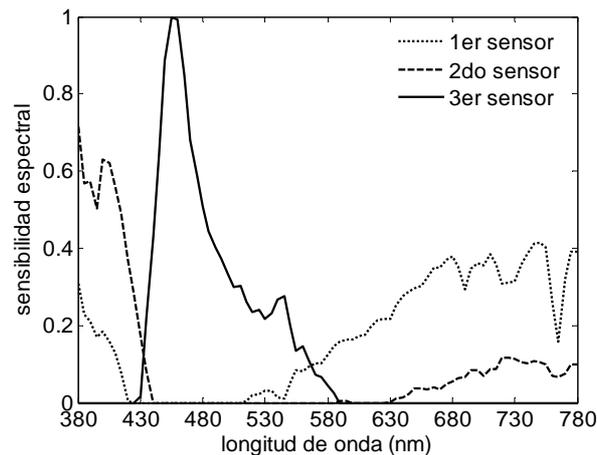


Figura 3.15: Forma espectral de la pseudoinversa truncada positiva de los vectores base NMF, que podrían representar las sensibilidades espectrales de unos sensores hipotéticos cuyas respuestas,  $\rho$ , fuesen directamente los pesos,  $\varepsilon$ , en la combinación lineal de la ecuación (2.14).

Los tres sensores óptimos encontrados al trabajar con bases ICA son bastante diferentes de los que hemos visto para PCA y NMF con los métodos de Maloney-Wandell y de Imai-Berns, mientras que son muy similares entre sí en el caso del método de Shi-Healey (ver figura 3.14). Las reconstrucciones usando tres sensores y los vectores base ICA arrojan los mejores valores para la métrica CSCM con los tres métodos de estimación espectral, como otros autores han encontrado también [Xiong y Funt 2005, Oxtoby *et.al.* 2002] al recuperar espectralmente reflectancias espectrales de objetos o radiancias de escenas diversas. Para el método de Maloney-Wandell con tres sensores, los resultados obtenidos con ICA mejoran aquellos obtenidos con PCA o NMF incluso usando sólo tres vectores, pero con ICA dichos resultados aún mejoran incluso más hasta llegar a  $n=12$ . Con los métodos de Imai-Berns y de Shi-Healey los resultados de ICA también son mejores que los obtenidos con PCA o NMF, pero se necesita un mayor número de vectores base (el valor óptimo de  $n$  encontrado en este caso es el máximo mostrado en la tabla 3.5).

### 3.3.4.- Tiempo de cálculo y esquemas de cuantización.

En esta sección hacemos una pequeña comparación entre el tiempo de cálculo que cada método de estimación espectral necesita para recuperar los espectros a partir de las respuestas de los sensores. Dicho tiempo puede depender, en principio, de  $m$  (el tamaño del conjunto de espectros de entrenamiento). Asumiendo que el sistema ya está entrenado, es decir, que ya se tienen las matrices  $V$  y  $\Lambda$  para Maloney-Wandell (ver ecuación (2.17)), las matrices  $V$  y  $G$  para Imai-Berns (ver ecuación (2.20)), las matrices  $V_1$ ,  $V_2$  y  $\varepsilon_1^*$  para Shi-Healey (ver (2.25)), y la matriz  $W_L$  para la regresión lineal (ver (2.30)), sólo vamos a medir el tiempo transcurrido durante la estimación espectral usando tres sensores óptimos. Debemos notar que los algoritmos de Maloney-Wandell, Imai-Berns y regresión lineal sólo tienen que calcular un producto matricial de la forma:

$$E_R = X\rho \quad (3.6)$$

donde  $X$  es una matriz  $N \times 3$  que transforma las respuestas de los sensores en curvas espectrales. Esta matriz se calcula de diferentes formas según utilicemos uno u otro método de estimación, pero en este apartado no incluiremos el tiempo de computación necesario para este cálculo previo (entrenamiento del sistema). No debería sorprendernos, por tanto, que los tres métodos mencionados tardasen el mismo tiempo en la computación de los espectros. En la figura 3.16 mostramos en el eje vertical una escala de tiempos en la que comparamos de forma relativa el tiempo empleado por cada método en la estimación espectral (en unidades arbitrarias) de los 1567 espectros de luz-cielo del conjunto de test, con tres sensores y diferentes valores de  $m$ . En esta simulación los métodos de Maloney-Wandell y de Imai-Berns utilizaron tres vectores base PCA, mientras que el de Shi-Healey utilizó cinco.

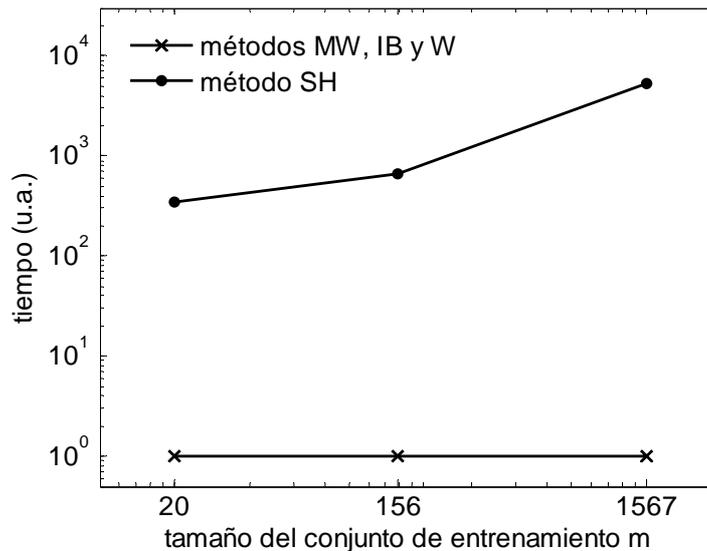


Figura 3.16: Comparación relativa del tiempo de computación requerido por los cuatro métodos de estimación espectral en función del tamaño del conjunto de espectros de entrenamiento  $m$ . Se usaron tres sensores con todos los métodos (MW indica Maloney-Wandell, IB indica Imai-Berns, SH indica Shi-Healey y W indica regresión lineal). Con los métodos de Maloney-Wandell y de Imai-Berns se usan tres vectores base PCA, mientras que con el método de Shi-Healey se usan cinco.

Podemos ver en la figura 3.16 cómo los métodos de Maloney-Wandell, Imai-Berns y regresión lineal consumen el mismo tiempo de computación una vez que el sistema ha sido entrenado. El método de Shi-Healey, aunque arroja los mejores resultados en cuanto a calidad de las reconstrucciones espectrales, es extremadamente lento comparado con los otros tres métodos probados aquí, especialmente cuando  $m$  es grande. Todos estos parámetros deben ser tenidos en cuenta a la hora de diseñar un sistema multiespectral real. Al seleccionar el método de estimación espectral más adecuado, el diseñador debe buscar un equilibrio entre la precisión esperada para las estimaciones espectrales y el tiempo de computación requerido para ello. En un sistema multiespectral con un elevado número de píxeles, al obtener un espectro por píxel, el tiempo de computación puede ser considerable si se elige un algoritmo de estimación muy lento.

Como resumen esquemático de todos los resultados mostrados en la sección 3.3, mostramos en la tabla 3.6 las características más importantes estudiadas de los cuatro métodos de estimación espectral que hemos presentado en este trabajo doctoral. Esta tabla incluye a la tabla 2.2 ya presentada en el capítulo anterior a la hora de describir la matemática de los diferentes métodos de estimación espectral, pero ahora la ampliamos recogiendo también un resumen de los resultados obtenidos.

método	Maloney-Wandell	Imai-Berns	Shi-Healey	Regresión lineal
Base lineal	Sí	Sí	Sí	No
Espectros de entrenamiento	Sí (PCA)	Sí (PCA y pseudoinversa)	Sí (PCA y comparación)	Sí (pseudoinversa)
Sensibilidad espectral	Sí	No	Sí	No
Tiempo de computación	Rápido y constante con $m$	Rápido y constante con $m$	Lento y creciente con $m$	Rápido y constante con $m$
Influencia del conjunto de entrenamiento en los sensores óptimos	Baja	Baja	Baja	Baja
Influencia del conjunto de entrenamiento en los resultados	Baja	Baja	Alta	Baja
Influencia del ruido en los sensores óptimos	Estrechamiento	Estrechamiento y desplazamiento	Estrechamiento	Estrechamiento
Influencia del ruido en los resultados	40dB:30dB:26dB CSCM=1:2:3	40dB:30dB:26dB CSCM=1:2:3	40dB:30dB:26dB CSCM=1:2:3	40dB:30dB:26dB CSCM=1:2:3
$n = k$ con PCA	Mejor $n=k$	Mejor $n=k$	Mejor $n= 6, 7$ según la SNR	--

Tabla 3.6. Similitudes y diferencias entre los cuatro métodos de estimación espectral estudiados.

Para finalizar con esta sección, presentamos los resultados obtenidos al comparar el efecto de usar cuantización uniforme frente a diferentes esquemas de cuantización no-uniforme [Lathi 1989] usando varios niveles de número de bits. Aunque el efecto del ruido de cuantización es mucho menor que el de otras fuentes de ruido [Burns y Berns 1999, López-Álvarez *et al.* 2005c], creemos interesante realizar un estudio de este tipo, al menos de forma simulada, para obtener conclusiones relevantes en cuanto al número de bits que deben usarse en la cuantización.

Recordemos que la cuantización es parte del proceso de conversión de datos analógicos a forma digital [Lathi 1989]. Este paso es necesario debido a que los sistemas digitales trabajan con un número finito de valores para la representación de cantidades numéricas [Lloris y Prieto 1996], y se precisa discretizar o cuantizar los valores continuos (analógicos) de las magnitudes que se traten. Estudiemos el ejemplo de un conversor A/D de audio cuya entrada es una señal de voltaje comprendida entre 0 V y 1 V y cuya salida debe ser un valor numérico entre 0 y 255 (suponemos que es un conversor A/D de 8 bits y que por tanto puede representar  $2^8$  valores discretos diferentes). Suponiendo el caso sencillo de cuantización uniforme, el conversor asignará 256 “escalones” de  $1V / 256 = 0,0039V$  cada uno

para representar todos los posibles valores de la señal eléctrica analógica. Así, si en un instante dado la señal eléctrica tiene un valor de  $0,85\text{ V}$ , el conversor A/D le asignará el valor discreto  $0,85\text{V} / 0,0039\text{V} = 217,95 \approx \mathbf{218}$  por ser el más cercano. En esta asignación se comete un error de  $0,2\text{mV}$ , que es lo que se conoce como error de cuantización. Al ser este error aleatorio y no correlacionado entre unos instantes de tiempo y otros, se le denomina usualmente como '*ruido de cuantización*'. El efecto del ruido de cuantización es menor cuanto mayor sea el número de bits usados en la conversión A/D, pero también hay esquemas de cuantización no-uniforme que tratan de reducir el efecto de este ruido cuando la señal es débil (donde dicho efecto sería más perjudicial), consiguiendo -en promedio - una mejora considerable en la calidad de la representación digital de las señales.

En la tabla 3.7 mostramos los promedios y desviaciones estándar obtenidos al reconstruir los 1567 espectros de luz-cielo del conjunto completo de test (el número de espectros de entrenamiento,  $m$ , fue en este caso también 1567) usando los sensores óptimos encontrados en la sección 3.3.1 para cada uno de los métodos y un ruido simulado de 40dB. Las respuestas de dichos sensores se transforman de analógico a digital (conversión A/D) usando diferentes números de bits, con cuantización uniforme y otros dos esquemas de cuantización no-uniforme que incluyen transformaciones no-lineales de los datos previas a la cuantización. Utilizaremos una transformación potencial [Burns y Berns 1999] (transformamos cada componente  $i$  del vector de respuestas de los sensores,  $\rho_i$ , en  $\rho_i^p$ , siendo  $p$  un número real menor que la unidad; en nuestro caso 0,33), y la ley de transformación  $\mu$  para cuantización no-uniforme [Lathi 1989], que es un esquema de cuantización ampliamente utilizado en comunicaciones de voz (con el valor típico  $\mu = 255$ ). El propósito de estas dos transformaciones es asignar un número mayor de pasos (cuantos más pequeños) donde la señal es menor, aumentando así la SNR promedio debida a la cuantización (si ninguna otra fuente de ruido estuviese presente). Puede verse en la tabla 3.7 que aumentar el número de bits de 8 a 10 provoca una mejora significativa en los resultados de las métricas estudiadas, mientras que el aumento de 10 a 12 bits no es tan relevante. También vemos que la utilización de los esquemas de cuantización no-uniforme es recomendable si sólo se usan 8 bits, pero la mejora conseguida al comprimir previamente los datos es poco apreciable si se utilizan 10 o 12 bits para la cuantización.

método	cuantización	bits	GFC	$\Delta E_{ab}^*$	CSCM
Maloney-Wandell <sup>a</sup>	uniforme	8	0.9993±0.0012	0.8384±0.5619	2.2722±1.1569
		10	0.9994±0.0012	0.8132±0.5567	2.0563±1.1148
		12	0.9994±0.0012	0.8100±0.5652	2.0125±1.0836
	potencial $p = 0.33$	8	0.9993±0.0012	0.8182±0.5675	2.1180±1.1056
		10	0.9994±0.0012	0.8110±0.5564	2.0285±1.1068
		12	0.9994±0.0012	0.8106±0.5536	2.0099±1.1029
	ley- $\mu$ $\mu = 255$	8	0.9994±0.0012	0.8177±0.5746	2.0867±1.1256
		10	0.9994±0.0012	0.8103±0.5576	2.0296±1.1079
		12	0.9994±0.0012	0.8092±0.5635	2.0078±1.1045
Imai-Berns <sup>a</sup>	uniforme	8	0.9993±0.0012	0.8286±0.5201	2.2912±1.1649
		10	0.9993±0.0012	0.7924±0.4950	2.0324±1.0955
		12	0.9993±0.0012	0.7725±0.5104	2.0089±1.0866
	potencial $p = 0.33$	8	0.9993±0.0012	0.8064±0.5103	2.1320±1.1276
		10	0.9993±0.0012	0.7920±0.4934	2.0144±1.0912
		12	0.9993±0.0012	0.7733±0.4901	2.0075±1.0781
	ley- $\mu$ $\mu = 255$	8	0.9993±0.0012	0.8034±0.5089	2.1085±1.0936
		10	0.9993±0.0012	0.7928±0.4929	2.0121±1.0913
		12	0.9993±0.0012	0.7733±0.4900	2.0061±1.0782
Shi-Healey <sup>b</sup>	uniforme	8	0.9996±0.0003	0.6210±0.4763	1.3552±0.8273
		10	0.9997±0.0003	0.5628±0.4709	1.1676±0.7902
		12	0.9997±0.0003	0.5730±0.4611	1.1727±0.7586
	potencial $p = 0.33$	8	0.9997±0.0004	0.6012±0.4875	1.2448±0.8048
		10	0.9997±0.0004	0.5624±0.4826	1.1787±0.8076
		12	0.9997±0.0003	0.5690±0.4808	1.1773±0.7842
	ley- $\mu$ $\mu = 255$	8	0.9997±0.0003	0.5840±0.4784	1.2187±0.7916
		10	0.9997±0.0003	0.5562±0.4713	1.1569±0.7928
		12	0.9997±0.0003	0.5687±0.4789	1.1666±0.7723
Regresión lineal	uniforme	8	0.9993±0.0012	0.8166±0.5020	2.2432±1.1310
		10	0.9994±0.0012	0.7742±0.4968	2.0139±1.0794
		12	0.9994±0.0012	0.7873±0.5240	1.9882±1.0422
	potencial $p = 0.33$	8	0.9993±0.0012	0.7945±0.5021	2.0766±1.0897
		10	0.9994±0.0012	0.7721±0.4990	2.007±1.0640
		12	0.9994±0.0012	0.7868±0.4946	1.9816±1.0773
	ley- $\mu$ $\mu = 255$	8	0.9993±0.0012	0.7972±0.4976	2.0598±1.0893
		10	0.9994±0.0012	0.7728±0.4975	2.0070±1.0626
		12	0.9994±0.0012	0.7872±0.4952	1.9835±1.0767

Tabla 3.7. Valores promedio  $\pm$  desviaciones estándar para varias métricas al recuperar espectralmente el conjunto completo de test de 1567 espectros de luz-cielo usando para ello los tres sensores óptimos encontrados en cada caso, con una SNR de 40dB y  $m = 1567$  espectros de entrenamiento. <sup>a</sup>Tres sensores y tres vectores base PCA. <sup>b</sup>Tres sensores y cinco vectores base PCA.

A la vista de la completa discusión que hemos presentado en este capítulo, creemos tener argumentos suficientes como para recomendar el algoritmo de regresión lineal para obtener estimaciones espectrales de luz-cielo en la mayoría de casos prácticos. Por ejemplo, en el capítulo siguiente utilizaremos este método para las estimaciones espectrales a partir de las respuestas de una cámara RGB, por las razones que argumentaremos más adelante. Las ventajas de este método frente a los otros son diversas, pero se derivan principalmente del hecho de que su sencillez matemática lo hace rápido y robusto frente al ruido [Day 2003, López-Álvarez *et al.* 2007].

En primer lugar, la calidad de las reconstrucciones espectrales obtenidas con él son similares a las que arrojan los otros métodos, excepto el de Shi-Healey que significativamente las mejora, pero que -sin embargo- descartaremos por la lentitud que conlleva en los cálculos frente al resto de algoritmos.

En segundo lugar, supone una gran ventaja práctica el no tener que medir las sensibilidades espectrales de la cámara para poder disponer de un instrumento capaz de registrar imágenes multiespectrales, pues esto conlleva -muchas veces- incluir en las matrices numerosas fuentes de error que afectan a los cálculos posteriores.

Esta característica también la comparte el método de Imai-Berns, que -sin embargo- precisa de la utilización de una base lineal de vectores estadísticamente representativa del tipo de espectros que se pretende recuperar. Hemos visto también que si se usa una base ICA con un número elevado de vectores (24 en nuestro estudio con 3 sensores), los resultados obtenidos con el método de Imai-Berns mejoran significativamente los obtenidos mediante el método de regresión lineal. Podríamos recomendar esta alternativa si se cumplen dos supuestos. Primero, que el ruido en el sistema no sea excesivo, pues en ese caso la elevada dimensión de las matrices resultantes -debido al alto número de vectores ICA necesarios- daría lugar a un empobrecimiento en la calidad de las estimaciones espectrales [Hardeberg 1999, López-Álvarez *et al.* 2005], lo que también podría ocurrir si el número de sensores fuese elevado, como discutiremos en el capítulo 5. Segundo, que se disponga de un conjunto de espectros de entrenamiento de suficiente calidad y tamaño como para que los vectores ICA obtenidos a partir de él sean realmente útiles para las estimaciones espectrales.



## **4.- APLICACIONES I: ESTIMACIÓN ESPECTRAL DE LUZ-CIELO CON UNA CÁMARA CCD DIGITAL RGB.**

### **4.1.- Descripción del sistema.**

El trabajo presentado en este capítulo comenzó a desarrollarse, en colaboración con el equipo de investigación de los profesores Olmo Reyes y Alados Arboledas -pertenecientes al Grupo de Física de la Atmósfera del Centro Andaluz de Medio Ambiente (CEAMA) y al Departamento de Física Aplicada de la Universidad de Granada-, cuando dicho equipo adquirió una cámara digital RGB de 12 bits y 1280x1024 píxeles modelo QImaging Retiga Q1300C con un objetivo ojo de pez, para tomar continuamente imágenes del cielo con la finalidad de estudiar los patrones de nubes presentes en él.

Dicha cámara fue instalada en la azotea del edificio del CEAMA, situado al sur de la capital granadina ( $37^{\circ} 10'N$ ,  $3^{\circ} 36'W$ , altitud 670 m), en una zona urbana con elevada presencia de contaminantes provenientes del tráfico rodado. El sistema acoplado a la cámara consta, además del ojo de pez, de una cúpula transparente protectora contra la lluvia, de un sistema de refrigeración tipo Peltier que mantiene la cámara a una temperatura constante cercana a los  $0^{\circ}C$  y de un ocultador solar movido por un motor. En las figuras 4.1, 4.2 y 4.3 podemos ver algunas imágenes descriptivas de este sistema de adquisición de imágenes.

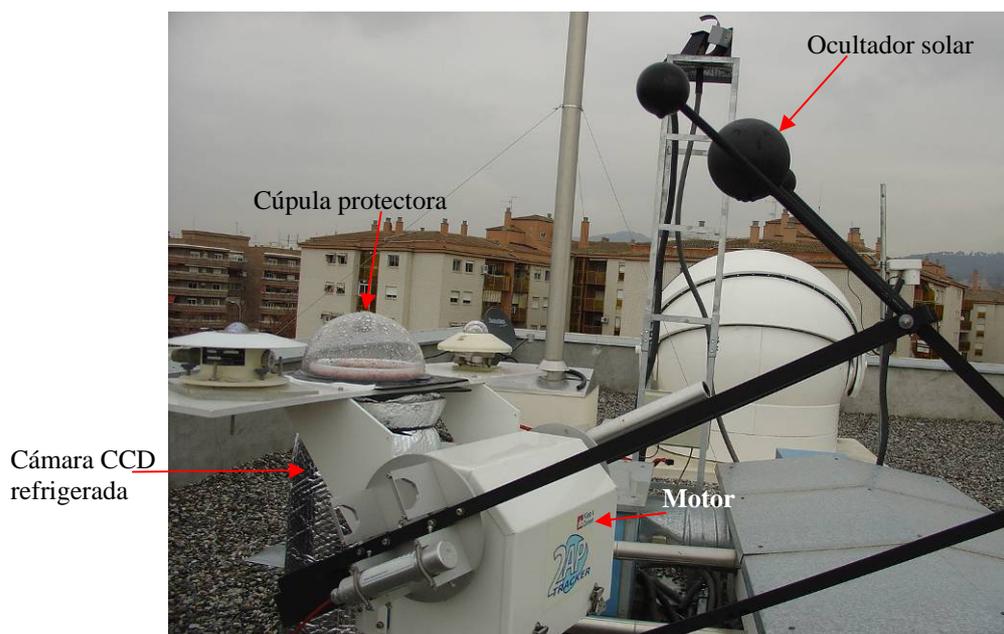


Figura 4.1. Sistema de adquisición de imágenes del cielo basado en cámara RGB.



Figura 4.2. Sistema de adquisición de imágenes del cielo basado en cámara RGB.

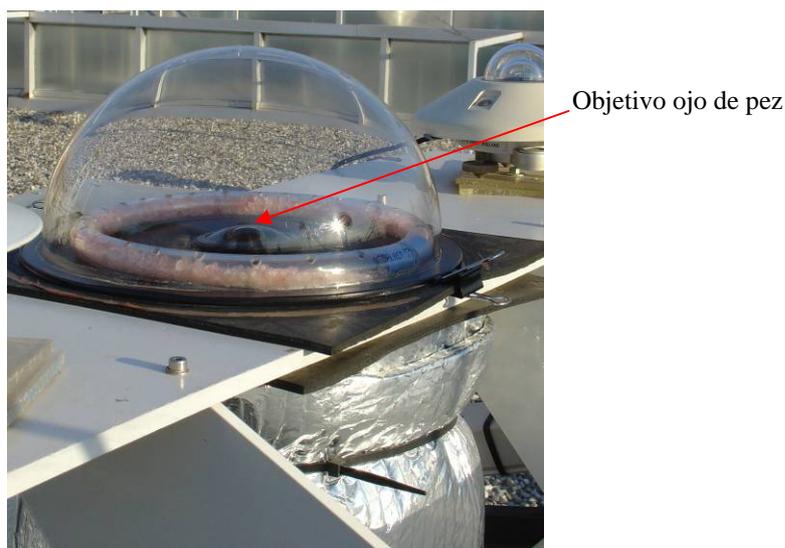


Figura 4.3. Detalle de la situación del objetivo ojo de pez dentro de la cúpula.

Los dos ocultadores solares menores que pueden apreciarse en la figura 4.2 son para sendos dispositivos que se encuentran en la misma plataforma que la cámara y cuya finalidad no es relevante para este estudio. El tipo de imágenes que capta esta cámara es como la mostrada en la figura 4.4. En ella podemos apreciar cómo el ocultador solar evita que se produzca sobresaturación de los píxeles correspondientes al Sol y sus vecinos cercanos. El resto de píxeles de la imagen es utilizado por el personal del CEAMA para la detección

automática de nubes mediante tratamiento informático basado en redes neuronales a partir de la información tricromática disponible. En nuestro caso, utilizaremos este tipo de imágenes para obtener información espectrorradiométrica de la luz-cielo proveniente de cualquier punto de la bóveda celeste en ese instante, independientemente de la presencia de nubes, como explicaremos más adelante. El objetivo ojo de pez distorsiona la imagen, pero permite registrar todos los puntos de la bóveda celeste por encima del horizonte en una sola fotografía.

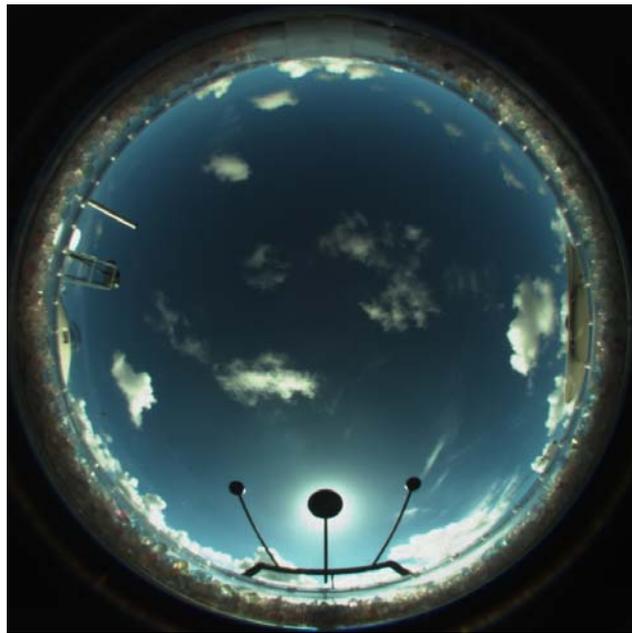


Figura 4.4. Imagen típica captada por el sistema RGB situado en el CEAMA.

Se toma una imagen cada 5 minutos entre la salida y la puesta de sol. El tiempo de exposición es fijo en todo momento, e igual a  $12\text{ ms}$ , asegurando así que no se produce saturación en la imagen en las horas centrales del día. El gain y el offset de la cámara también son fijos en todo momento a 0,5 y 83 respectivamente. Sin embargo algunos píxeles superan el 90% del máximo registrable por la cámara en gran cantidad de imágenes, siendo éste el límite típico elegido para mantener la linealidad de la cámara [Ferrero *et al.* 2006b]. El balance de blancos se encuentra igualmente fijado dando el mismo peso a cada uno de los canales R, G y B. Dado que el sistema ya se encuentra funcionando desde hace más de un año, y realiza su función de almacenamiento de imágenes del cielo en una gran base de datos, no podemos modificar ninguno de estos parámetros, ni podemos calibrar la cámara en un laboratorio radiométrico, ya que ello supondría la ruptura de la secuencia de captura de datos para la que este equipo fue diseñado e instalado.

Según lo que acabamos de exponer, nos ha sido imposible hacer medidas del ruido presente en la cámara, de la transmitancia espectral del ojo de pez, de la sensibilidad espectral de los canales RGB o si se produce atenuación para grandes ángulos de incidencia de la luz. Aún así, es posible poder utilizar los algoritmos de regresión, lineal o no-lineal, vistos en el capítulo 2 para obtener estimaciones espectrales de la luz-cielo registrada por esta cámara, pese a que sólo posee tres canales (teóricamente no podríamos clasificarla como sistema multiespectral según lo expuesto en la tabla 2.1, pero sí que puede proporcionar medidas espectrales, como se explica a continuación). Como ya se argumentó al final del capítulo 3, preferimos utilizar el algoritmo de regresión lineal por su sencillez, robustez frente al ruido y buenos resultados incluso utilizando conjuntos de entrenamiento pequeños.

Si recordamos la sección 2.3.5, utilizando el algoritmo de regresión lineal es posible relacionar las respuestas,  $\rho$ , de la cámara, esto es, los valores RGB de cada píxel de la imagen, con su correspondiente curva espectral  $E(\lambda)$ , para así entrenar al sistema y obtener la matriz  $W_L$  que servirá posteriormente para estimar espectros a partir de las imágenes RGB registradas. La ecuación (2.30) resume este proceso

$$W_L = E_{ts} \rho_{ts}^+ \quad (2.30)$$

Es imprescindible, por tanto, llevar a cabo una fase de entrenamiento del sistema con el fin de obtener la matriz  $W_L$ . Para ello, se realizaron medidas con un espectrorradiómetro SpectraScan PR650 simultáneamente con las fotografías que se captaban con la cámara digital. En la figura 4.5 se muestra este dispositivo. El espectrorradiómetro sólo mide un espectro de un punto del cielo correspondiente a un ángulo de campo de visión (FOV, del inglés '*field of view*') de 1°. Ese campo corresponde en la imagen captada por la cámara a una región circular de entre 3 y 4 píxeles de radio, dependiendo de la elevación a la que se haya realizado la medida (es un efecto de la distorsión introducida por el ojo de pez, ver figura 4.6). En nuestro caso realizamos medidas en el cénit (elevación 90° a la que corresponde un punto de radio 4 píxeles en la imagen) y con elevaciones de 60° (3,5 píxeles de radio) y 45° (3 píxeles).



Figura 4.5. Espectrorradiómetro PR650 realizando las medidas espectrales de entrenamiento y de test.

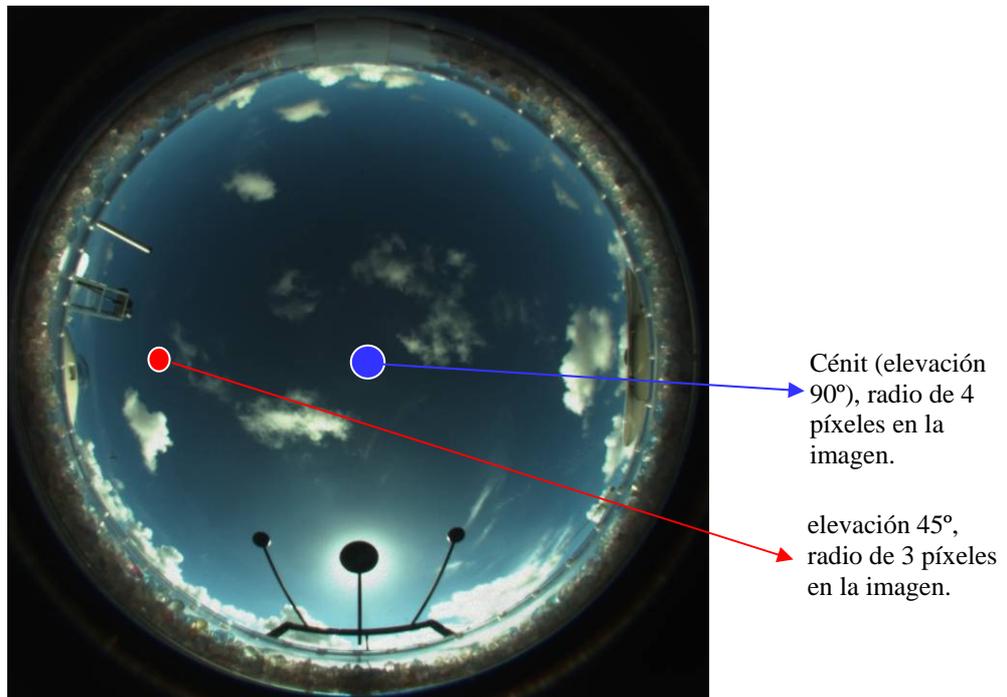


Figura 4.6. Correspondencia entre el campo de visión del espectrorradiómetro PR650 y la cámara en función de la elevación a la que se realiza la medida. El tamaño de los círculos representativos en esta figura es mayor que el real.

#### **4.2.- Entrenamiento del sistema.**

Tal y como hemos indicado al final de la sección anterior, con el fin de obtener estimaciones espectrales a partir de las imágenes registradas por la cámara CCD, es necesario relacionar de alguna forma los valores RGB obtenidos en un píxel o en un conjunto pequeño

de ellos (las respuestas de la cámara) con la curva espectral de radiancia de luz-cielo medida en el mismo instante para el punto del cielo en cuestión. El entrenamiento del sistema multispectral consiste en establecer dicha relación, que se lleva a cabo tal y como se ha visto en la ecuación (2.30).

La campaña completa de toma de medidas e imágenes recoge un total de 902 curvas y sus correspondientes valores RGB, llevadas a cabo en diferentes épocas del año, a diferentes horas del día, con cielos cubiertos y despejados, y a diferentes elevaciones. Las características de dichas medidas se muestran en la tabla 4.1.

Día	Número de medidas	Elevaciones	Orientaciones	Horas del día (GMT)	Cielo
10/07/2006	37	90°	Cénit	8:35 a 18:00	Claros y nubes
30/10/2006	69	90°	Cénit	10:10 a 17:35	Claros y nubes
31/10/2006	38	90°	Cénit	9:20 a 12:30	Claros y nubes
30/11/2006	14	45°	Norte y Sur	15:50 a 17:00	Despejado
04/12/2006	15	45°	Norte	15:45 a 16:55	Despejado
05/12/2006	275	45°	Norte, Sur, Este y Oeste	9:10 a 16:50	Claros y nubes
12/12/2006	454	60°	Norte, Sur, Este y Oeste	9:00 a 16:50	Claros y nubes

Tabla 4.1. Resumen de la campaña de medidas realizada en el CEAMA.

De todo este conjunto de medidas debemos elegir un subconjunto pequeño para entrenar al sistema, y el conjunto completo (incluyendo las medidas seleccionadas para entrenar al sistema) se usará como conjunto de test para comprobar la bondad del algoritmo de regresión lineal que utilizaremos en las estimaciones espectrales. Por este motivo, a continuación presentamos un método original para elegir los mejores espectros de entrenamiento y el número óptimo de los mismos.

#### 4.2.1.- Elección de los espectros de entrenamiento.

Parece lógico pensar que cuanto mayor y más variado, espectralmente, sea un conjunto de entrenamiento mejores resultados se obtendrán en las reconstrucciones espectrales que obtengamos a partir de él. El problema reside en que un conjunto excesivamente grande ralentiza los cálculos e impone severas limitaciones de tipo práctico [Hardeberg 1999]. Se hace necesario, por tanto, elegir un conjunto de entrenamiento pequeño pero que al mismo tiempo permita obtener reconstrucciones de la máxima calidad posible.

En la literatura podemos encontrar multitud de propuestas para elegir el conjunto de espectros de entrenamiento adecuado. Hardeberg [Hardeberg 1999] propuso un método iterativo en el que se van añadiendo espectros al conjunto de entrenamiento de forma que se minimice el cociente entre el primer y último valor singular de la matriz así construida (su '*condition number*'). Otros autores [Schettini *et al.* 2004] sugieren utilizar los valores de los vectores de respuesta de la cámara y elegir los espectros que maximicen la distancia promedio con el resto de vectores de salida ya elegidos. Existen otros métodos alternativos [Mohammadi *et al.* 2004] basados en la búsqueda de máximas diferencias espectrales entre los miembros del conjunto finalmente elegido de acuerdo con alguna métrica predefinida (maximización de la entropía [Lathi 1989]), o utilizan las direcciones de máxima variación espectral dadas por el análisis de componentes principales (PCA) para después elegir aquellos espectros que más se acercan a cada una de dichas direcciones.

En esta sección comparamos algunos de los anteriores métodos y presentamos un nuevo método basado en el agrupamiento de aquellos espectros más cercanos según la métrica combinada espectral y colorimétrica CSCM [López-Álvarez *et al.* 2005], presentada en el capítulo 3. En concreto, estudiaremos los métodos de minimización del '*condition number*' [Hardeberg 1999], de maximización de la entropía de Shannon [Lathi 1989] (bien conocida en el contexto de la teoría de la información), el de cercanía a las direcciones PCA [Mohammadi *et al.* 2004] y el propuesto aquí de agrupamiento por cercanía según la métrica CSCM. Este último consiste en, partiendo del conjunto completo de espectros conocidos, elegir uno al azar, calcular las distancias entre ese espectro y todos los demás del conjunto y agrupar junto a él a aquel espectro más cercano según la métrica CSCM. Como representante del agrupamiento se elige al primero de los espectros. De esta forma se elimina un espectro del conjunto original en cada iteración, y el procedimiento se repite hasta alcanzar el número deseado de espectros de entrenamiento quedando éstos lo más alejados posible entre sí de acuerdo con la métrica elegida. En la figura 4.7 mostramos un esquema de cómo funciona el algoritmo propuesto.

El conjunto de entrenamiento elegido siguiendo este método es diferente cada vez que se ejecuta el algoritmo, puesto que dicha elección depende del espectro que se seleccione primero al azar. Sin embargo, la calidad de las reconstrucciones obtenidas con cualquiera de los conjuntos de entrenamiento resultantes de ejecutar el algoritmo de selección -medida mediante la métrica CSCM- es muy similar en todos los casos y no hay diferencias

significativas entre los resultados obtenidos con conjuntos diferentes procedentes de ejecutar el algoritmo de selección en ocasiones diferentes.

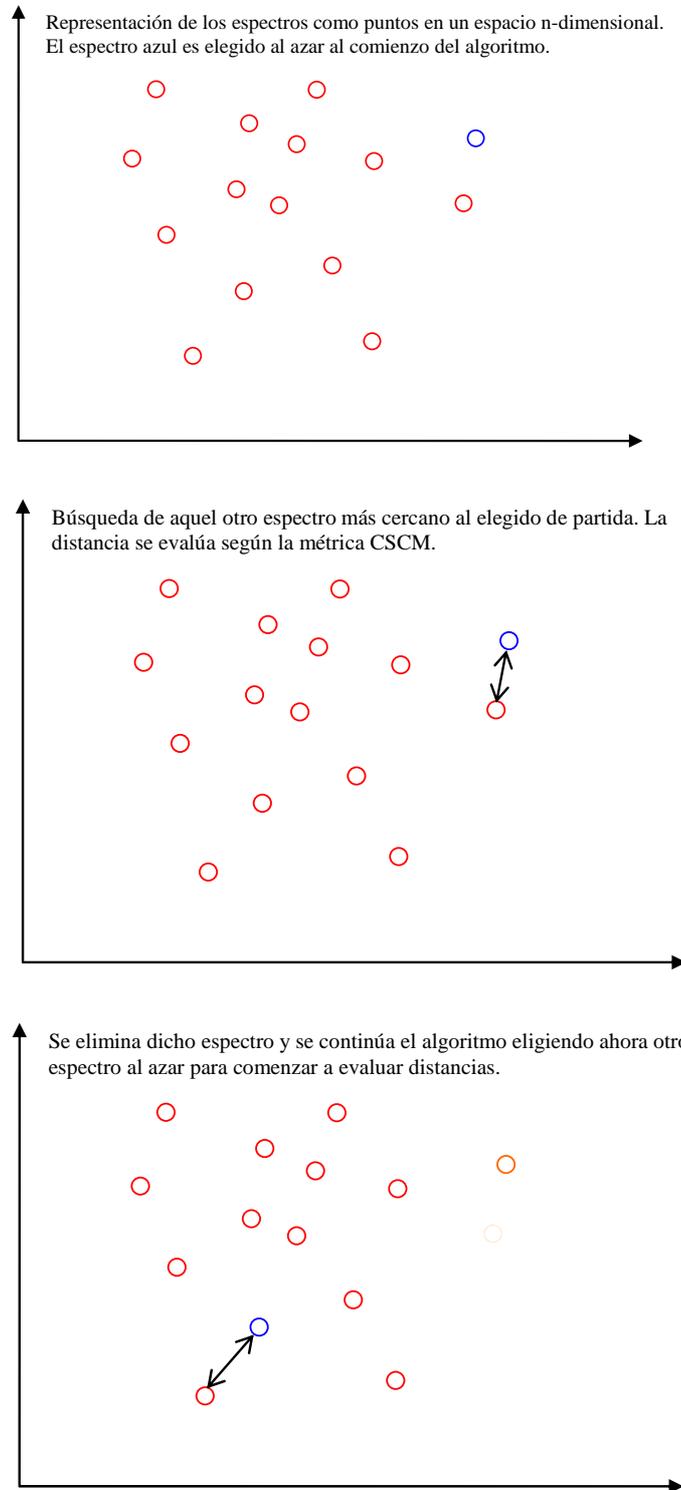


Figura 4.7. Esquema ilustrativo del algoritmo de elección de espectros de entrenamiento por agrupamiento según la métrica CSCM.

Los diversos métodos de elección de los espectros de entrenamiento se ejecutan para elegir un conjunto de 40 medidas, que -como hemos podido comprobar en el capítulo 3- es suficiente para obtener buenas reconstrucciones espectrales con el método de estimación de regresión lineal. La calidad de cada uno de los conjuntos de entrenamiento obtenidos se evalúa calculando la media de la métrica CSCM obtenida al reconstruir espectralmente las 902 curvas del conjunto inicial.

En la tabla 4.2 podemos ver los resultados obtenidos en este estudio, que muestran claramente que las mejores reconstrucciones espectrales se obtienen si entrenamos al sistema con el conjunto de las 40 curvas de entrenamiento obtenidas con el método aquí propuesto de maximización de la métrica CSCM por agrupamiento de espectros similares.

	Condition number	Maximización de la métrica CSCM	PCA	Entropía
CSCM	38.20±32.97	12.22±16.70	19.13±20.89	85.83±95.21

Tabla 4.2. Resultados de la métrica CSCM al reconstruir los 902 espectros de luz-cielo utilizando como conjunto de entrenamiento los 40 espectros obtenidos con cada uno de los métodos mostrados por columnas.

En la figura 4.8 mostramos, en el diagrama de cromaticidad CIE-1931, la situación de las 902 medidas espectrales de luz-cielo del conjunto completo así como de las 40 elegidas para entrenamiento. En dicha figura se aprecia que la variedad cromática de ambos conjuntos es amplia, y que el conjunto de entrenamiento prácticamente engloba todo el intervalo cromático abarcado por el conjunto completo de medidas.

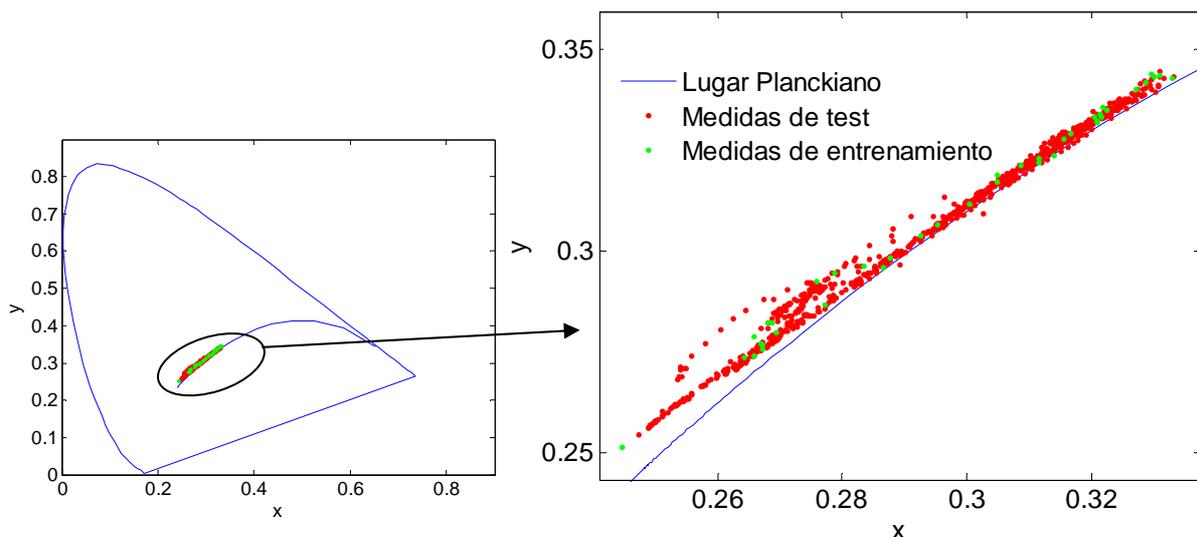


Figura 4.8. Diagrama CIE-1931 mostrando el lugar Plankiano, las coordenadas de cromaticidad del conjunto completo de 902 medidas espectrales (en rojo) y de las 40 elegidas como entrenamiento (en verde).

#### 4.2.2.- Influencia del tamaño del conjunto de entrenamiento.

Es interesante comprobar si existe un número óptimo de espectros de entrenamiento necesarios para obtener buenas reconstrucciones espectrales con ellos. Dicho número sería el mínimo necesario para obtener un valor fijado para las métricas con las que evaluamos las reconstrucciones espectrales obtenidas. Hay algunos trabajos publicados que estudian este parámetro [Hardeberg 1999, de Lasarte *et al.* 2007b, López-Álvarez *et al.* 2007c], y la conclusión principal de todos ellos es que por encima de un tamaño crítico del conjunto de entrenamiento no se consigue mejora en las reconstrucciones espectrales por más espectros que se añadan a dicho conjunto, siempre y cuando éste haya sido elegido adecuadamente. Curiosamente tampoco empeoran los resultados si el tamaño de dicho conjunto es superior a ese tamaño crítico, pero esa información adicional resulta innecesaria. Debemos mencionar, igualmente, que el tamaño crítico encontrado para los conjuntos de entrenamiento depende de las características espectrales del conjunto completo del que se pretenden extraer los espectros de entrenamiento, así como del método de estimación espectral utilizado. Por ejemplo, Hardeberg [Hardeberg 1999] encuentra que 20 espectros -bien elegidos- de reflectancias del atlas Munsell son suficientes para entrenar a un sistema multispectral que pretende reconstruir las 1269 muestras de dicho atlas. Nosotros mismos probamos en el capítulo 3 para luz-cielo que se obtienen prácticamente los mismos resultados, con cualquiera de los métodos excepto el de Shi-Healey, con 20 espectros que con 1567. También en este sentido, de Lasarte [de Lasarte *et al.* 2007b] muestra, haciendo una evaluación colorimétrica, que el número de espectros que deben ser extraídos de la carta ColorChecker DC para entrenar al sistema lo suficientemente bien como para recuperar reflectancias del Munsell y de la carta ColorChecker Color Rendition varía entre 40 y 60, según el método de estimación espectral empleado.

Por todo lo que acabamos de comentar, se decidió diseñar un segundo experimento en el que se evaluó la influencia del tamaño del conjunto de entrenamiento,  $m$ , sobre la calidad de las reconstrucciones espectrales obtenidas utilizando únicamente el conjunto dado por el método que acabamos de presentar de agrupamiento de espectros según la métrica CSCM. La figura 4.9 muestra el promedio de la métrica CSCM obtenido al reconstruir los 902 espectros del conjunto completo, y en ella apreciamos que la mejora es poco significativa por encima de  $m = 100$ , con lo que podemos recomendar ese tamaño de conjunto de entrenamiento como óptimo en este experimento concreto, es decir, para el método de regresión lineal y este tipo

de espectros que no sólo corresponden a luz-cielo en días despejados, sino que también incluyen medidas en días con nubes.

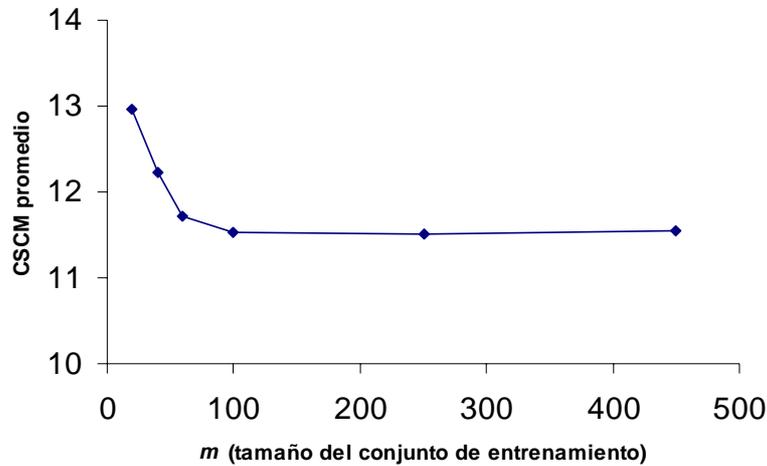


Figura 4.9. Promedio de la métrica CSCM sobre las 902 medidas espectrales del conjunto completo tras entrenar el método de regresión lineal con los conjuntos de espectros de entrenamiento de tamaño  $m$  obtenidos al aplicar el algoritmo de agrupamiento de espectros semejantes.

### **4.3.- Resultados de las estimaciones espectrales.**

En esta sección exponemos que es posible obtener estimaciones espectralradiométricas de luz-cielo con la cámara RGB presentada al principio de este capítulo, utilizando para ello el método de regresión lineal -explicado en el capítulo 2- y el entrenamiento desarrollado en el apartado 4.2, con un tamaño para el conjunto de entrenamiento  $m = 100$ . Dichas estimaciones espectrales resultan muy similares a las curvas medidas -simultáneamente- con el espectralradiómetro SpectraScan PR650, como veremos a continuación.

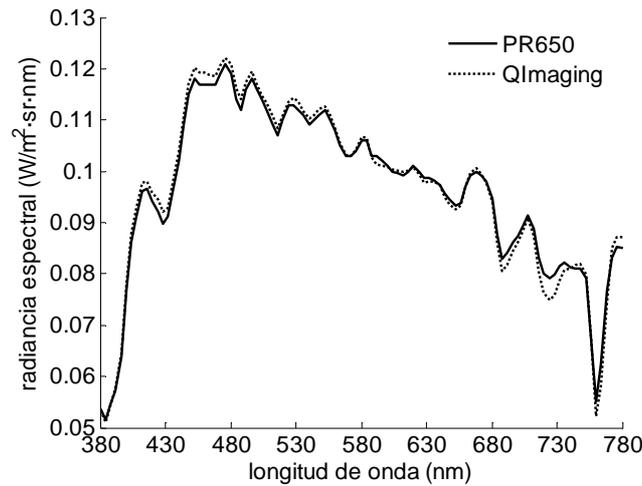
En la tabla 4.3 mostramos los valores promedio para varias métricas, y sus correspondientes desviaciones estándar ( $\pm SD$ ), obtenidos al recuperar espectralmente las 902 curvas del conjunto completo a partir de sus correspondientes valores RGB y tras aplicar el algoritmo de regresión lineal. Podemos apreciar que la calidad de las estimaciones es aceptablemente buena desde un punto de vista espectral y colorimétrico, si bien la métrica radiométrica IRE(%), introducida en el capítulo 3, es la que presenta un peor comportamiento. Esto último es resultado de una pobre estimación de la energía global recibida en el sensor (seguramente por desconocimiento de la variación de la transmitancia del ojo de pez con la

elevación o por trabajar cerca de la saturación del CCD), si bien la forma relativa de las curvas espectrales estimadas sigue siendo buena, como muestran los altos valores obtenidos para el GFC. Podríamos sentirnos tentados a comparar estos resultados con los de las simulaciones de la tabla 3.4, sin embargo aquellos correspondían a simulaciones computacionales con ruido añadido conocido mientras que aquí las medidas son experimentales y se desconoce el nivel de ruido presente en la cámara. Además, los sensores de la cámara RGB distan mucho de ser los óptimos con los que se hicieron las simulaciones del capítulo 3.

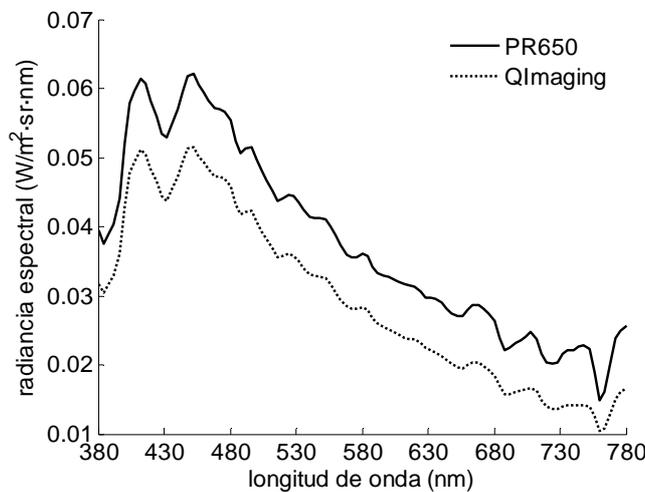
<b>GFC</b> <b>media±SD</b>	<b>CIELAB</b> <b>media±SD</b>	<b>%IRE</b> <b>media±SD</b>	<b>CSCM</b> <b>media±SD</b>
0.9985±0.0032	0.987±1.362	9.422±12.723	11.438±14.161

Tabla 4.3. Resultados de las estimaciones espectrales de luz-cielo con la cámara RGB.

En la figura 4.10 mostramos dos ejemplos de reconstrucciones espectrales obtenidas con este sistema. La figura 4.10a corresponde al percentil 10 de la métrica CSCM (con un valor de 2,15; medida realizada el 12/12/2006 a las 10:29 GMT con orientación sur y cielo parcialmente cubierto) mientras que la figura 4.10b corresponde al percentil 90 de dicha métrica (con un valor de 25,56; medida realizada el 10/07/2006 a las 10:30 GMT en el cénit con cielo completamente despejado).



(a)



(b)

Figura 4.10. Dos ejemplos de reconstrucción espectral obtenidos con el sistema RGB. (a) percentil 10 de la métrica CSCM y (b) percentil 90 de la métrica CSCM.

#### **4.4.- Utilización de las curvas espectrales de luz-cielo.**

Una vez que hemos probado que la cámara RGB puede proporcionar curvas espectralradiométricas de luz-cielo con suficiente calidad, en cualquier punto de la bóveda celeste (aunque nosotros sólo hemos trabajado hasta ahora con elevaciones superiores a los 45° desde el horizonte), podemos plantearnos qué hacer con toda esa información multispectral. Por ejemplo, a la vista de la figura 4.10, sabiendo que la curva de la figura 4.10a corresponde a un punto del cielo con presencia de nubes mientras que la 4.10b afecta a un punto del cielo totalmente despejado, podríamos plantearnos utilizar la información de las curvas obtenidas para la detección y clasificación automática de nubes, pues parece claro que

la forma relativa del espectro en ambos casos es bastante diferente. En este caso podríamos incluso normalizar las curvas estimadas (dividiéndolas por su norma  $L^2$ ; ya no necesitaríamos la información radiométrica en  $W/m^2sr$ ) y obtendríamos estimaciones de calidad superior, ya que -como hemos dicho anteriormente- el principal error de las recuperaciones espectrales obtenidas reside en la pobre estimación de la energía global y no en la forma relativa de las curvas. En efecto, si normalizamos todas las curvas a su integral  $L^2$ , obtenemos la tabla 4.4, análoga a la 4.3 pero para curvas normalizadas, en cuyo caso los valores de la métrica IRE(%) son significativamente mejores, y cualquier aplicación práctica que necesitara sólo la forma relativa de los espectros podría utilizar las excelentes estimaciones normalizadas que se obtienen con este sistema RGB. Debemos notar, especialmente, que el valor del GFC obtenido en ambos casos -con y sin normalizar las curvas- es idéntico pues dicha métrica sólo tiene en cuenta la forma relativa de las curvas y es insensible a diferencias de escala [Imai *et al.* 2002, Viggiano 2004, López-Álvarez *et al.* 2005b]

<b>GFC</b> <b>media±SD</b>	<b>CIELAB</b> <b>media±SD</b>	<b>%IRE</b> <b>media±SD</b>	<b>CSCM</b> <b>media±SD</b>
0.9985±0.0032	1.162±0.999	0.699±1.041	2.506±2.462

Tabla 4.4. Resultados de las estimaciones espectrales normalizadas de luz-cielo con la cámara RGB.

En este caso, el percentil 90 de la métrica CSCM tiene el aspecto que mostramos en la figura 4.11, y corresponde con un valor de la misma de 5,69.

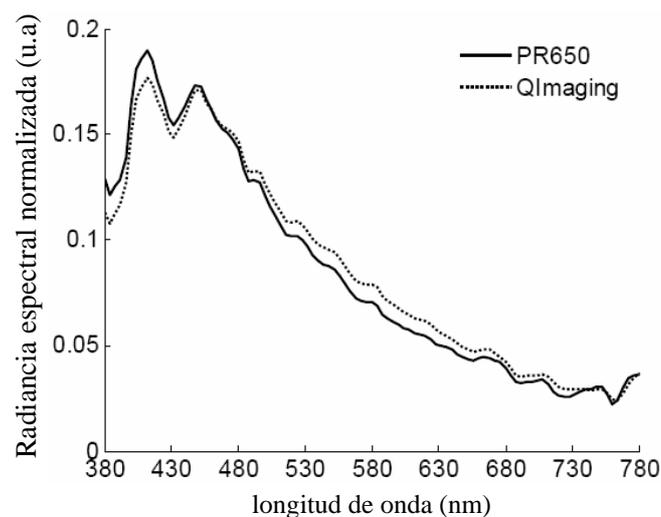


Figura 4.11. Percentil 90 de la métrica CSCM al reconstruir las curvas de radiancia espectral normalizada.

#### 4.4.1.- Estimación del exponente de Angström y del AOD para aerosoles.

La aplicación que decidimos desarrollar utiliza, sin embargo, las curvas espectrales de luz-cielo estimadas sin normalizar ya que necesita de la información radiométrica completa. Restringimos el estudio sólo a aquellas curvas medidas en el cénit por querer estudiar efectos concernientes a la columna vertical de aire sobre el lugar de trabajo. En concreto, vamos a mostrar cómo usando las curvas de radiancia espectral obtenidas, o estimadas, a partir de los valores RGB registrados por la cámara CCD es posible calcular el valor de algunos parámetros que informan sobre el tamaño y la concentración de partículas en suspensión en la atmósfera [Olmo *et al.* 2007] como son el exponente  $\alpha$  de Angström y la profundidad óptica de los aerosoles (AOD del inglés ‘*aerosol optical depth*’), que describiremos rápidamente a continuación. El lector más interesado puede acudir al texto de Goody y Yung [Goody y Yung 1995].

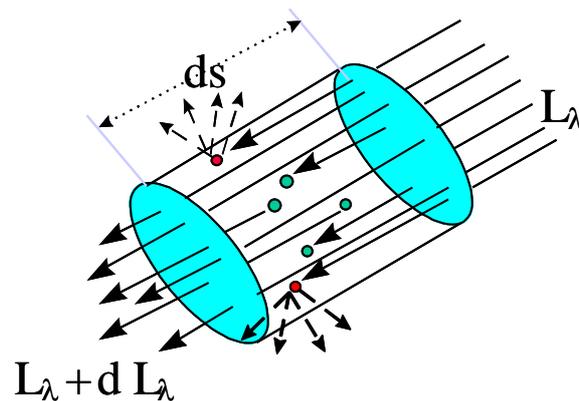


Figura 4.12. Extinción de la radiación entrante  $L_\lambda$  en un camino elemental  $ds$ .

Atendiendo a la figura 4.12, podemos formular la extinción, a lo largo del camino  $ds$ , de la radiación entrante,  $L_\lambda$ , a través de una superficie perpendicular al camino, siguiendo la ley de Beer-Bouguer-Lambert:

$$L_\lambda(s_2) = L_\lambda(s_1) e^{-\int_{s_1}^{s_2} \sigma_{ext\lambda} ds} \quad (4.1)$$

El exponente de la anterior expresión es lo que se conoce como ‘*profundidad óptica*’ en el caso en que la extinción se evalúe sobre la vertical (ver figura 4.13), y se denomina con la letra griega  $\delta$  (el subíndice  $\lambda$  indica que depende de la longitud de onda):

$$\delta_{\lambda} = \int_0^{\infty} \sigma_{ext\lambda} dz \quad (4.2)$$

Donde  $\sigma_{ext\lambda}$  es el *coeficiente de extinción*, magnitud que depende de la densidad del medio, así como de los procesos de difusión (en inglés, ‘*scattering*’) y absorción de radiación que tengan lugar en él. En el caso en que dicha integral se evalúe a lo largo de un camino cualquiera alejado un ángulo  $\theta$  de la vertical, se denomina *espesor óptico*  $\tau_{\lambda}$ :

$$\tau_{\lambda} = \int_0^{\infty} \sigma_{ext\lambda} ds \quad (4.3)$$

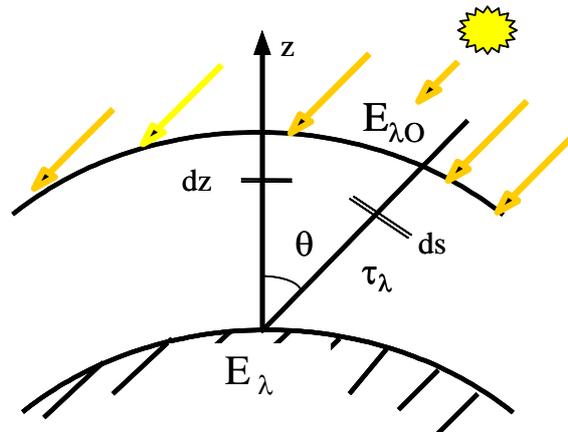


Figura 4.13. Esquema ilustrativo de la diferencia entre espesor óptico y profundidad óptica.

Angström propuso una ley empírica para la dependencia de la profundidad óptica con la longitud de onda por la cual se puede expresar dicho parámetro de la siguiente manera:

$$\delta_{\lambda} = \beta \lambda^{-\alpha} \quad (4.4)$$

Donde el exponente  $\alpha$  da información del tamaño del aerosol en suspensión en la atmósfera.

El interés por definir estos dos parámetros, importantes en el contexto de la Climatología, radica en que es posible calcular su valor en un instante concreto a partir de las estimaciones de radiancia espectral que llevamos a cabo con la cámara RGB. Para ello, se hace uso del software SBDART [Ricchiuzzi *et al.* 1998], que permite obtener curvas de radiancia espectral de luz-cielo (lo que los meteorólogos llaman ‘*componente difusa*’ de la radiación atmosférica) introduciendo como parámetros los valores del exponente  $\alpha$  y del  $\tau_\lambda$ . Se trataría, pues, de ejecutar el programa SBDART con unos valores iniciales para ambos parámetros desconocidos, obtener una curva de radiancia espectral de luz-cielo que compararíamos con la medida con la cámara RGB, y variar el valor de dichos parámetros de forma iterativa hasta que ambas curvas espectrales (la de la cámara y la del software) coincidiesen de forma más o menos aproximada o con un error por debajo de un umbral establecido. En ese momento, los valores de entrada para el exponente  $\alpha$  y el  $\tau_\lambda$  deberían corresponder con los existentes en la atmósfera, que mediremos con un instrumento específico: un CIMEL CE318 [Holben *et al.* 1998], un espectrofotómetro específico para este tipo de medidas (figura 4.14). En la figura 4.15 mostramos un diagrama explicativo de esta búsqueda iterativa.



Figura 4.14. Espectrofotómetro CIMEL CE318.

Una vez que el anterior método alcanza la convergencia, podemos ver (figura 4.16) que la forma de las dos curvas comparadas de radiancia espectral de luz-cielo -la obtenida a partir de las respuestas de la cámara y la estimada por el SBDART- son realmente parecidas. Igualmente, los correspondientes valores de  $\alpha$  y  $\tau_\lambda$  alcanzados entonces son cercanos a los

medidos por el CIMEL, pues la divergencia apenas supera el 14% para el parámetro  $\alpha$  y el 10% para el  $\tau_\lambda$ , como podemos calcular a partir de los datos mostrados en la figura 4.16. Aunque las medidas realizadas hasta el momento en esta línea de trabajo no son suficientes como para establecer una estadística, sí que hemos creído conveniente presentar este ejemplo aislado a modo de resultado previo, que demuestra la utilidad del procedimiento seguido para estimar el valor de estos parámetros climáticos a partir de las imágenes registradas por una cámara CCD tricromática.

*Cálculo del exponente  $\alpha$  y del AOD utilizando la cámara RGB:*

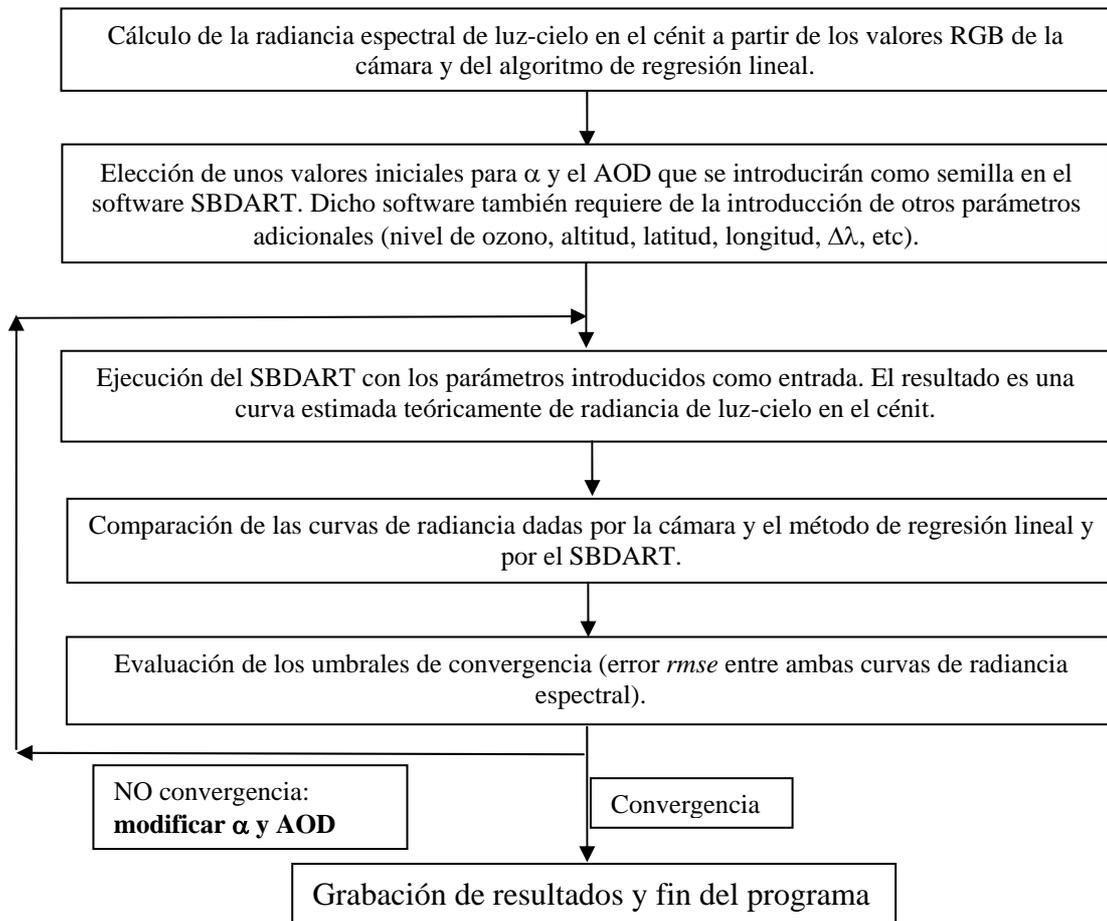


Figura 4.15. Esquema iterativo empleado para el cálculo de  $\alpha$  y  $\tau_\lambda$ .

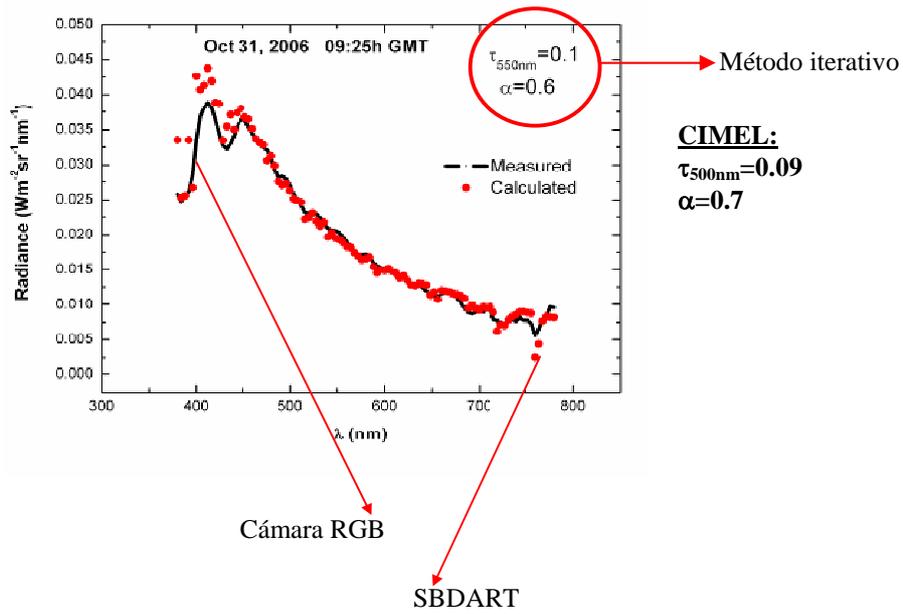


Figura 4.16. Ejemplo de estimación de los parámetros  $\alpha$  y  $\tau_{\lambda}$  usando la cámara RGB y comparación con los datos del CIMEL.



## **5.- APLICACIONES II: MEDIDAS ESPECTRALES DE LUZ-CIELO CON UNA CÁMARA MONOCROMÁTICA Y UN FILTRO LCTF.**

### **5.1.- Descripción del sistema:**

En este capítulo pretendemos aprovechar la versatilidad de un filtro sintonizable de cristal líquido (LCTF, del inglés ‘*Liquid Crystal Tunable Filter*’) para desarrollar un sistema multiespectral que pueda trabajar en múltiples configuraciones. Este filtro permite seleccionar una transmitancia de banda estrecha en torno a cualquier longitud de onda entre 400 nm y 720 nm, como veremos más adelante al hablar de su calibración, y son múltiples los investigadores en sistemas multiespectrales que han optado por utilizar este elemento para ajustar las sensibilidades de los canales de sus sistemas [Hardeberg 1999, Nascimento *et al.* 2002, Imai *et al.* 2002b, Schettini *et al.* 2004, Foster *et al.* 2004, Peralta *et al.* 2007]. En la figura 5.1 podemos ver las características geométricas de este instrumento, que es controlado electrónicamente mediante un adaptador que se conecta fácilmente a cualquier PC.



Figura 5.1. Filtro sintonizable de cristal líquido.

Junto a este elemento, el otro componente fundamental del sistema multiespectral que se diseña en este capítulo es la cámara CCD. En este caso, al contrario que en el capítulo 4, se trata de una cámara monocromática modelo Retiga QImaging SRV1394 con 12 bits, 1392x1040 píxeles y refrigerada hasta los -30°C. De esta forma, al acoplar el filtro LCTF a la

cámara, obtendremos en cada imagen capturada la información del canal o banda espectral correspondiente a aquella seleccionada en el filtro. En la figura 5.2a mostramos la estructura de la cámara, y en la 5.2b cómo se adapta a su objetivo el filtro sintonizable.



(a)



(b)

Figura 5.2. (a) Cámara CCD monocromo. (b) LCTF acoplado a ella.

En la figura 5.3 se aprecia cómo hemos alineado el sistema multiespectral, compuesto por la cámara y el LCTF, con el espectrorradiómetro PR650 para realizar medidas simultáneas que serán comparadas más adelante. Hemos comprobado que, pese a la

separación entre ambos elementos, para medidas de luz-cielo sin presencia de nubes, en las que el objeto se puede considerar suficientemente lejano y es bastante homogéneo espacialmente [Hernández-Andrés *et al.* 2003], la disposición del sistema se puede considerar correcta. Los datos experimentales que presentaremos más adelante en este mismo capítulo corroboran esta afirmación.



Figura 5.3. Disposición del espectrorradiómetro y la cámara con el LCTF en el trípode.

Toda la instrumentación presentada está conectada a un PC portátil que controla los diferentes elementos. Para las medidas con el espectrorradiómetro se realizaron rutinas en Matlab que permitían controlar dicho instrumento a través del puerto serie COM. Para la cámara y el filtro sintonizable, sin embargo, fue necesario programar a más bajo nivel las librerías dadas por el fabricante en un kit de desarrollo de software (SDK, del inglés ‘*Software Development Kit*’) utilizando el lenguaje C++. Todos estos programas de control se integraron en el mismo computador y las medidas se consiguieron programar de forma automática, salvo por la necesidad de poner y quitar el tapón del objetivo necesario para las medidas oscuras (‘*dark current noise*’, ver capítulo 2) que se explican en la sección siguiente.

### **5.2.- Calibración espectral del filtro LCTF.**

En el apéndice I mostramos las curvas de transmitancia espectral que suministra el fabricante del filtro LCTF VariSpec VIS de la casa CRi. En cualquier caso, durante el transporte, este tipo de dispositivos pueden sufrir algún desajuste que dé lugar a variaciones en las transmitancias de los modos del filtro. De hecho, así ocurrió con la primera unidad de este dispositivo que adquirimos, cuya transmitancia espectral cuando se sintonizaba entre los 420 nm y los 460 nm presentaba lóbulos de transmisión no deseada en torno a los 600 nm, y que -por ello- fue sustituida, varios meses después, por una segunda unidad que ya sí funciona correctamente. Este problema pudo ser detectado gracias a la calibración espectral del filtro que llevamos a cabo en nuestro laboratorio.

Para medir las curvas de transmitancia espectral del filtro LCTF debemos tener en cuenta que, como siempre ocurre con dispositivos basados en cristales líquidos, la luz a su salida es linealmente polarizada. Para evitar problemas o falsos errores por atenuación debida a polarización desconocida de la luz incidente, se decidió medir la transmitancia del LCTF incidiendo con luz linealmente polarizada, como así hace el fabricante y otros autores que utilizan dispositivos similares [Peralta *et al.* 2007], cuidando -por supuesto- que el eje de polarización de la luz incidente y la transmitida a través del filtro coincidan.

El filtro LCTF, en este proceso de calibrado, presenta dos problemas adicionales. En primer lugar, su reducida transmitancia obliga a utilizar una fuente luminosa lo suficientemente potente como para poder realizar medidas fiables (no muy afectadas de ruido) con la luz a la salida del filtro. En segundo lugar, la emisión de dicha fuente debe abarcar todo el intervalo que puede barrer el LCTF (desde 400 nm hasta 720 nm) para así poder medir la transmitancia del mismo sin que haya zonas espectrales perdidas. Otros autores han realizado esta tarea utilizando láseres sintonizables y una esfera integradora [Peralta *et al.* 2007], pero en nuestro caso no disponíamos de dicha instrumentación. Para solventar estos problemas, proponemos utilizar la luz-cielo en días despejados como fuente de luz que cumple los anteriores requisitos: es suficientemente potente en todo el espectro visible, y se puede considerar espacial y temporalmente homogénea [Hernández-Andrés *et al.* 2003] dentro de los campos de visión (FOV, del inglés '*Field Of View*') y tiempos necesarios para estas medidas. La luz-cielo presenta, eso sí, el problema de que es elípticamente polarizada, como comentaremos más adelante.

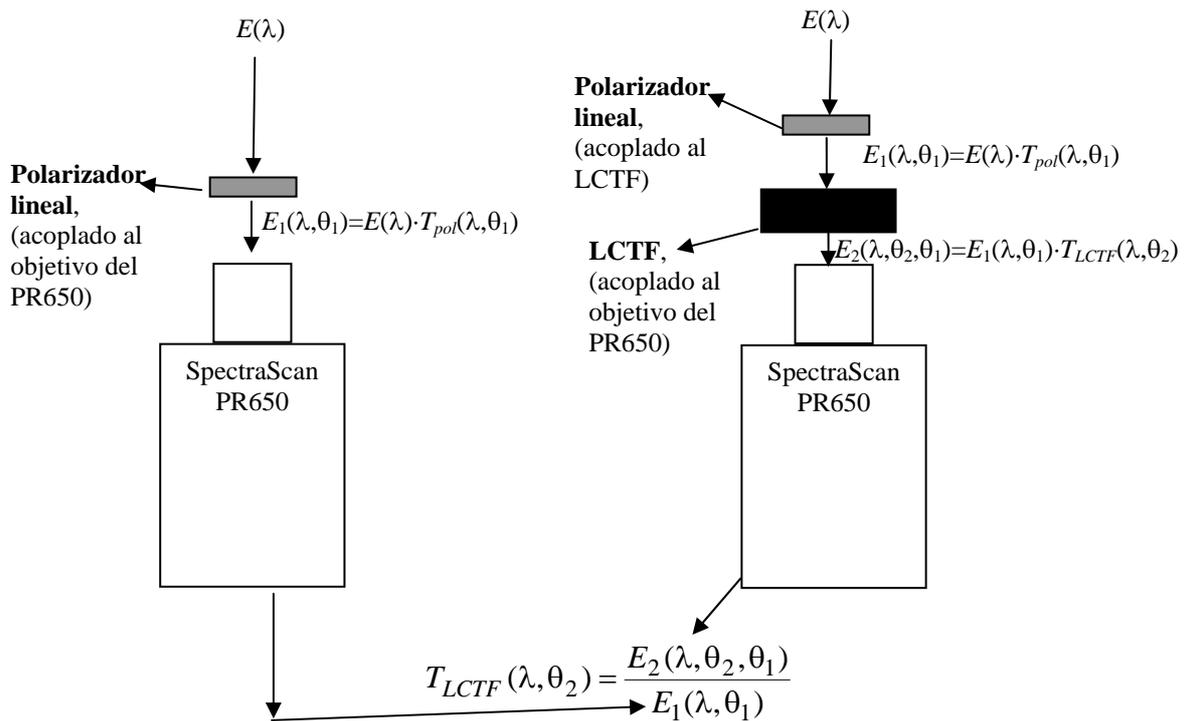


Figura 5.4. Procedimiento para medir la transmitancia del LCTF.

El procedimiento para medir las transmitancias del filtro fue, pues, el siguiente. En primer lugar tomamos un polarizador lineal cuyas líneas de polarización se conocían perfectamente, y se aseguró en todo momento que estuviesen alineadas con las del LCTF para obviar así la dependencia con el ángulo de orientación de los mismos. Con el espectrorradiómetro SpectraScan PR650 apuntando a un punto del cielo cercano al cenit en días despejados se realizaron dos medidas consecutivas (separadas no más de 5 segundos). En la primera de esas medidas se disponía delante del espectrorradiómetro el polarizador lineal, mientras que para la segunda de las medidas se retiraba el polarizador y se añadían el filtro LCTF unido a un polarizador idéntico al primero (siempre asegurando, como decimos, que las líneas de transmisión de todos los elementos polarizadores y del filtro estuviesen perfectamente alineadas). En la figura 5.4 mostramos esquemáticamente el procedimiento seguido. Como hemos dicho, al asegurar la coincidencia de los ejes de polarización de ambos dispositivos, los ángulos  $\theta_1$  y  $\theta_2$  son iguales y no hay dependencia con la orientación (aún así hemos preferido hacerla explícita en lo sucesivo). Debemos indicar que  $T_{pol}(\lambda, \theta_1)$  es la

transmitancia espectral del polarizador,  $T_{LCTF}(\lambda, \theta_2)$  la del filtro sintonizable y  $E(\lambda)$  la radiancia procedente de la bóveda celeste.

Dividiendo la radiancia espectral registrada por el PR650 en la segunda de las medidas entre la obtenida en la primera de ellas, se obtiene la transmitancia espectral del LCTF en el modo en el que esté sintonizado. Esta manera de proceder consigue que se incida con luz linealmente polarizada en el filtro y se obtenga la transmitancia espectral respecto a ese tipo de luz, esto es, si se incide en el filtro con luz natural (sin estado de polarización definido) las curvas de transmitancia tendrían un valor mitad al que calculamos con este procedimiento.

Este tipo de medidas se realizó tres veces para cada uno de los modos disponibles en el LCTF desde los 400 nm hasta los 720 nm en pasos de 10 nm (el LCTF permite, sin embargo, ser sintonizado en ese intervalo cada 1 nm, pero no creímos necesario tener tanta precisión espectral para el resto de este trabajo doctoral). En la figura 5.5. mostramos las curvas de transmitancia espectral obtenidas con este método con sus correspondientes barras de error a lo largo de las tres series. Dichas curvas prácticamente coinciden con las proporcionadas por el fabricante y las obtenidas por otros autores para dispositivos idénticos [Peralta *et al.* 2007, Foster *et al.* 2004].

### **5.3.- Calibración de la cámara.**

En esta sección explicamos todo el proceso de calibrado radiométrico de una cámara CCD [Healey y Kondepudy 1994, Ferrero *et al.* 2006b, de Lasarte *et al.* 2007], para lo cual es necesario corregir el efecto de las diferentes fuentes de ruido vistas en el capítulo 2 y estudiar la respuesta del sensor CCD a la radiación recibida en función de la longitud de onda. La mayoría de las medidas necesarias para el calibrado completo de nuestra cámara Retiga QImaging SRV1394 se llevaron a cabo en los laboratorios del IFA en el CSIC en Madrid, utilizando una esfera integradora iluminada convenientemente como campo homogéneo, y como fuente de luz dos tipos de láser sintonizable (iónico de Argón y de colorante) o -en otras ocasiones- una lámpara de incandescencia. Otra serie de medidas, por el contrario, se realizaron con una esfera integradora y un láser sintonizable iónico de Argón (de la casa Melles Griot) en los laboratorios del Departamento de Óptica de la Universidad de Granada en colaboración con los profesores Rubiño y Pozo. En los siguientes apartados explicamos con detalle todo el proceso de la calibración y el equipo empleado en cada circunstancia.

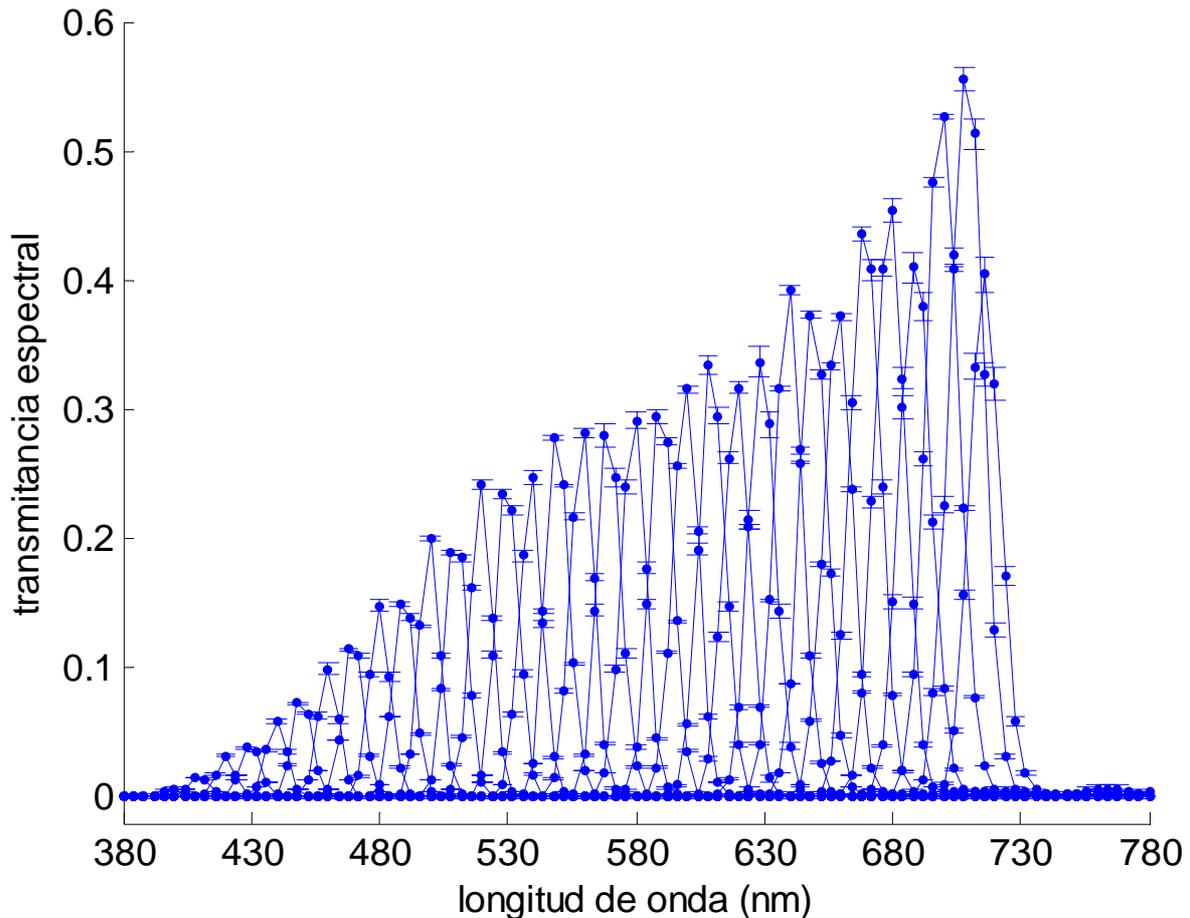


Figura 5.5. Transmitancia espectral de los modos del filtro LCTF desde 400 nm hasta 720 nm cada 10nm

### 5.3.1.- Ruido temporal de alta frecuencia.

En primer lugar debemos estimar el ruido temporal de alta frecuencia [Healey y Kondepudy 1994] que afecta al CCD. Por ruido de alta frecuencia entendemos aquel cuya variación es suficientemente rápida como para poder detectarlo en intervalos de menos de un minuto [Ferrero *et al.* 2006c]. Este tipo de ruido puede suprimirse si se toman una serie de imágenes consecutivas y son promediadas. El objetivo principal de este primer experimento es, por tanto, calcular cuántas imágenes es necesario tomar y promediar en cada medida que se realice con el CCD.

El montaje experimental es el mostrado en la figura 5.6. Contábamos con una esfera integradora de 50cm de diámetro por uno de cuyos puertos de entrada introducíamos luz policromática procedente de una lámpara de incandescencia (alimentada con corriente estabilizada a 125V y 3A) refrigerada por un ventilador. Se utilizaba un difusor rotatorio para

conseguir mayor uniformidad en la esfera integradora. El puerto de salida de la esfera se situaba a  $90^\circ$  del puerto de entrada y tenía 10cm de diámetro. Frente a éste situábamos la cámara CCD en un rail de manera que el objetivo de la cámara estuviese perfectamente alineado con el rail y centrado frente al puerto de salida.

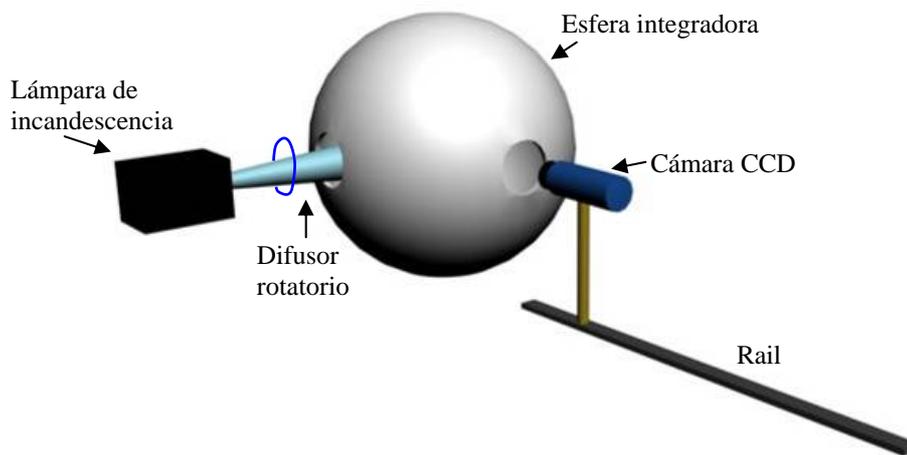


Figura 5.6. Montaje experimental para medir el ruido de alta frecuencia. La iluminación en la esfera integradora es policromática en este caso.

Se acercó la fuente luminosa al puerto de entrada de la esfera integradora hasta que la señal recibida por la cámara, trabajando con un tiempo de exposición de 10ms, estaba cerca del valor máximo pero sin llegar a saturarla. El nivel de señal promedio para este experimento se buscó cercano a las 3500 cuentas (sobre un máximo de 4095, correspondiente a 12 bits).

Se tomaron series de  $p = 20, 50, 80, 150, 200$  y  $300$  imágenes para estudiar la dependencia del promedio temporal de cada píxel,  $\bar{C}_i$ , y su desviación estándar,  $\sigma(\bar{C}_i)$  que es una estimación del ruido temporal de alta frecuencia, con el número de muestras usadas para promediar. Al hacer dicho promedio, se elimina este tipo de ruido. En la figura 5.7 vemos cómo al aumentar el tamaño de la serie, la cantidad eliminada de ruido temporal de alta frecuencia se estabiliza. Se ha estimado para este caso particular que para eliminar la práctica totalidad de este tipo de ruido son necesarias al menos 100 imágenes por serie.

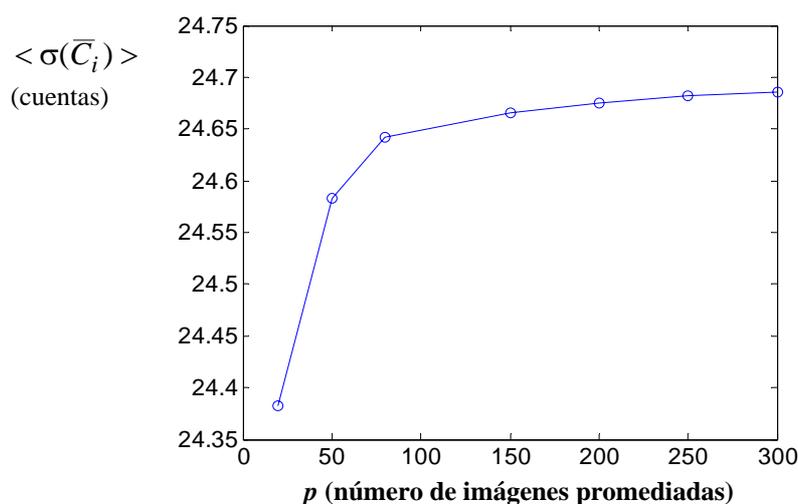


Figura 5.7. Ruido temporal de alta frecuencia eliminado en función del número de imágenes promediadas.

### 5.3.2.- Variación del ruido de alta frecuencia con el tiempo de exposición.

En este apartado pretendemos determinar si existe dependencia del ruido temporal de alta frecuencia con el tiempo de exposición y la longitud de onda. En un experimento similar al descrito en el apartado anterior se hacía incidir la luz procedente del láser sintonizable de Ión-Argón de Granada sobre una esfera integradora de 10 cm de diámetro en este caso. Las longitudes de onda seleccionadas para este experimento fueron 454 nm, 514 nm y 632,8 nm (ésta última obtenida a partir de un láser de He-Ne y no del sintonizable). El montaje experimental se dibuja en la figura 5.8. Se utilizó un difusor rotatorio a la entrada de la esfera integradora para evitar que se formase un patrón de speckle en la misma.

Se repitieron las medidas del apartado anterior para estimar el número de imágenes que deben ser promediadas para eliminar el ruido temporal de alta frecuencia existente en la cámara. Se tomaron series de  $p = 20, 80, 150$  y  $300$  imágenes que serían promediadas más tarde. Sin embargo, en esta ocasión estudiamos la desviación estándar espacial de la imagen promedio resultante, esto es, el ruido espacial residual tras el promedio temporal que elimina el ruido temporal de alta frecuencia. Se realizaron las experiencias para tiempos de exposición comprendidos entre 7ms y 1s, y para las tres longitudes de onda mencionadas anteriormente con el propósito de visualizar la posible dependencia del ruido con ambos parámetros. En todo momento, el número medio de cuentas registrado en la CCD fue de 3500 (sobre 12 bits) y la temperatura del CCD se mantuvo a  $-30\text{ }^{\circ}\text{C}$  gracias al sistema de refrigeración disponible,

con lo cual se elimina la conocida influencia de estos dos parámetros en el ruido de la cámara [Ferrero *et al.* 2006c].

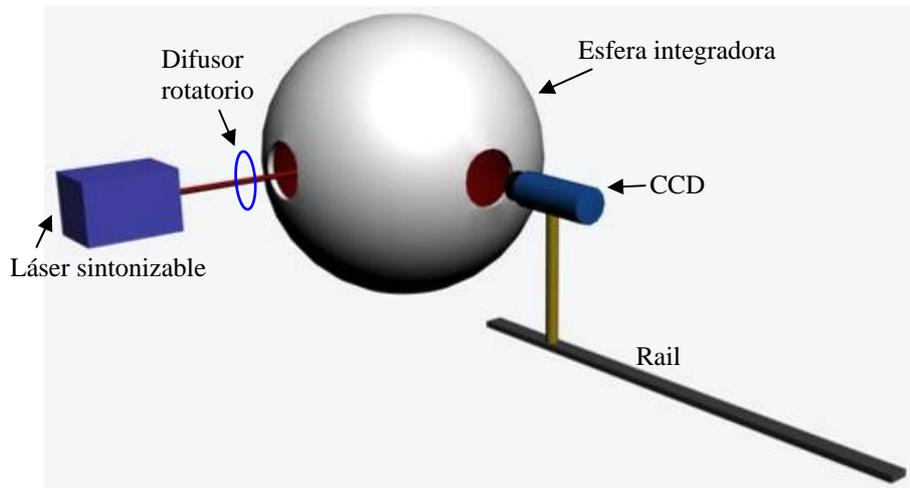


Figura 5.8. Montaje experimental para obtener un campo homogéneo en la esfera integradora con luz monocromática.

En la figura 5.9 podemos ver los resultados obtenidos para una longitud de onda de la radiación incidente en la esfera de 514nm. Debemos notar que no encontramos diferencias significativas entre los resultados para distintas longitudes de onda. Se aprecia en dicha figura cómo al aumentar el tiempo de exposición aumenta el ruido remanente en la imagen. Este aumento es significativamente mayor para el caso de 1s de tiempo de exposición. La explicación de este fenómeno la encontramos en el ruido tipo flicker o  $1/f$  (descrito en el capítulo 2), que aumenta con el tiempo de exposición. Mientras, el ruido térmico y el ruido tipo shot sólo dependen, respectivamente, de la temperatura del CCD y del nivel de señal registrado, parámetros que permanecieron constantes durante todo el experimento.

Las curvas para tiempos de exposición por debajo de 100ms en la figura 5.9 presentan niveles de ruido similares ya que en esos casos el ruido tipo flicker es menos significativo que el térmico y el shot (ambos son ruidos de tipo 'blanco', que no dependen del tiempo de exposición). Es decir, trabajando con tiempos de exposición pequeños se puede eliminar el efecto del ruido tipo flicker, pero siempre habrá un límite de ruido mínimo impuesto por el ruido térmico, que se puede reducir disminuyendo la temperatura del CCD, y el ruido tipo shot, que aumenta al aumentar el nivel de señal registrado por la CCD.

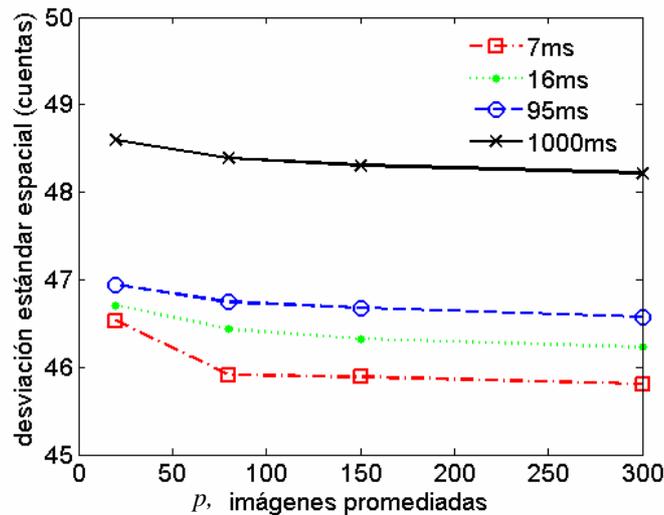


Figura 5.9. Ruido espacial residual para 514nm.

En cualquier caso, podemos apreciar también en la figura 5.9 que el número de imágenes que se deben promediar para eliminar de manera adecuada el ruido temporal (tras hacer el promedio de dichas imágenes) vuelve a ser de 100 aproximadamente, ya que si se promedian menos imágenes aún existe un elevado ruido temporal, y si se promedian más se consigue poca mejora. Esta variable  $p$  (el número de imágenes que se deben promediar) parece, pues, un parámetro fijo de cada CCD, ya que es independiente del tiempo de exposición o la composición espectral de la fuente radiante.

### 5.3.3.- Ruido temporal de baja frecuencia.

En este apartado se realizaron una serie de medidas encaminadas a evaluar el ruido temporal de baja frecuencia, que afecta a la cámara si se utiliza durante periodos de tiempo de más de un minuto [Ferrero *et al.* 2006c]. Es importante comprobar que la respuesta individual de los píxeles de toda la matriz CCD y el promedio espacial de éstos presentan un comportamiento similar durante largos períodos de tiempo, ya que de no ser así no tendrían validez los algoritmos de corrección espacial -que veremos más adelante- pues dicha corrección variaría con el tiempo. El experimento llevado a cabo para estudiar el ruido de baja frecuencia permite, como veremos, estudiar el comportamiento individual de cada píxel en comparación con el del promedio espacial a lo largo de toda la matriz, y permite también encontrar píxeles anómalos en la misma [Ferrero *et al.* 2006c].

Para ello, se tomaron series de 100 imágenes separadas 5 minutos durante tres horas (36 series en total) en ausencia de iluminación, para evitar en la medida de lo posible el ruido de alta frecuencia (principalmente de tipo ‘shot’) que es incrementado al crecer el valor de la señal registrada, como se dijo en el capítulo 2. Se registra, pues, únicamente la señal ‘dark noise’, utilizando para ello tiempos de exposición de 10ms en todo el experimento.

En cada una de las 36 series, se calcula el promedio temporal a lo largo de las 100 muestras de la diferencia entre el valor de cada píxel  $C_i$  y el promedio espacial en toda la CCD  $\langle C \rangle$ , es decir,  $\overline{C_i - \langle C \rangle}$ . También se calcula la desviación estándar  $\sigma(\overline{C_i - \langle C \rangle})$  a lo largo de las 36 series, pues es una estimación de cómo fluctúa en el tiempo la respuesta de cada píxel individual en relación con el promedio espacial en toda la CCD. En otras palabras, nos mostrará si la respuesta de los píxeles individuales va *al unísono* con la del promedio espacial y si se puede -por tanto- estudiar el promedio espacial como indicador de lo que ocurre para todos los píxeles del CCD y si dicha equiparación es estable en el tiempo.

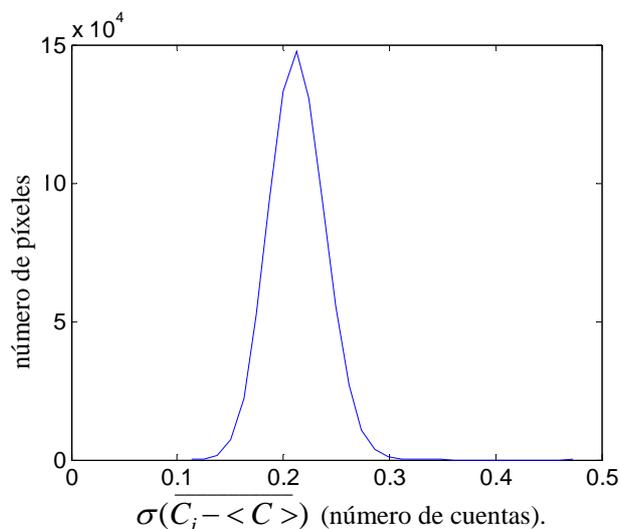


Figura 5.10. Histograma de  $\overline{\sigma(C_i - \langle C \rangle)}$  para la CCD estudiada.

En la figura 5.10 vemos un histograma que muestra la cantidad de píxeles que presentan un determinado valor de la anterior desviación estándar. Al contrario de lo que otros autores han encontrado para otras CCD [Ferrero *et al.* 2006c], en este caso el histograma sólo presenta una cola indicando que -en principio- no se ha encontrado ningún píxel en esta cámara con un comportamiento anormal que no siga *al unísono* el promedio espacial.

Podemos ver que dicho histograma está centrado en un valor para la desviación estándar  $\overline{\sigma(C_i - \langle C \rangle)}$  cercano a 0,22, lo que corresponde teóricamente [Ferrero *et al.* 2006c] con un valor para el ‘*readout noise*’ [Healey y Kondepudy 1994] (única fuente de ruido de alta frecuencia presente en este experimento) de 2,2 cuentas, que es el valor experimental dado por el fabricante para este tipo de ruido en esta cámara (ver apéndice II). Este cálculo ha sido realizado de acuerdo con las ecuaciones presentadas por A. Ferrero [Ferrero *et al.* 2006c] para un experimento similar, donde el ruido de alta frecuencia (‘*dark noise*’, ‘*readout noise*’ y ‘*shot noise*’), que notaremos como  $\sigma(a_i)$ , afecta a la magnitud  $\overline{\sigma(C_i - \langle C \rangle)}$  -que estamos usando como indicador del comportamiento *al unísono* de los píxeles del CCD- en la forma:

$$\overline{\sigma(C_i - \langle C \rangle)} = \sqrt{\frac{\sigma^2(a_i)}{p} \left(1 + \frac{1}{M}\right)} \quad (5.1)$$

donde  $p$  es el número de muestras usadas para hacer el promedio temporal (100 en nuestro caso) y  $M$  es el número total de píxeles de la CCD. El acuerdo de esta ecuación con el comportamiento experimental de las cámaras del CSIC y de la aquí estudiada valida por completo el modelo teórico presentado en el trabajo de A. Ferrero [Ferrero *et al.* 2006c].

En la figura 5.11 mostramos un diagrama 2D con el valor de  $\overline{\sigma(C_i - \langle C \rangle)}$  para cada píxel de la matriz CCD, donde vemos que no hay ningún conjunto de píxeles que se aleje significativamente del promedio espacial a lo largo de las 3 horas que duró el experimento. Podemos decir, por tanto, que todos los píxeles de la cámara presentan una respuesta *al unísono*, y que es posible aplicar los algoritmos de corrección espacial sobre la respuesta de la cámara ya que ésta no va a variar con el tiempo (dentro de los límites estudiados aquí).

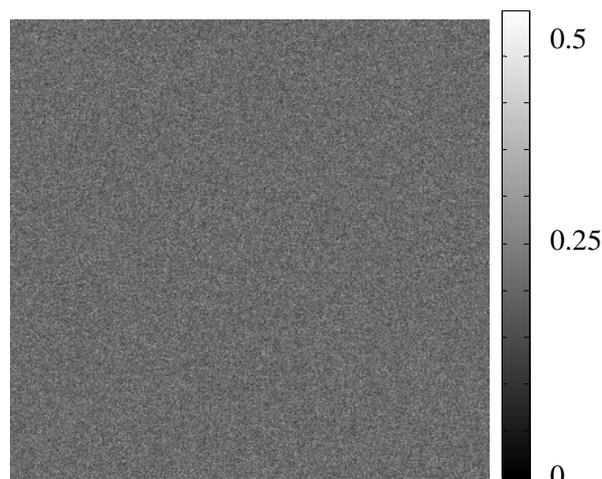


Figura 5.11. Diagrama 2D de  $\sigma(C_i - \langle C \rangle)$  para cada píxel individual.

Es posible repetir este experimento pero haciendo incidir una radiancia uniforme sobre la CCD utilizando el montaje de la figura 5.6, de manera que se obtengan unas 3000 cuentas de respuesta. En ese caso, obtenemos un histograma muy similar al de la figura 5.10, pero centrado en un valor de  $\sigma(C_i - \langle C \rangle) = 2,5$ , lo que indica que el ruido temporal residual (compuesto por ‘shot noise’ y ‘readout noise’ en este caso) es de 25 cuentas en promedio aproximadamente para cada imagen individual [Ferrero *et al.* 2006c].

Para finalizar el estudio del comportamiento *al unísono* de los píxeles de esta CCD, se analizó cómo variaba durante la primera hora del experimento el promedio espacial de las respuestas de la matriz en comparación con la respuesta individual de algunos píxeles. En la figura 5.12 se ve cómo tanto el promedio espacial como los píxeles individuales, elegidos al azar, varían de forma similar a lo largo del experimento, mostrando que para esta cámara es plausible la suposición de que el ruido temporal de baja frecuencia afecta por igual a toda la matriz CCD, y que -por tanto- la aplicación de algoritmos de corrección espacial será invariante frente al tiempo. Asimismo, también se podrá aplicar con libertad la suposición de que el comportamiento del promedio espacial es representativo del comportamiento de cada píxel individual, como haremos más adelante en varias experiencias, ya que esto simplifica mucho el estudio cualitativo del ruido en sensores CCD.

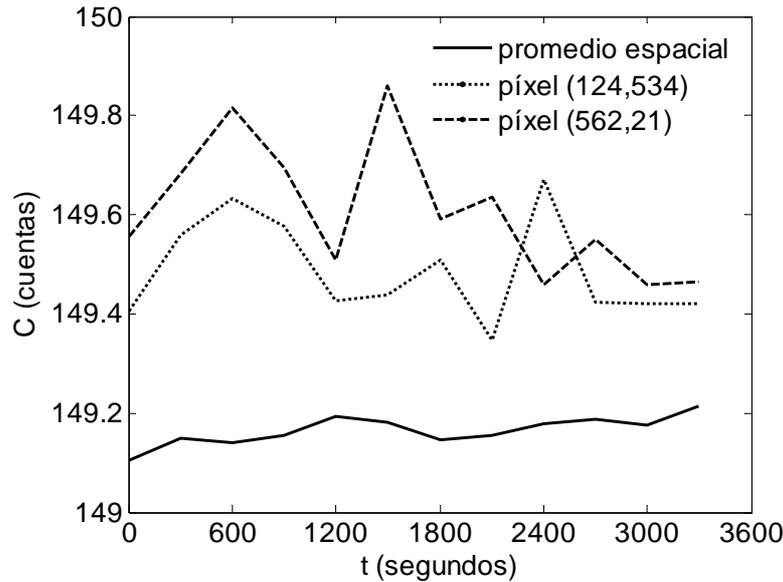


Figura 5.12. Evolución temporal del valor en oscuridad de varios píxeles y del promedio espacial.

### 5.3.4. Ley de reciprocidad.

La respuesta de un píxel perteneciente a una matriz CCD,  $C_i$ , se puede modelar como [Ferrero *et al.* 2006b]:

$$C_i = C_{o,i} + R_i E_i t_{exp} \quad (5.2)$$

En teoría, si la responsividad  $R_i$  es constante, la respuesta de la cámara se mantiene constante si el producto  $E_i t_{exp}$  no varía. Por tanto, podemos -por ejemplo- duplicar el tiempo de exposición y reducir a la mitad la radiancia incidente manteniendo constante la respuesta de la cámara. Esto es lo que se conoce como ‘ley de reciprocidad’ [Ferrero *et al.* 2006]. Sin embargo, hay resultados que muestran que esta reciprocidad no se cumple bajo ciertas condiciones. En el siguiente experimento estudiaremos para qué tiempos de exposición es admisible la anterior ley, es decir, estudiaremos la dependencia de  $R_i$  con  $t_{exp}$ .

Con el montaje experimental mostrado en la figura 5.6, se tomaron series de 100 imágenes - y sus correspondientes imágenes oscuras- con diferentes tiempos de exposición entre 10 $\mu$ s y 100ms. Se calculó el cociente de la expresión  $\frac{C_i - C_{o,i}}{t_{exp}}$  para cada píxel a partir de los correspondientes promedios temporales, como se ha explicado en la sección 5.2.1, para

eliminar el ruido de alta frecuencia. El anterior cociente corresponde al ratio entre la responsividad  $R_i$  y la radiancia  $E_i$  que en este caso no fue medida. No es necesario medir la radiancia en este punto, pues si normalizamos las responsividades al valor de la misma para 100ms, podemos estudiar la variación relativa de esta magnitud con el tiempo de exposición, ya que en todo caso no estamos por ahora interesados en su valor absoluto [Ferrero *et al.* 2006] sino sólo en ver su dependencia con el tiempo de exposición.

En la figura 5.13 podemos ver cómo varía el promedio espacial de la responsividad normalizada al valor para tiempo de exposición de 100ms,  $\langle R^p \rangle$ . Como dijimos en la sección anterior, podemos suponer que el promedio espacial es significativo del comportamiento de todos los píxeles de la matriz CCD ya que estos presentan un comportamiento *al unísono*. Se aprecia claramente en dicha figura que para tiempos de exposición por debajo de 1ms la responsividad varía significativamente con el tiempo de exposición. Por tanto, si queremos trabajar en condiciones de cumplimiento de la ley de reciprocidad, deberemos siempre utilizar tiempos de exposición superiores a 4ms aproximadamente, ya que en ese caso las variaciones de la responsividad son inferiores al 2% (dicho límite se indica en la figura 6 mediante sendas rectas).

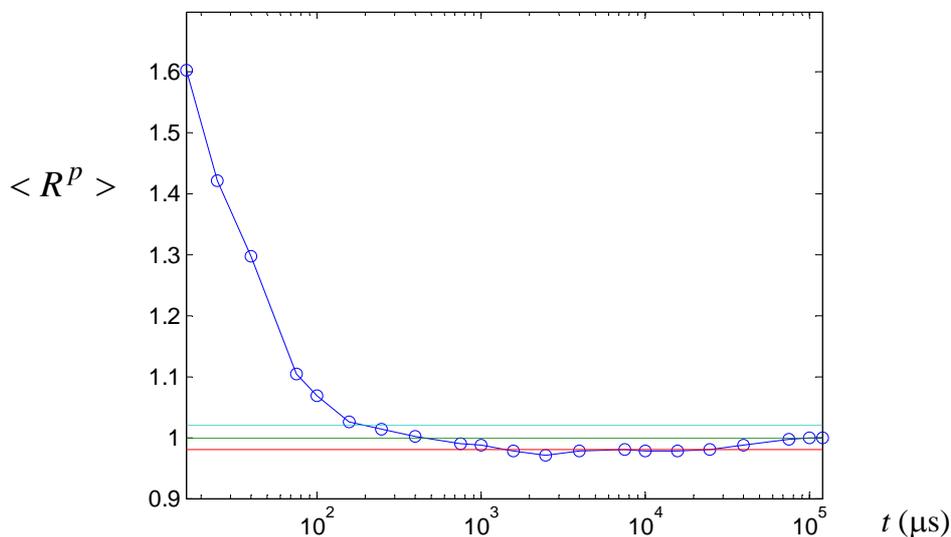


Figura 5.13. Promedio espacial de la responsividad relativa en función del tiempo de exposición.

También se ha podido comprobar que la responsividad depende de otros muchos factores como la apertura del objetivo, la longitud de onda o la apertura numérica del haz

incidente en el CCD. Para el lector interesado, recomendamos la referencia [Ferrero *et al.* 2006].

### 5.3.5.- No linealidad y no uniformidad.

Se puede comprobar experimentalmente que la responsividad  $R_i$  de un píxel -lejos de ser constante- también depende del número de electrones que se recogen en dicho píxel de la CCD, es decir, del número de cuentas  $C_i$  registrado, incluso si trabajamos con tiempos de exposición para los que se cumple la ley de reciprocidad (según el apartado anterior, sería a partir de 4ms). Este es un efecto no-lineal que se puede estimar y corregir aunque sea de forma aproximada. En efecto, si retomamos la ecuación (5.2) podemos expresar la responsividad ideal como:

$$R_i = \frac{C_i - C_{o,i}}{E_i t_{\text{exp}}} \quad (5.3)$$

Sin embargo, debemos añadir un término que tenga en cuenta el efecto no lineal al que antes aludíamos, lo llamaremos  $r^{LN}$  que dependerá del número de cuentas registrado  $C = C_i - C_{o,i}$  en la CCD [Ferrero *et al.* 2006d]:

$$R_i^0(\lambda) = \frac{C_i - C_{o,i}}{E_i t_{\text{exp}} r^{LN}(C)} \quad (5.4)$$

Se ha encontrado experimentalmente que si se corrige este efecto no lineal dependiente del número de cuentas, la responsividad ya sólo depende de la longitud de onda, aunque sigue presentando variaciones espaciales píxel a píxel (no-uniformidad espacial) que discutiremos más tarde. Por ello, distinguiremos en adelante:

$$R_i(\lambda) = R_i^0(\lambda) r^{LN}(C) = \langle R_i^0(\lambda) \rangle r^{NU}(\lambda) r^{LN}(C) \quad (5.5)$$

donde se ha separado explícitamente la variación de la responsividad por efectos no lineales con el número de cuentas ( $r^{LN}$ ) y por efecto de la no-uniformidad espacial ( $r^{NU}$ ), ya que el promedio espacial  $\langle R_i^0(\lambda) \rangle$  es una constante. La dependencia con la longitud de onda queda explícita en la ecuación (5.5). Así pues, estudiaremos en primer lugar cómo medir  $r^{LN}$  y más adelante en esta misma sección mediremos  $r^{NU}$ . La dependencia con la longitud de onda  $\langle R_i^0(\lambda) \rangle$  se estudiará en la sección siguiente.

En este apartado trataremos de medir el factor de no-linealidad para tiempos de exposición superiores a 4 ms, asegurándonos así de que eliminamos toda la variación de la responsividad con el tiempo de exposición. Para ello, utilizamos el montaje experimental de la figura 5.6 situando la fuente luminosa a una distancia del puerto de entrada de la esfera integradora tal que para un tiempo de 4 ms se obtenían algo más de 500 cuentas. El tiempo de exposición se elevó hasta los 10 ms, manteniendo constante la radiancia de salida de la esfera integradora, para los que se obtenían en torno a 3000 cuentas (eliminando ya la imagen oscura). De esta manera aseguramos que se trabaja en el intervalo de tiempos de exposición donde se cumple la ley de reciprocidad y además barreos prácticamente todo el intervalo de posibles cuentas registradas por la cámara.

En la figura 5.14 podemos apreciar los valores promedio para toda la matriz CCD obtenidos para el factor de no-linealidad  $r^{LN}$  en función del número de cuentas registradas  $N$  (eliminando ya la señal oscura). Podemos apreciar cómo dicho factor comienza a decaer si el número de cuentas registradas es inferior a 2500 aproximadamente, haciendo necesario -por tanto- introducir dicho factor de corrección como aparece en la ecuación (5.4) para tratar de conseguir una responsividad corregida constante. En la misma figura se muestran las barras de error correspondientes a la desviación típica (SD, en inglés ‘*Standard Deviation*’) de  $r^{LN}$  a lo largo de toda la matriz CCD. Igualmente, se han ajustado los puntos experimentales a un polinomio de grado 2 (mostrado en la figura 5.14 como una línea continua) que será el que se utilice en futuras correcciones. El error de este ajuste es pequeño comparado con los errores causados por el ruido temporal y espacial, como mostramos en la figura 5.15. Esto es debido, sin duda, a que contamos con pocos puntos experimentales para realizar dicho ajuste, pero consideramos que son suficientes para aplicar este algoritmo de corrección en el futuro.

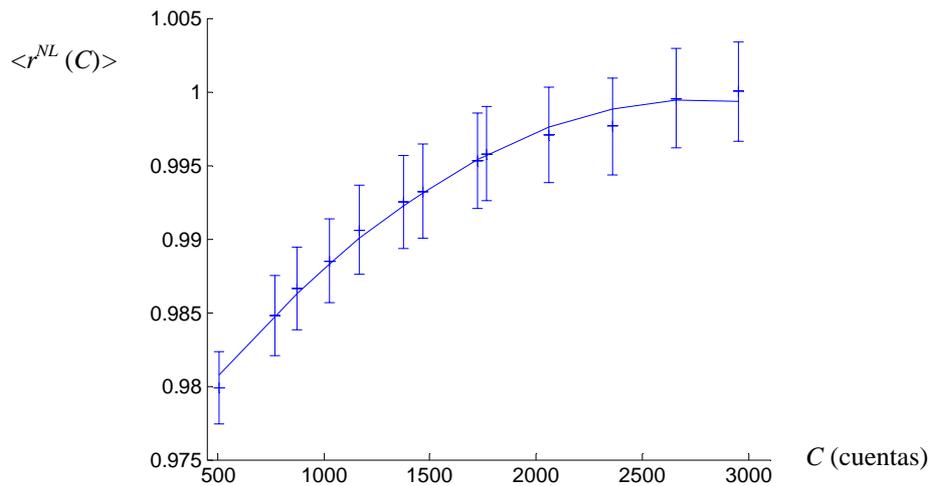


Figura 5.14. Promedio espacial del factor de corrección no-lineal en función del número de cuentas. Las barras de error muestran la desviación estándar a lo largo de la matriz CCD.

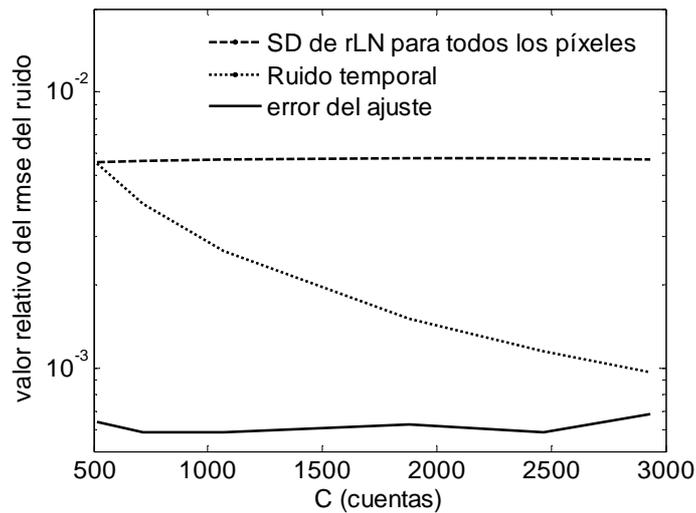


Figura 5.15. Comparación del ruido espacial y temporal con la incertidumbre en el ajuste de  $r^{LN}$ .

En la figura 5.16 mostramos el promedio espacial de la responsividad  $\langle R_i^0(\lambda) \rangle$  corregida con el factor  $r^{LN}$  que acabamos de ajustar y normalizada a su valor en 10ms, en función del número de cuentas registradas por la cámara CCD. Podemos notar cómo la responsividad varía de forma aleatoria (no monótona como hacía en la figura 5.14), y dicha variación no es superior al 1%. De esta forma hemos conseguido ampliar el intervalo de validez de la ley de reciprocidad a cualquier número de cuentas entre 500 y 3000 cuentas.

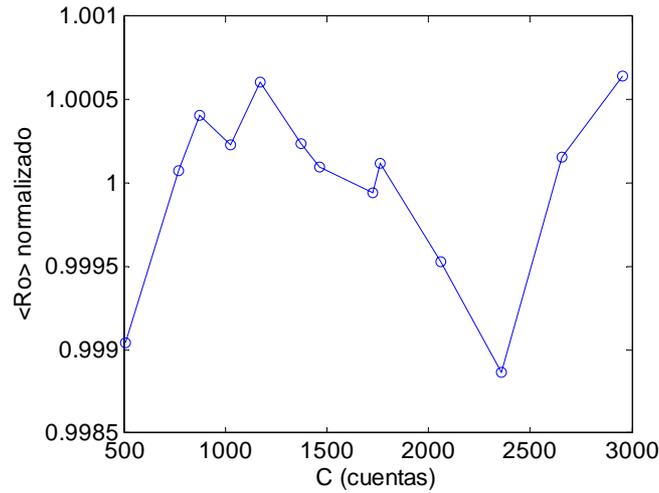


Figura 5.16. Promedio espacial de la responsividad corregida y normalizada a su valor en 10ms en función del número de cuentas registradas en la CCD.

Para finalizar este apartado, calcularemos ahora el último de los factores de corrección [Ferrero *et al.* 2006d] que aparecían en la ecuación (5.5), y que se refiere a la no-uniformidad espacial,  $r^{NU}$ . Las fuentes de esta falta de uniformidad espacial son diversas [de Lasarte *et al.* 2007], pero quizás la más acentuada sea el efecto de atenuación que produce el objetivo conforme nos acercamos a los bordes de la imagen. En este estudio, calcularemos este factor de acuerdo a la siguiente expresión, fácilmente obtenible a partir de las ecuaciones (5.5), (5.4) y (5.2):

$$r_i^{NU}(\lambda) = \frac{C_i - C_{o,i}}{r_i^{LN}(C) \langle R_i^0(\lambda) \rangle E(\lambda) t_{\text{exp}}} \quad (5.6)$$

Como Ferrero discute [Ferrero *et al.* 2006d], y como podemos observar a la vista de la ecuación (5.6), la principal ventaja de este método es que se consigue separar la dependencia espectral de la no uniformidad espacial de otros factores con mayor influencia. Otros autores [Healey y Kondepudy 1994] han utilizado otros algoritmos de corrección espacial (llamados flat-field correction algorithms) sin estudiar la dependencia de esta corrección con la longitud de onda. Esto invalidaba la corrección si se cambiaba de iluminante  $E$  por ejemplo. Sin embargo, siguiendo el procedimiento aquí expuesto, en primer lugar se corrige la no linealidad (cuya influencia relativa sobre la falta de constancia en la responsividad es bastante acentuada), y más tarde se corrige la no uniformidad espacial que depende de la longitud de onda, cuya influencia relativa es menor. Para ser correctos, se debe medir  $r^{NU}$  en cada

longitud de onda por separado para aplicar una corrección exacta [Ferrero *et al.* 2006d]. Sin embargo, como su influencia es relativamente pequeña en comparación a la de  $r^{LN}$  -que no depende de  $\lambda$ - el algoritmo es igualmente aplicable (aunque sólo sea de forma aproximada) para cualquier contenido espectral del iluminante  $E$ . Una vez que ambos factores de corrección son conocidos, la respuesta corregida de la CCD se calcula según [Ferrero *et al.* 2006d]:

$$C_i^c = \frac{C_i - C_{o,i}}{r_i^{LN}(C)r_i^{NU}(\lambda)} \quad (5.7)$$

La magnitud  $C_i^c$  es lineal con el tiempo de exposición y con la radiancia a lo largo de la matriz CCD para cualquier número de cuentas registrado, con lo cual la corrección aplicada permite utilizar la cámara para medidas radiométricas de forma correcta. En la figura 5.17 mostramos el efecto de esta corrección completa en la desviación típica (SD) a lo largo de la matriz CCD de una imagen de un campo de radiancia uniforme. Como vemos, la no uniformidad en la responsividad se reduce, para 3000 cuentas, aproximadamente del 3% al 0.27% una vez que la ecuación (5.10) se aplica sobre las imágenes registradas en la cámara.

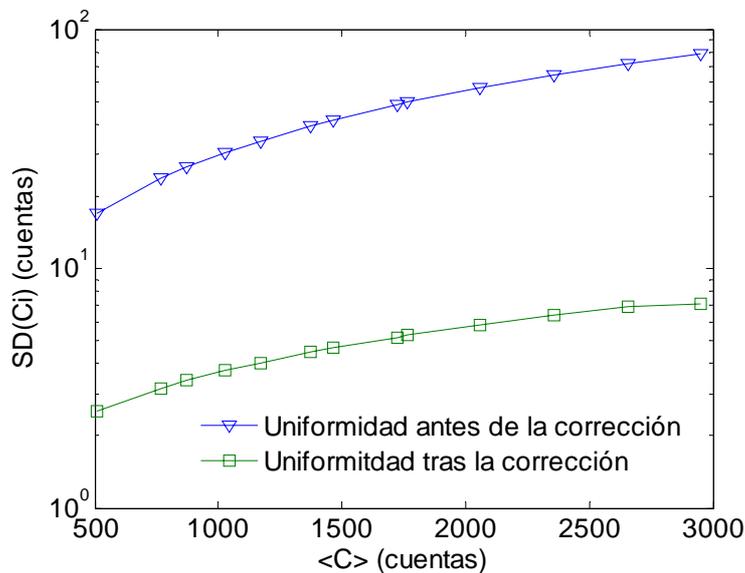


Figura 5.17. Mejora de la uniformidad espacial tras aplicar el algoritmo de la ecuación (5.7).

En la figura 5.18 podemos apreciar cómo varía una imagen de un campo homogéneo tras aplicar la corrección. La variación espacial se reduce en un 2.5% en promedio. La mayor falta de uniformidad se da hacia los bordes. Al tratarse de un efecto determinista [Ferrero *et al.* 2006d], se puede evaluar y corregir, mejorando sensiblemente la funcionalidad radiométrica de la cámara CCD. Debemos notar que esta figura fue corregida según unos factores  $r^{LN}$  y  $r^{NU}$  calculados para un iluminante distinto al utilizado al registrar la imagen, probando que el algoritmo de corrección presentado es totalmente general.

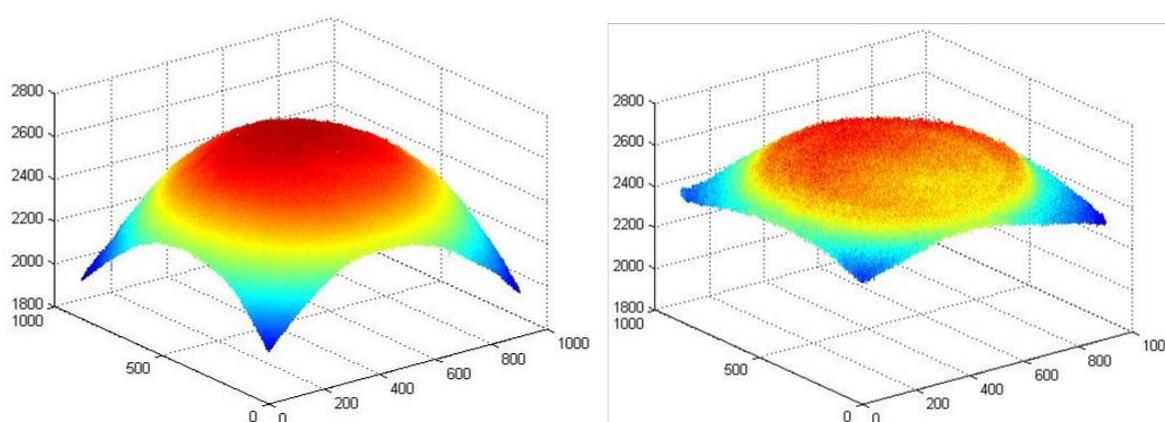


Figura 5.18. Imagen de un campo homogéneo antes y después de aplicar la corrección.

### 5.3.6.- Calibración espectral.

La calibración espectral completa de la cámara CCD en todo el espectro visible es una tarea ardua si se pretende realizar con el montaje experimental mostrado en la figura 5.8, pues ningún láser sintonizable es capaz de barrer todo el intervalo deseado. Por ello, es necesario utilizar diferentes fuentes de radiación monocromática incidentes en la esfera integradora si se desean realizar las medidas radiométricas necesarias para esta calibración siguiendo dicha configuración.

En esta sección también presentamos una configuración alternativa que aprovecha la monocromaticidad de la luz a la salida de un filtro LCTF y la gran cantidad de energía luminosa que procede de la bóveda celeste en días despejados. Veremos que dicha configuración también es apropiada para la calibración espectral de la cámara, y permite medir su respuesta en el intervalo completo de variación del filtro, en nuestro caso desde

400nm hasta 720nm. Veremos que los resultados coinciden con los de la configuración anterior en aquellas regiones del espectro visible en que hemos podido medir con ambos procedimientos.

#### *5.3.6.a.- Esfera integradora y láser sintonizable.*

Esta configuración es la presentada en la figura 5.8. Para el intervalo comprendido entre los 615nm y los 760nm se utilizó el material disponible en el CSIC, es decir, un láser iónico de Ar de 15 W de potencia utilizado como bombeo para un láser sintonizable de colorante (615nm a 675nm) o para un láser sintonizable iónico de Ar (705nm a 760nm). En esta ocasión se contaba, además con algunos instrumentos no mostrados en la figura 5.8 que añadían precisión y exactitud a la medida. En concreto, entre la salida del láser sintonizable y el difusor rotatorio se contaba con un estabilizador de potencia del haz láser y con un medidor de longitud de onda. La radiancia,  $E(\lambda)$ , en el puerto de salida de la esfera integradora se midió con un fotodetector CIRI calibrado al efecto.

Para el intervalo de longitudes de onda cortas -entre 454 nm y 514 nm- y para una medida puntual en 632,8 nm, se utilizó una configuración similar a la que acabamos de describir disponible en el Departamento de Óptica de Granada y que fue la misma utilizada para los experimentos de la sección 5.2.2. La esfera integradora, de 10 cm de diámetro, es algo menor que la utilizada en Madrid (de 50 cm de diámetro). En este caso no es necesario contar con el medidor de longitud de onda pues el láser sintonizable iónico de Ar sólo emite cuando el tornillo que controla el tamaño de la cavidad resonante del láser alcanza las posiciones calibradas especificadas por el fabricante (en las que la longitud de onda emitida se conoce con exactitud). En este laboratorio no se disponía de estabilizador de potencia para el haz láser. La radiancia a la salida de la esfera integradora se midió con el espectrorradiómetro SpectraScan PR650 situado en la misma posición que la cámara CCD una vez que las medidas con ésta finalizaron.

Con la configuración de ambos laboratorios, el experimento consiste en seleccionar una longitud de onda, medir la respuesta de la cámara y al mismo tiempo medir la radiancia  $E(\lambda)$  que recibe la cámara tal y como hemos indicado en cada caso. La calibración espectral consiste, pues, en medir la dependencia con la longitud de onda de la responsividad de cada

píxel de la CCD, una vez que su respuesta ha sido corregida según el algoritmo presentado en apartados anteriores, es decir:

$$R_i(\lambda) = \frac{C_i^c}{E(\lambda)t_{\text{exp}}} \quad (5.8)$$

El procedimiento de calibración espectral se llevó a cabo tres veces para asegurar una correcta medida de la responsividad. En la figura 5.19 vemos el resultado de cada una de las tres tandas de medidas realizadas en el CSIC (en alguna tanda falta algún dato que no pudo ser medido por falta de tiempo). Vemos claramente que la dispersión de los datos calculados es mínima a lo largo de las tres tandas.

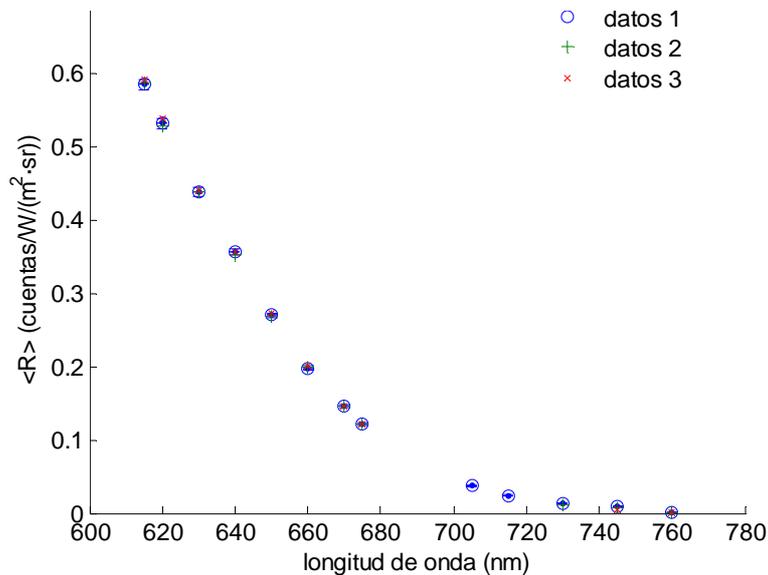


Figura 5.19. Resultado de la calibración espectral de la cámara CCD realizada en los laboratorios del CSIC.

Podemos notar cómo la responsividad de la cámara en la región espectral entre los 615 nm y los 760 nm es baja, ya que se trata de uno de los extremos del espectro visible. Según el fabricante, en 615nm la eficiencia cuántica es de apenas el 30% (ver apéndice II), dato que puede servirnos de comparación con la curva aquí presentada. En la figura 5.20 mostramos una extensión de la figura 5.19 en la que se aprecian las barras de error correspondientes a la desviación estándar promedio a lo largo de toda la matriz CCD y de las 3 tandas. Estos errores son pequeños gracias a la aplicación del algoritmo de corrección de la no uniformidad de la sección anterior.

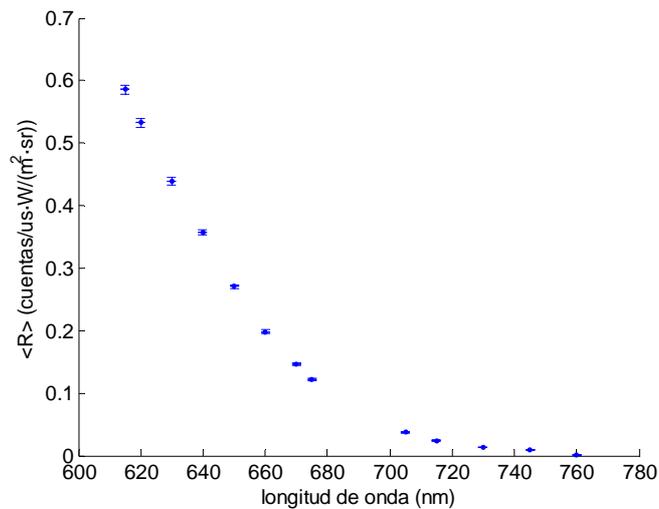


Figura 5.20. Responsividad espectral obtenida a partir de las medidas realizadas en el laboratorio del CSIC en Madrid. Las barras de error corresponden a la desviación típica espacial en cada longitud de onda y a lo largo de las tres medidas y toda la matriz CCD.

En la figura 5.21 mostramos los resultados de la calibración espectral obtenidos a partir de las medidas realizadas en el laboratorio de Granada. Obviamos la descripción detallada de cada una de las tres series de medidas realizadas y mostramos directamente la figura, análoga a la 5.20, con los promedios y las barras de error mostrando la desviación estándar a lo largo de las tres tandas y de toda la matriz CCD. En este caso las desviaciones son superiores a las obtenidas en el laboratorio de Madrid, debido -seguramente- a que en este caso no contábamos con un estabilizador de potencia para el láser.

### 5.3.6.b.- Filtro sintonizable y luz-cielo.

Si nos fijamos en las curvas de responsividad mostradas en las figuras 5.20 y 5.21 vemos que, hasta ahora, no tenemos información sobre la sensibilidad de la cámara por debajo de 454 nm ni en el intervalo entre 514 nm y 650 nm. Para solventar esta falta de información, imprescindible para poder realizar medidas espectrorradiométricas con la cámara CCD, es necesario idear una configuración alternativa con la que poder medir la responsividad de la cámara en las longitudes de onda restantes.

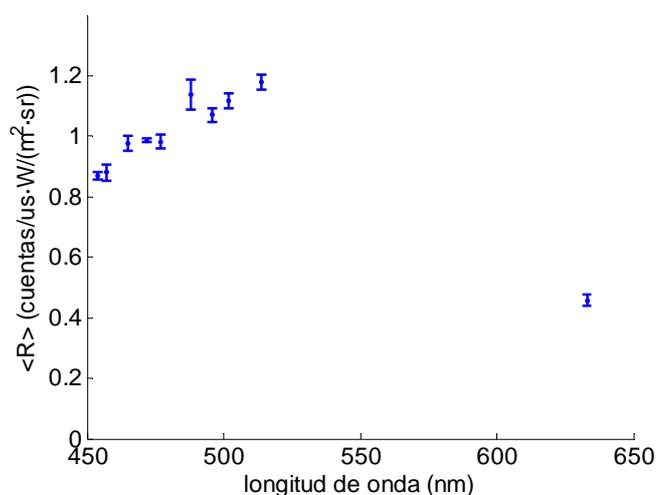


Figura 5.21. Responsividad espectral obtenida a partir de las medidas realizadas en el laboratorio de Granada. Las barras de error corresponden a la desviación típica espacial en cada longitud de onda y a lo largo de las tres medidas y toda la matriz CCD.

Para ello, decidimos aprovechar la selectividad cromática que ofrece el filtro LCTF. En la sección 5.2 hemos visto que las curvas de transmitancia de este tipo de filtro son bastante selectivas en longitud de onda. El propio fabricante indica (ver apéndice I) que el FWHM (*Full Width a Half Maximum* o anchura a mitad del máximo) varía entre 7 y 20 nm según la posición central del máximo (es más estrecho en los azules que en los rojos). Podemos asumir que esa anchura espectral es suficiente como para suponer que la luz saliente del filtro es monocromática, y calibrar con dicha luz la sensibilidad espectral de la cámara CCD.

La utilización del filtro LCTF para este fin presenta los problemas que comentamos en la sección 5.2 referentes a su reducida transmitancia -que obliga a utilizar una fuente luminosa lo suficientemente potente para registrar un número de cuentas aceptable en la cámara a la salida del filtro- y a que la emisión de dicha fuente debe ser espectralmente continua y abarcar todo el intervalo que puede barrer el LCTF (desde 400 nm hasta 720 nm). Para solventar estos problemas, proponemos utilizar -al igual que hicimos en la sección 5.2 para calibrar espectralmente el LCTF- la luz-cielo en días despejados como fuente de luz que cumple los anteriores requisitos. Además, en un campo no excesivamente grande, la luz-cielo se puede considerar espacialmente homogénea [Hernández-Andrés *et al.* 2003] y así obtendríamos en la cámara CCD el registro de un campo uniforme similar al de los experimentos con esfera integradora.

Se trataría, pues, de sintonizar el LCTF en una longitud de onda, tomar una imagen del cielo y, al mismo tiempo, una medida con el espectrorradiómetro apuntando al mismo punto de la bóveda celeste. La radiancia medida por el espectrorradiómetro, multiplicada por la transmitancia espectral conocida para el filtro sintonizado en ese modo, sería la radiancia que incide en la cámara  $E(\lambda)$ , que es la que debemos medir para poder aplicar la ecuación (5.8). Sin embargo, este procedimiento no es válido. Como ya se ha comentado más arriba, existe el problema de que la luz-cielo es elípticamente polarizada y el filtro LCTF actúa como polarizador lineal. Por tanto, según la orientación de los ejes de polarización del filtro,  $\theta_2$ , éste dejará pasar mayor o menor cantidad de luz hacia la cámara. Sólo podemos, pues, pretender medir con nuestro sistema multiespectral la porción de radiancia procedente de la bóveda celeste con polarización según el eje del propio filtro. En ese caso, la radiancia medida con el espectrorradiómetro, para compararla correctamente con la medida por el sistema multiespectral, debe estar filtrada para recoger la luz polarizada en el mismo eje del LCTF, es decir, el PR650 debe trabajar con el polarizador lineal con su eje orientados en un ángulo,  $\theta_1$ , igual que al del filtro ( $\theta_1 = \theta_2$ ).

Debemos tener en cuenta, asimismo, que el polarizador lineal, lejos de realizar sólo la función de filtrado de la luz no polarizada en la orientación de su eje, también introduce atenuación cromática que debe ser tenida en cuenta a la hora de relacionar la radiancia que mide el PR650, que llamaremos  $E_1(\lambda)$ , con la que incide sobre la cámara, que llamaremos  $E_2(\lambda)$ . Si medimos su transmitancia espectral, utilizando como fuente una luz linealmente polarizada -según el eje del polarizador- procedente de una pantalla TFT (del inglés, '*Thin Film Transistor*') y el espectrorradiómetro PR650 al modo en que hemos presentado en la sección 5.2, obtenemos la curva de la figura 5.22.

En la figura 5.23 mostramos un esquema de las radiancias que medimos con el espectrorradiómetro y con la cámara durante el proceso de calibrado espectral del CCD utilizando el filtro LCTF.

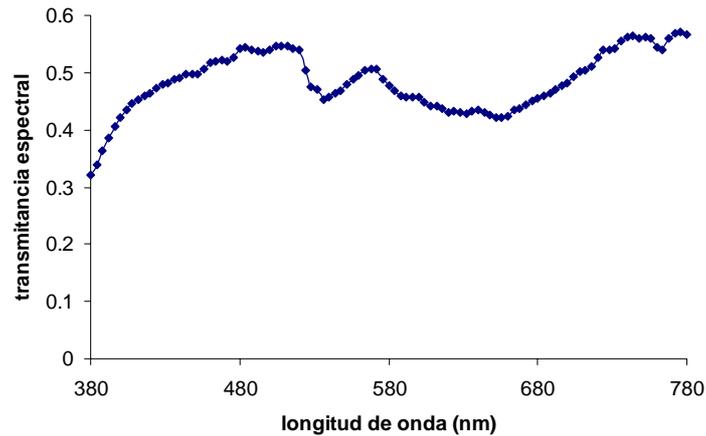


Figura 5.22. Transmitancia espectral del polarizador lineal  $T_{pol}(\lambda)$ .

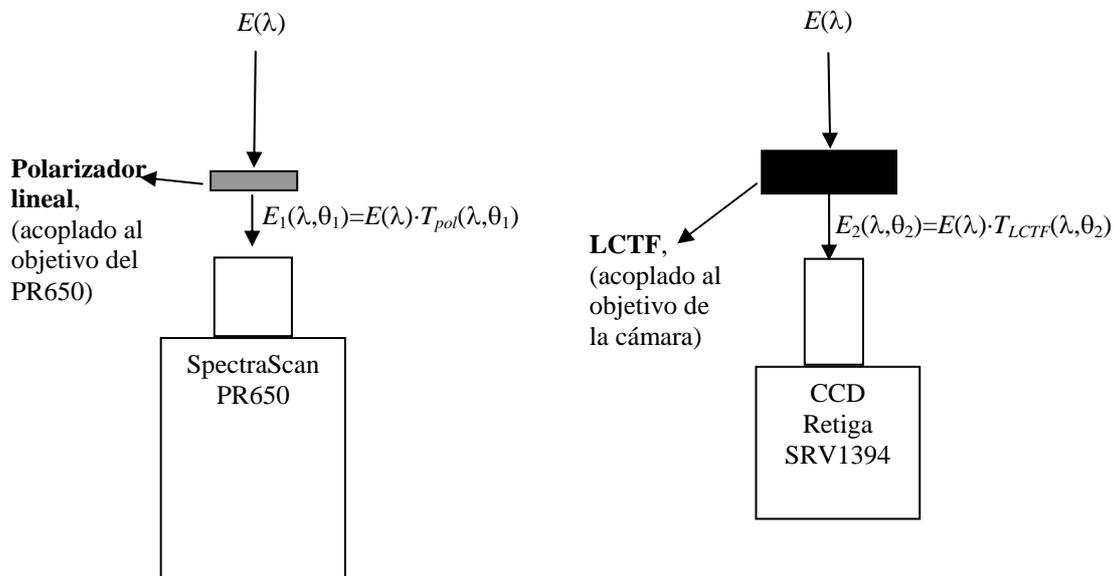


Figura 5.23. Esquema de las radiancias recibidas en el espectrorradiómetro y en la cámara CCD durante las series de medidas de luz-cielo.

Para poder aplicar la ecuación (5.8) y conocer la sensibilidad espectral del CCD, debemos relacionar de alguna forma la radiancia  $E_2$ , que es la que debemos introducir en el denominador de dicha ecuación, con  $E_1$ , que es la que podemos medir con el espectrorradiómetro (ver figura 5.23). Lo único que está claro es que  $E_1$  y  $E_2$  son luces linealmente polarizadas en la misma dirección. Ahora sólo falta deducir la relación espectral entre ellas. Está claro, a la vista de la figura 5.23, que:

$$\begin{aligned}
 E_1(\lambda, \theta_1) &= E(\lambda)T_{pol}(\lambda)T_{pol}(\theta_1) \\
 E_2(\lambda, \theta_2) &= E(\lambda)T_{LCTF}(\lambda)T_{LCTF}(\theta_2)
 \end{aligned}
 \tag{5.9}$$

donde hemos separado explícitamente la dependencia cromática de la debida a la orientación respectiva de los ejes de polarización de ambos filtros. Dado que aseguramos en todo momento que  $\theta_1 = \theta_2$ , y si suponemos que entonces la acción de los filtros debida exclusivamente a la polarización es la misma:

$$T_{pol}(\theta_1) = T_{LCTF}(\theta_2) \quad (5.10)$$

podemos entonces eliminar la dependencia con la orientación del eje de polarización de ambos filtros y calcular el cociente entre las dos ecuaciones de la expresión (5.9) para obtener así la relación buscada entre la radiancia medida con el PR650 y la que excita el CCD:

$$E_2(\lambda) = E_1(\lambda) \frac{T_{LCTF}(\lambda)}{T_{pol}(\lambda)} \quad (5.11)$$

Para comprobar la veracidad experimental de la ecuación (5.11), realizamos una medida espectral de  $E_1(\lambda)$  con el PR650 y el polarizador lineal para, a partir de ella, calcular teóricamente el valor de  $E_2(\lambda)$  mediante (5.11). Igualmente realizamos una medida de  $E_2(\lambda)$  con el PR650 y el filtro LCTF sintonizado en 550 nm. El resultado de este pequeño experimento se muestra en la figura 5.24, donde vemos que el acuerdo entre la medida experimental de  $E_2(\lambda)$  y el valor calculado teóricamente usando la ecuación (5.11) y la medida de  $E_1(\lambda)$  es casi perfecto. En cualquier caso, la prueba de la validez de la ecuación (5.11) la tendremos al realizar la calibración espectral de la cámara CCD con el procedimiento que estamos presentando y comprobar que la curva de sensibilidad espectral obtenida coincide con la que se ha medido en los laboratorios con los láseres sintonizables en aquellas zonas del espectro donde es posible realizar dicha comparación.

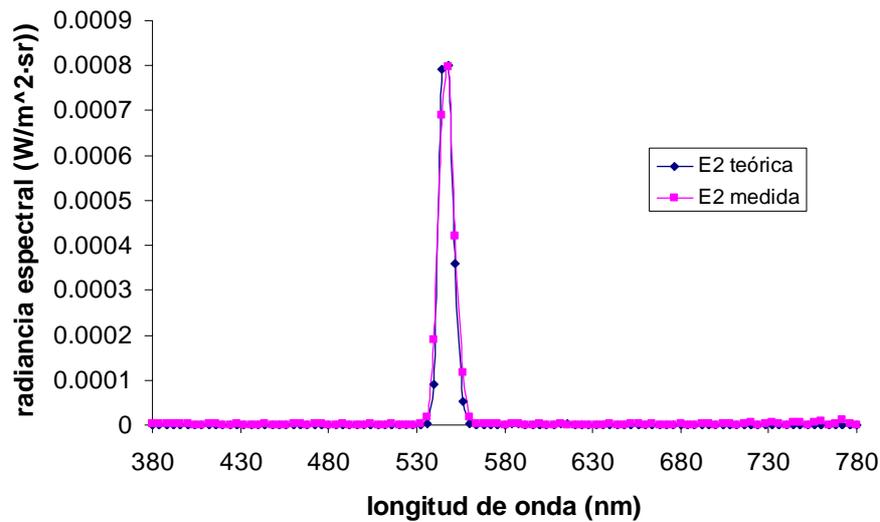


Figura 5.24. Comprobación de la validez de la ecuación (5.11) para el caso de 550 nm.

De esta manera, podemos ya presentar el resultado obtenido para la calibración espectral de la cámara siguiendo el procedimiento ideado en el que utilizamos el filtro LCTF y la luz-cielo como se ha explicado. La figura 5.25 muestra la curva de sensibilidad espectral medida de esta forma, y en ella podemos apreciar que el pequeño valor de las barras de error da fé de la homogeneidad espacial y temporal de la luz-cielo a la que aludíamos anteriormente. En dicha figura también mostramos superpuestos los resultados obtenidos con los tres procesos que hemos seguido para la calibración espectral de la cámara CCD, añadiendo a la figura 5.25 las figuras 5.20 y 5.21. La concordancia, casi exacta, entre los resultados obtenidos con los diferentes métodos es una prueba de que el procedimiento propuesto en esta sección para medir la curva de sensibilidad espectral de la cámara CCD es perfectamente aplicable.

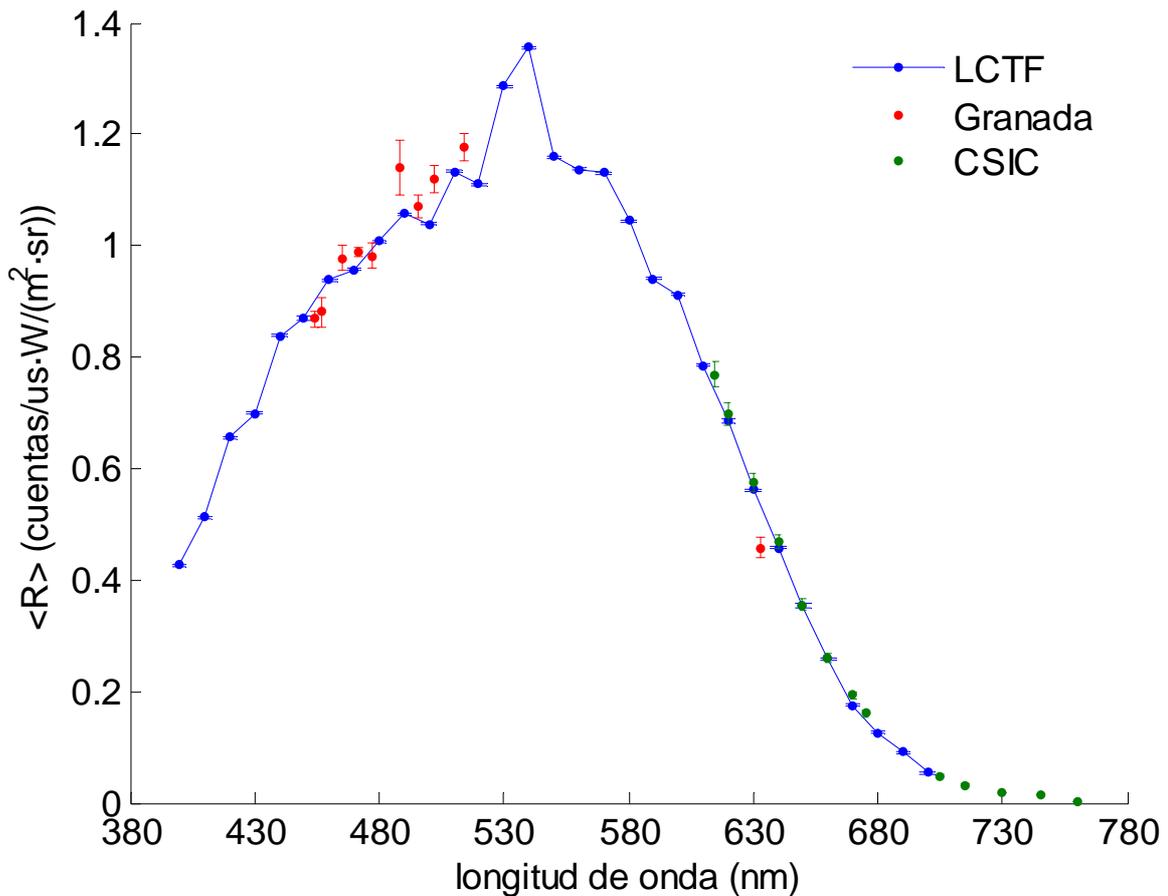


Figura 5.25. Sensibilidad espectral de la cámara. Se muestran los resultados obtenidos con las medidas realizadas en el CSIC (verde) y en Granada (rojo) con los correspondientes láseres sintonizables sobre la curva medida utilizando el LCTF y luz-cielo (azul).

A la vista de estos resultados, diremos que la curva de sensibilidad espectral que finalmente usaremos en todos los cálculos venideros será la que se ha medido mediante este último método. Dicha curva será extendida en el intervalo de 700 nm a 760 nm con los datos obtenidos a partir de las medidas realizadas en el CSIC (en verde en la figura 5.25), y se considerará nula hasta los 780 nm. En el intervalo entre 400 nm y 380 nm se hará una extrapolación lineal de la curva azul de la figura 5.25 con la pendiente dada a partir de los datos proporcionados por el fabricante (ver apéndice II), según los cuales la eficiencia cuántica de la cámara cae de manera lineal entre 400 nm y 300 nm hasta el valor cero. De esta manera, tenemos la curva de sensibilidad espectral de la cámara en el intervalo deseado de 380 nm a 780 nm en el que trabaja el PR650. Si interpolamos linealmente para obtener los valores cada 4 nm (al igual que el espectrorradiómetro), obtenemos la curva de la figura 5.26 que será la función que usemos en todos los cálculos venideros.

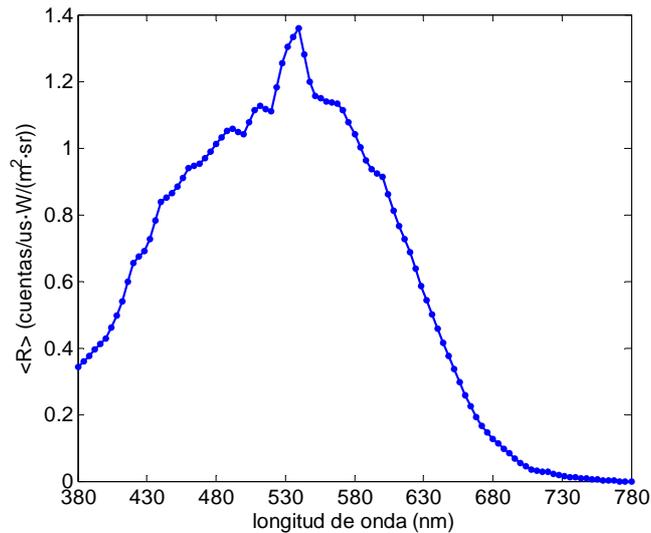


Figura 5.26. Curva de sensibilidad espectral de la cámara CCD extendida al intervalo entre 380 nm y 780 nm e interpolada a sus valores correspondientes cada 4 nm.

#### **5.4.- Implementación de un sistema hiperspectral de banda estrecha:**

Ya que disponemos de una cámara CCD calibrada radiométricamente, como hemos visto en la sección 5.3, y de un filtro LCTF del que conocemos su transmitancia espectral (sección 5.2), el siguiente paso es intentar realizar medidas espectralradiométricas con ambos dispositivos acoplados. Esta tarea se puede llevar a cabo de dos formas.

En primer lugar, podemos suponer que la transmitancia de cada uno de los modos del LCTF es suficientemente monocromática como para asegurar que si tomamos una imagen con la cámara CCD y el LCTF sintonizado en una longitud de onda dada, la radiancia que midamos con la cámara se debe exclusivamente a la energía luminosa proveniente de la bóveda celeste en dicha longitud de onda. En definitiva, se trataría de un sistema de banda estrecha (quasi-monocromático) e hiperspectral (pues tendríamos 33 canales de 400 nm a 720 nm cada 10 nm) que simplemente muestrearía en cada longitud de onda la radiancia recibida.

La segunda opción consiste en utilizar algún algoritmo de estimación espectral con un sistema de 33 canales, de manera que las respuestas registradas para cada uno de esos canales sean la matriz de entrada para obtener los espectros deseados a la salida. En este caso, no es preciso suponer que los canales son monocromáticos, e incluso -si utilizamos el algoritmo de Imai-Berns o el de regresión- ni siquiera es necesario conocer la forma espectral de dichos canales, como se discutió en el capítulo 3. Sin embargo, esta tarea requiere de un proceso de

entrenamiento del sistema, el cual no tiene sentido en el procedimiento de muestreo espectrorradiométrico descrito en el párrafo anterior.

En toda esta sección utilizamos, como conjunto de test, un total de 125 medidas espectrorradiométricas de luz-cielo tomadas en la Facultad de Ciencias de Granada entre julio y noviembre de 2007, siempre en días despejados, entre la salida y la puesta de sol, apuntando al oeste y con elevaciones de 45° y 60°. Las medidas se realizaron con el SpectraScan PR650 al tiempo en que se tomaba una imagen con la cámara digital tras sintonizar el LCTF en cada uno de los 33 canales disponibles. Se programó una rutina para que, de forma automática, el tiempo de exposición en cada imagen asegurase que el número de cuentas registradas en la cámara quedaba comprendido entre 3500 y 3700 (sobre un total de 12 bits, 4095 cuentas), asegurando así que la señal recogida es alta y evitando la saturación del CCD. El proceso completo de toma de imágenes duraba 1 minuto, y en ese tiempo se realizaban 3 medidas con el espectrorradiómetro. En todos los casos se comprobó que la forma espectral de las tres medidas durante ese minuto era la misma (con errores RMSE menores del 0,5%), validando así la hipótesis de homogeneidad temporal de la luz-cielo en períodos de tiempo tan cortos [Hernández-Andrés *et al.* 2003]. En la figura 5.27 mostramos las coordenadas de cromaticidad en el diagrama CIE-1931 de este conjunto de 125 medidas.

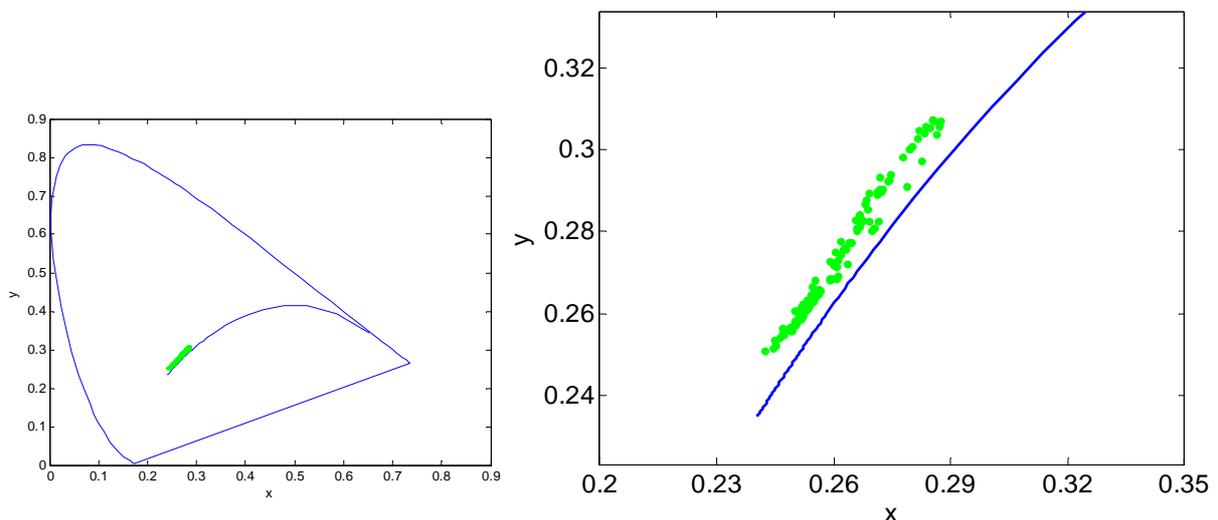


Figura 5.27. Coordenadas de cromaticidad en el diagrama CIE-1931 de las 125 medidas espectrorradiométricas de luz-cielo tomadas en Granada en 2007.

### 5.4.1. Medidas espectrorradiométricas suponiendo canales monocromáticos.

Conocidas la curva de sensibilidad espectral de la cámara CCD,  $R(\lambda)$ , y las transmitancias espectrales de los 33 modos -supuestos monocromáticos- del LCTF,  $T_{k,LCTF}(\lambda)$  (el subíndice  $k$  hace referencia a cada uno de los canales), es inmediato obtener las funciones de conversión de número de cuentas registradas y corregidas,  $C_k^C$ , en radiancia recibida,  $E_k$ , sin más que aplicar la ecuación (5.8) una vez conocido el tiempo de exposición empleado en cada canal  $k$ ,  $t_{exp}(k)$ . Ya obviamos el subíndice  $i$  que hace referencia a cada píxel por separado, pues desde ahora trabajaremos con un promedio en la zona central de la matriz CCD correspondiente al mismo FOV de 1° del PR650:

$$E_k = \frac{C_k^C}{t_{exp}(k) \int_{380}^{780} R(\lambda) T_{k,LCTF}(\lambda) d\lambda} \quad (5.12)$$

Notemos que con este procedimiento, obtenemos el valor de la radiancia en la longitud de onda correspondiente a cada modo monocromático de los disponibles en el LCTF, por eso designamos a esta magnitud como  $E_k$ . En la figura 5.28 mostramos el valor de cada uno de los 33 términos del tipo

$$F_k = \left( \int_{380}^{780} R(\lambda) T_{k,LCTF}(\lambda) d\lambda \right)^{-1} \quad (5.13)$$

que denominaremos *funciones de conversión*  $F_k$ , y que son necesarias para realizar la transformación explicada en la ecuación (5.12) sin más que incluir los valores del tiempo de exposición,  $t_{exp}(k)$ , y número de cuentas corregidas,  $C_k^C$ .

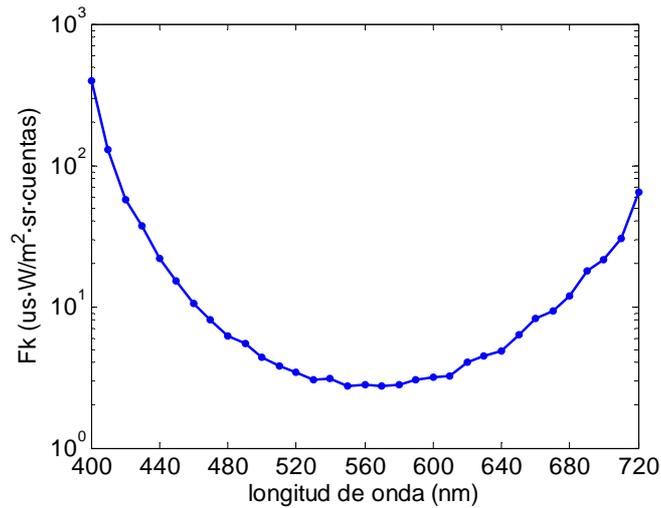


Figura 5.28. Valor de cada una de las 33 funciones de conversión  $F_k$ .

Realizando estos cálculos para cada una de las 125 series de medidas del conjunto de test, obtenemos los resultados estadísticos mostrados en la tabla 5.1, donde mostramos los promedios  $\pm$  desviaciones estándar (SD, del inglés ‘*Standard Deviation*’) a lo largo de este conjunto. En la figuras 5.29a, 5.29b y 5.29c mostramos, asimismo, las curvas estimadas con la cámara CCD y las medidas con el PR650 correspondientes a los percentiles 10, 50 y 90, respectivamente, de la métrica CSCM en la anterior estadística (que equivalen a unos valores respectivos iguales a 6,00, 15,35 y 25,05). Como podemos comprobar, las curvas medidas con ambos instrumentos son muy similares espectralmente hablando en todos los casos, si bien hay una cierta deriva en la estimación de la energía total bajo la curva, lo que da lugar a los valores relativamente elevados de la métrica IRE(%). Esto podría deberse a un error sistemático introducido por la incorrecta suposición de monocromaticidad de los canales del sistema, o a un error en la determinación de la sensibilidad espectral de la cámara CCD.

GFC	CIELAB $\Delta E_{ab}^*$	IRE (%)	CSCM
0.9976 $\pm$ 0.0018	1.262 $\pm$ 0.371	13.095 $\pm$ 7.086	15.522 $\pm$ 7.328

Tabla 5.1. Promedios  $\pm$  desviaciones estándar (SD) de las estimaciones espectrales del conjunto de 125 medidas realizadas en Granada en 2007 obtenidas mediante el método de muestreo monocromático.

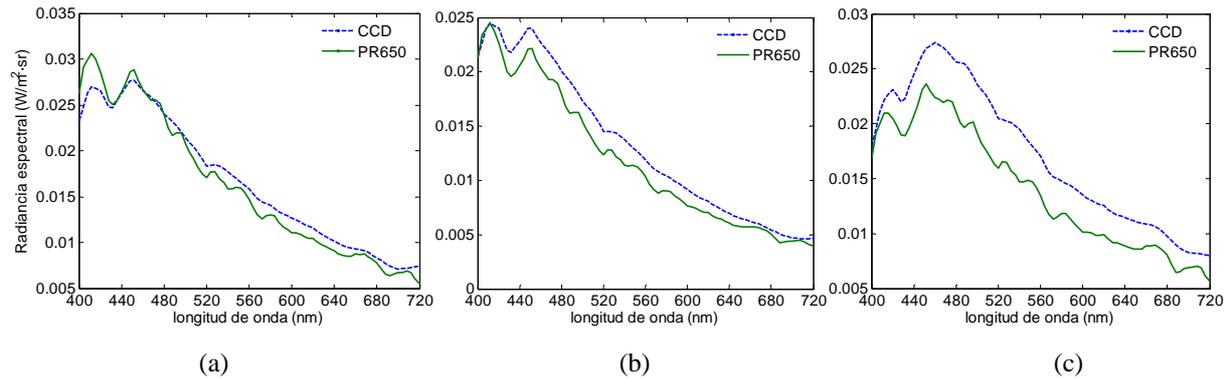


Figura 5.29. (a) Percentil 10 con un CSCM = 6,00, (b) Mediana con un CSCM = 15,35 y (c) Percentil 90 con un CSCM = 25,05, dentro del conjunto de test de 125 medidas de luz-cielo tomadas en Granada en 2007, de las estimaciones espectrales siguiendo el método de muestreo monocromático.

En conclusión, aunque hemos encontrado una cierta tendencia a sobreestimar la energía total de las curvas de luz-cielo obtenidas a partir de las medidas con la cámara CCD, las medidas espectrales llevadas a cabo con el método de muestreo monocromático son bastante fieles a las tomadas simultáneamente con el espectrorradiómetro PR650, como muestran los valores de las métricas espectrales y colorimétricas presentados en la tabla 5.1, así como la comparación espectral de las curvas mostradas en la figura 5.29. Estos resultados validan la utilización de este método, utilizando una cámara CCD y un filtro LCTF, para obtener buenas estimaciones espectrales de luz-cielo.

#### 5.4.2.- Modelo de regresión de 33 canales de banda estrecha.

En esta sección proponemos utilizar la información recogida por la cámara CCD en los 33 canales que proporciona el LCTF para conseguir estimaciones espectrales utilizando alguno de los métodos presentados en el capítulo 3. Algunos autores [Day 2003b] han utilizado el método de regresión lineal con un sistema multiespectral de similares características al aquí estudiado para obtener estimaciones espectrales de reflectancias de pinturas en obras de arte. A la vista de la discusión presentada al final del capítulo 3, nosotros proponemos utilizar dicho algoritmo de regresión lineal, pero también el de Imai-Berns con vectores base ICA, cuyo número óptimo de vectores deberá ser determinado según la calidad de las estimaciones obtenidas.

El principal inconveniente de emplear estos algoritmos es que necesitamos entrenar el sistema, es decir, establecer una relación entre un conjunto de espectros de luz-cielo conocidos y sus respuestas registradas en la cámara CCD. Dado que el conjunto de 125

medidas de luz-cielo tomadas en Granada en 2007 no es suficientemente grande como para extraer de él un conjunto de entrenamiento y establecer después una estadística aceptable, proponemos utilizar como conjunto de entrenamiento el de 1567 medidas de luz-cielo tomadas en Granada a finales de los 90 que ya se ha empleado en los estudios del capítulo 3. Sin embargo, no tenemos las respuestas del CCD a dichos espectros, pero sí que podemos simularlas conociendo la sensibilidad espectral de nuestra cámara. Veremos en esta sección si dicho entrenamiento es suficientemente bueno y si las estimaciones espectrales del conjunto de test de 125 medidas son aceptables.

Recordando el formalismo del capítulo 3, en la ecuación (3.6) decíamos que, para los métodos de Imai-Berns y regresión lineal (también para el de Maloney-Wandell, pero que obviamos pues no lo usaremos aquí) podíamos utilizar la relación siguiente para obtener las estimaciones espectrales,  $E_R$ , a partir de las respuestas de los sensores  $\rho$ :

$$E_R = X\rho \quad (5.14)$$

Donde  $X = VG$  para el algoritmo de Imai-Berns (ver ecuación (2.18)) y  $X = W_L$  para el algoritmo de regresión lineal (ecuación (2.32)), mientras que  $\rho$  en nuestro caso deben ser las cuentas registradas en la cámara CCD normalizadas por el tiempo de exposición:

$$\rho = \frac{C_k^c}{t_{\text{exp}}(k)} \quad (5.15)$$

Si simulamos las cuentas que se habrían registrado en cada uno de los 33 canales de nuestra CCD para cada uno de los 1567 espectros de entrenamiento,  $E_{ts}(\lambda)$  según la relación (ver ecuación (5.8)):

$$C_k^c = R(\lambda)E(\lambda)t_{\text{exp}}(k) \quad (5.16)$$

y a partir de (5.16) calculamos el vector de respuestas de los espectros de entrenamiento (que volveremos a notar con el subíndice  $ts$ ),  $\rho_{ts}$ , utilizando (5.15), podemos entonces calcular las matrices necesarias para aplicar los algoritmos de estimación espectral, que no son más que

las ya vistas en el capítulo 2 y que recordamos aquí por comodidad. Para el método de regresión lineal:

$$W_L = E_{ts} \rho_{ts}^+ \quad (2.31)$$

mientras que para el de Imai-Berns:

$$G = \varepsilon_{ts} \rho_{ts}^+ \quad (2.19)$$

Recordemos que para el algoritmo de Imai-Berns debemos, además, seleccionar una base lineal,  $V$ , en la que expresar los espectros de entrenamiento y test, pues la matriz  $\varepsilon_{ts}$  contiene los coeficientes del desarrollo lineal de los espectros de entrenamiento  $E_{ts}(\lambda)$  en la dicha base. Como ya se comentó al final del capítulo 3, en las simulaciones con pocos sensores o canales encontramos que resultaba altamente beneficioso utilizar una base ICA de 24 vectores. Sin embargo, en este sistema de 33 canales la base ICA, que también aporta un elevado número de vectores, no arroja resultados aceptables en la reconstrucción de los 125 espectros de luz-cielo medidos en Granada (no mostraremos la estadística). Ello es debido a que la elevada dimensión de las matrices las hace muy sensibles al ruido (con un ‘*condition number*’ elevado [Hardeberg 1999]). Por ello, preferimos utilizar una base PCA, probando con varios números de vectores para seleccionar el óptimo, como mostraremos a continuación.

En la tabla 5.2 mostramos los resultados recogidos, para las diferentes métricas que venimos usando habitualmente, al reconstruir espectralmente los 125 espectros de luz-cielo del conjunto de test utilizando el algoritmo de regresión lineal. Podemos apreciar cómo los resultados mejoran significativamente a los obtenidos mediante el método de muestreo monocromático (salvo para el GFC, que es ligeramente peor), lo que nos sirve para afirmar que el entrenamiento del sistema ha sido correcto [Day 2003b]. Sin embargo, pensamos que si pudiésemos disponer de un conjunto de entrenamiento suficientemente grande, y con el que las respuestas de los sensores fuesen conocidas experimentalmente en lugar de simuladas, los resultados podrían mejorar incluso más, lo que se deja para trabajo futuro.

GFC	CIELAB $\Delta E^*_{ab}$	IRE (%)	CSCM
0.9971±0.0009	0.8548±0.2125	6.300±5.432	8.508±5.573

Tabla 5.2. Promedios ± desviaciones estándar (SD) de las estimaciones espectrales del conjunto de 125 medidas realizadas en Granada en 2007 obtenidas mediante el método de regresión lineal.

En la figura 5.30 enseñamos, como ya hiciéramos con el método de muestreo monocromático, las curvas espectrales correspondientes a los percentiles 10, 50 y 90 de la métrica CSCM obtenidas con este algoritmo de regresión lineal. Podemos apreciar, como característica significativa en dichas curvas, que el intervalo espectral se extiende de 380 nm hasta 780 nm, exactamente el mismo disponible en las medidas de entrenamiento (esto también ocurrirá para el método de Imai-Berns, como veremos a continuación). En el método de muestreo monocromático sólo podíamos abarcar el intervalo de barrido del LCTF (desde 400 nm hasta 720 nm), y -aunque ahora no tenemos más información registrada en la cámara CCD que antes- sí que los métodos basados en entrenamiento mediante curvas estadísticamente representativas del tipo de espectro que queremos estimar son capaces de predecir la forma espectral de las curvas en todo el intervalo, aunque no haya sensores en dichas zonas del espectro. Ello lo hacen utilizando las peculiaridades estadísticas de las curvas de luz-cielo recogidas durante la etapa de entrenamiento del sistema. Aparte de esta apreciación, se ve claramente en la figura 5.30 que las reconstrucciones espectrales son sumamente fieles a las medidas con el SpectraScan PR650, lo que valida la utilización de todo el proceso que hemos presentado anteriormente.

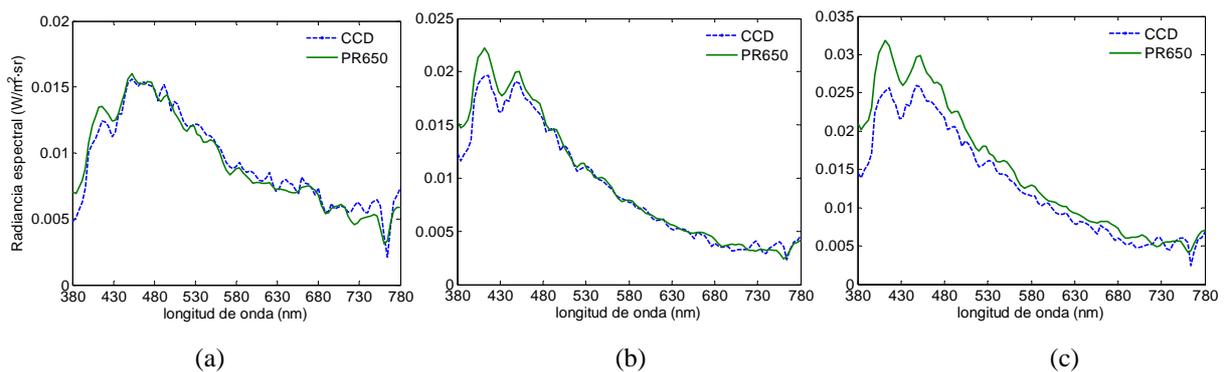


Figura 5.30. (a) Percentil 10 con un CSCM = 3,278, (b) Mediana con un CSCM = 6,73 y (c) Percentil 90 con un CSCM = 15,65, dentro del conjunto de test de 125 medidas de luz-cielo tomadas en Granada en 2007, de las estimaciones espectrales siguiendo el método de regresión lineal.

Los resultados concernientes al método de Imai-Berns se muestran en la tabla 5.3 para diferentes números,  $n$ , de vectores PCA utilizados. Podemos apreciar que, para nuestro

sistema de 33 canales, el número óptimo de sensores parece ser  $n = 6$ . Hemos realizado los cálculos con  $n = 33$  para comprobar si al utilizar  $n = k$  se obtenían los mejores resultados, pero podemos comprobar que esta afirmación parece cumplirse sólo para sistemas multispectrales con un número,  $k$ , de canales no excesivamente alto. También hemos utilizado  $n = 101$  pues eso equivale a utilizar todos los vectores propios PCA disponibles. En ese caso el método de Imai-Berns y el de regresión lineal coinciden formalmente, y también los resultados, como vemos en la tabla 5.3 y como ya demostramos en el capítulo 2. Al poder utilizar un número menor de vectores base PCA, el método de Imai-Berns mejora ligeramente los resultados obtenidos con el método de regresión lineal.

$n$	GFC	CIELAB $\Delta E^*_{ab}$	IRE (%)	CSCM
3	0.9975±0.0012	1.1856±0.2864	6.329±5.279	8.736±5.323
4	0.9975±0.0008	0.9678±0.2158	6.326±5.461	8.516±5.579
5	0.9975±0.0007	0.7007±0.2301	6.308±5.435	8.239±5.615
<b>6</b>	<b>0.9976±0.0007</b>	<b>0.7018±0.2298</b>	<b>6.311±5.432</b>	<b>8.232±5.577</b>
7	0.9975±0.0007	0.7135±0.2303	6.302±5.421	8.262±5.571
8	0.9975±0.0007	0.8764±0.2222	6.287±5.410	8.406±5.524
15	0.9974±0.0008	0.8225±0.2172	6.305±5.437	8.401±5.586
33	0.9971±0.0008	0.8517±0.2132	6.300±5.431	8.487±5.573
101	0.9971±0.0009	0.8548±0.2125	6.300±5.432	8.508±5.573

Tabla 5.3. Promedios ± desviaciones estándar (SD) de las estimaciones espectrales del conjunto de 125 medidas realizadas en Granada en 2007 obtenidas mediante el método de Imai-Berns con diferentes números de vectores base PCA utilizados. En negrita se muestran los mejores resultados, obtenidos con  $n = 6$ .

Para el número de vectores óptimo que hemos encontrado, las curvas espectrales estimadas correspondientes a los percentiles 10, 50 y 90 de la métrica CSCM se muestran en la figura 5.31.

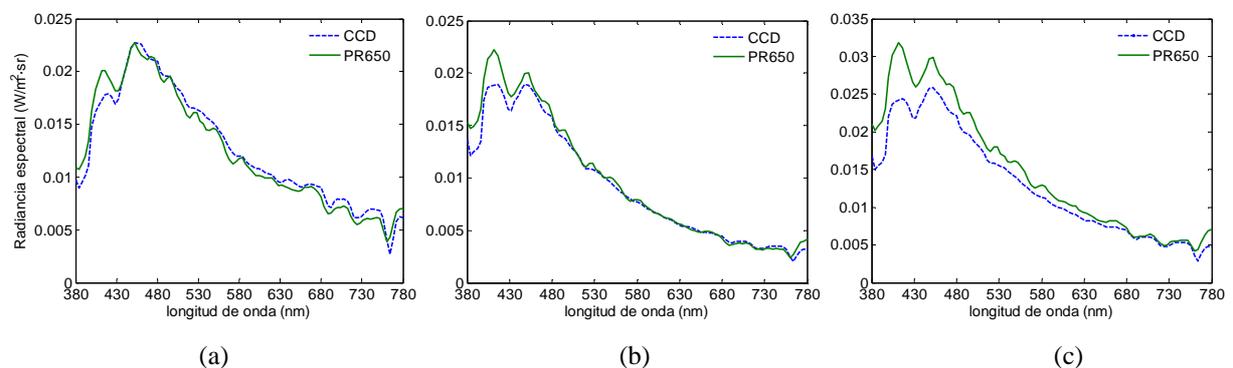


Figura 5.31. (a) Percentil 10 con un CSCM = 3,00, (b) Mediana con un CSCM = 6,44 y (c) Percentil 90 con un CSCM = 15,48, dentro del conjunto de test de 125 medidas de luz-cielo tomadas en Granada en 2007, de las estimaciones espectrales siguiendo el método de Imai-Berns con  $n = 6$  vectores PCA.

### **5.5.- Implementación de un sistema multispectral óptimo con pocos sensores:**

Para finalizar este capítulo, estudiaremos la posibilidad de implementar con nuestro LCTF y la cámara CCD alguno de los conjuntos de sensores óptimos encontrados en el capítulo 3. Si atendemos a las figuras 3.7, 3.8, 3.10, 3.11 y 3.14, veremos que casi todos los conjuntos de sensores óptimos encontrados tienen un sensor situado entre los 380 nm y los 400 nm. Esto hace imposible que dicho sensor pueda ser implementado con nuestro LCTF, que no puede ser sintonizado por debajo de los 400 nm. Apenas hay tres casos, de los estudiados en el capítulo 3, que puedan ser implementados por cumplir el requisito de tener todos sus sensores entre 400 nm y 720nm (el intervalo abarcado por el LCTF): a) cuatro sensores, método de Maloney-Wandell, cuatro vectores PCA y una SNR de 26dB, b) tres sensores, método de Maloney-Wandell, nueve vectores ICA y una SNR de 30dB, c) Cinco sensores, método de Imai-Berns, cinco vectores PCA y una SNR de 26dB.

Mirando a la figura 5.9 podemos afirmar que el ruido temporal de alta frecuencia en la cámara es de unas 50 cuentas sobre un total de 3000 aproximadamente, lo que equivale a un ruido del 1,7%. A esto debemos añadir que la corrección de no-linealidad y no-uniformidad (ruido espacial) dejan un error adicional del 0,5% y el 0,27% respectivamente (ver figuras 5.15 y 5.17). En total, nuestra cámara CCD tiene un ruido cercano al 3%, es decir, 30dB de SNR. Como algunos autores discuten [Day 2003, Shimano 2006, López-Álvarez *et al.* 2007], los sensores óptimos encontrados para un nivel de ruido superior al que realmente tiene la cámara presentan un buen comportamiento, aunque no sea el óptimo, cuando el nivel de ruido real es menor que aquel para el que fueron buscados. Lo contrario nunca ocurre, y así encontramos que sensores óptimos para niveles bajos de ruido se comportan mal cuando el ruido real en el sistema es más alto. Esta razón justificaría el que pudiésemos intentar sintetizar cualquiera de los tres casos anteriores con el LCTF, a modo de ejemplo ilustrativo del comportamiento de un supuesto sistema óptimo. Sin embargo, realizaremos sólo el último de ellos. Este ejemplo utiliza el método de Imai-Berns, que hemos utilizado también en la sección anterior y que ya justificamos como uno de los métodos más fiables al final del capítulo 3, pero en esta ocasión se utilizan cinco sensores y cinco vectores base PCA. En la figura 5.32 mostramos cómo podemos sintetizar los cinco sensores óptimos mediante la elección adecuada de los modos del LCTF (en este caso se necesitaron usar siete de los modos del filtro) y ajustando los tiempos de exposición de cada uno de ellos. Si hacemos esto e

intentamos reconstruir los 125 espectros de luz-cielo del conjunto de test, tenemos los resultados de la tabla 5.4. Debemos recordar que, de nuevo, el método de estimación espectral de Imai-Berns fue entrenado con las respuestas simuladas de los sensores a los 1567 espectros de luz-cielo del conjunto que venimos usando de entrenamiento.

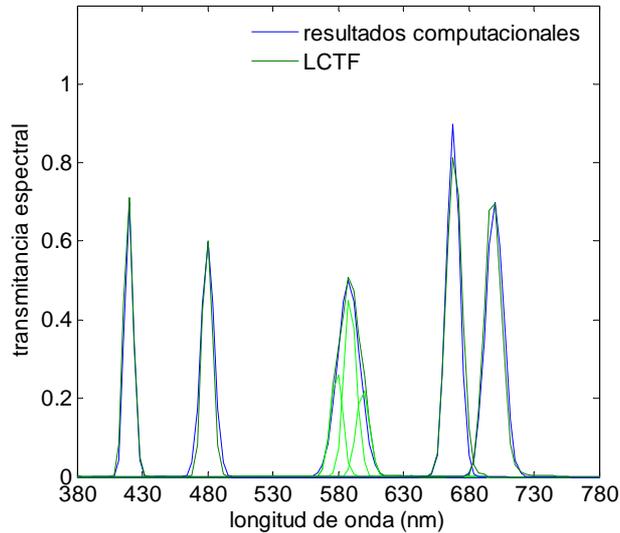


Figura 5.32. Síntesis de los cinco sensores óptimos para el método de Imai-Berns a partir de los modos del LCTF.

GFC	CIELAB $\Delta E_{ab}^*$	IRE (%)	CSCM
0.9981±0.0008	0.8723±0.2057	7.050±5.845	8.966±5.996

Tabla 5.4. Promedios ± desviaciones estándar (SD) de las estimaciones espectrales del conjunto de 125 medidas realizadas en Granada en 2007 obtenidas mediante el método de Imai-Berns con 5 sensores óptimos y 5 vectores base PCA.

Los resultados obtenidos con estos cinco sensores óptimos sintetizados a partir de siete modos del LCTF son muy similares a los que hemos presentado anteriormente con el resto de métodos, pues apenas obtenemos un valor de la métrica CSCM un 8% mayor que el mejor obtenido en la tabla 5.3. La ventaja aquí es que, al utilizar sólo siete de los modos del LCTF, el tiempo total empleado en adquirir las imágenes pasa de 1 minuto a unos 15 segundos (un factor 4 más rápido). En la figura 5.33 mostramos, como venimos haciendo en este capítulo, las curvas correspondientes a los percentiles 10, 50 y 90 de la métrica CSCM obtenidos con este último método testado.

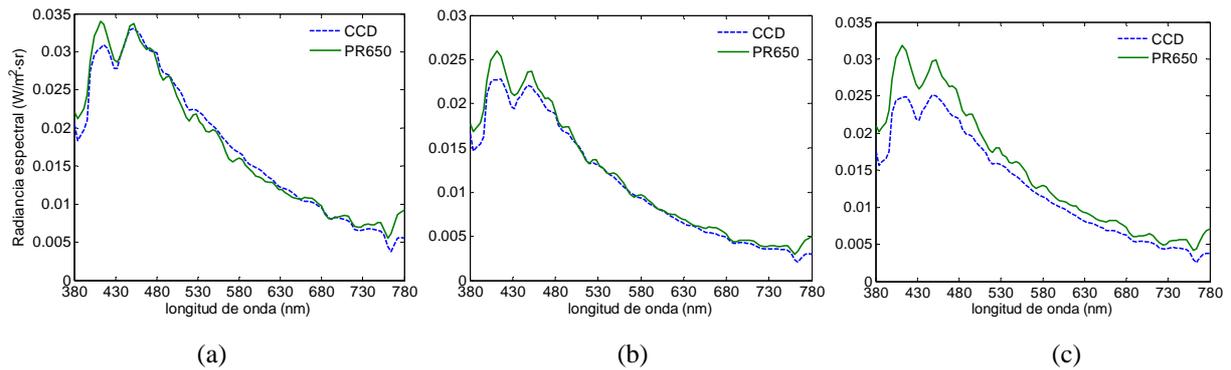


Figura 5.33. (a) Percentil 10 con un CSCM = 3,12, (b) Mediana con un CSCM = 7,48 y (c) Percentil 90 con un CSCM = 16,76, dentro del conjunto de test de 125 medidas de luz-cielo tomadas en Granada en 2007, de las estimaciones espectrales siguiendo el método de Imai-Berns con cinco sensores óptimos y cinco vectores PCA.

Los resultados obtenidos para la métrica CSCM con la implementación real de este sistema multispectral óptimo que encontramos en el capítulo 3, son sensiblemente peores que los resultados teóricos obtenidos entonces (ver tabla 3.4), pese a que las situaciones de ruido son similares. Las mayores diferencias se encuentran en el término debido a la radiancia integrada IRE(%), y ello nos hace pensar que el entrenamiento del sistema simulando las respuestas de la cámara CCD con los 1567 espectros de luz-cielo medidos en Granada no es del todo correcto, y es susceptible de ser mejorado. En el futuro, pretendemos obtener un conjunto amplio de medidas experimentales con este nuevo sistema multispectral, de manera que podamos llevar a cabo un entrenamiento correcto utilizando las respuestas de los sensores realmente registradas por la cámara CCD.



## **6.- CONCLUSIONES Y TRABAJO FUTURO.**

Las principales aportaciones, tanto teóricas como experimentales, que se han desarrollado en este trabajo doctoral se pueden resumir en los siguientes puntos:

1.- Se ha desarrollado un modelo teórico completo del comportamiento de un sistema multiespectral, en el que se han tenido en cuenta todos sus componentes y todos los posibles factores que pueden afectar a su respuesta y comportamiento, como son el ruido, el número de sensores, el algoritmo de estimación espectral, el tipo y tamaño de la base lineal empleada, el tipo y tamaño del conjunto de espectros de entrenamiento, la velocidad de cálculo y la conversión A/D de los datos registrados.

2.- El anterior modelo teórico ha permitido estudiar las características de los sensores óptimos de un sistema multiespectral, aportando importantes ideas para el posterior diseño del mismo. Se ha comprobado el estrechamiento de los sensores óptimos al aumentar el ruido y el número de los mismos, la dependencia de su forma espectral con el algoritmo de estimación espectral, la base lineal de vectores estadísticamente representativos o el propio número de sensores. En cualquier caso, se ha probado que es posible obtener estimaciones espectrales de luz-cielo de alta calidad a partir de las respuestas de un número reducido de sensores óptimos.

3.- Se ha preferido proponer para trabajos futuros el uso del algoritmo de regresión lineal frente al resto de algoritmos estudiados en este trabajo, por su sencillez matemática, robustez frente al ruido y excelentes resultados. El algoritmo de Imai-Berns también es una buena alternativa siempre y cuando se disponga de una base de vectores representativos de suficiente calidad.

4.- Al usar el mismo número de vectores base PCA que de sensores, en un sistema multiespectral con un número reducido de ellos, las reconstrucciones espectrales son significativamente mejores. También se ha comprobado que aumentar el número de sensores no siempre implica una mejora en la calidad de las estimaciones obtenidas, si el efecto del ruido es importante.

5.- Para poder simular computacionalmente todas las características del sistema multiespectral que hemos creído relevantes, ha sido necesario implementar un algoritmo de ‘*simulated annealing*’ que reduce considerablemente el tiempo de computación. La programación de este algoritmo requiere la utilización de una única métrica para evaluar la calidad de las reconstrucciones espectrales, para lo que se ha propuesto la métrica combinada espectral y colorimétrica CSCM. Esta métrica ha demostrado tener un excelente comportamiento en la evaluación de la calidad de las reconstrucciones espectrales desde tres puntos de vista diferentes: espectral, colorimétrico y de la radiancia integrada.

6.- Hemos comprobado que la utilización de bases NMF no mejora los resultados obtenidos con las bases ampliamente conocidas del Análisis de Componentes Principales (PCA). Las bases ICA pueden resultar interesantes en aquellos sistemas multiespectrales en los que el ruido no es excesivamente alto, pues la mayor dimensión de las matrices - consecuencia de la necesidad de usar un mayor número de vectores ICA- reduce la robustez frente al ruido del algoritmo.

7.- Ha quedado demostrada la posibilidad de obtener estimaciones espectrales de luz-cielo a partir de las respuestas de una cámara CCD RGB. Se ha probado que dichos espectros se pueden utilizar para calcular en tiempo real el valor de diversos parámetros climatológicos que proporcionan información sobre el tamaño y la concentración de partículas en suspensión en la atmósfera.

8.- Para el anterior estudio ha sido necesario llevar a cabo una campaña de 902 medidas espectrorradiométricas de luz-cielo simultáneamente con el registro de imágenes de la cámara CCD durante 5 meses. La base de datos contruida contiene información RGB y espectral del cielo granadino en multitud de situaciones atmosféricas, elevaciones y horas del día, y podría utilizarse para la elaboración de algoritmos de detección automática de nubes basados en las características espectrales y colorimétricas de las mismas.

9.- Se ha construido un sistema multiespectral a partir de una cámara CCD monocromática y un filtro sintonizable de cristal líquido (LCTF). Para ello ha sido necesario previamente llevar a cabo una calibración completa tanto del filtro como de la cámara. La

calibración de la cámara ha permitido corregir algunas fuentes de ruido que la afectan, así como la falta de linealidad y de homogeneidad espacial que siempre presentan. Esto ha servido para convertir la CCD en un preciso instrumento radiométrico.

10.- Hemos comprobado, en las calibraciones de los elementos de este sistema multiespectral, que -a falta de una fuente monocromática y de una esfera integradora- la propia luz-cielo y el LCTF pueden servir como elementos suficientemente buenos para llevar a cabo estas tareas de calibración.

11.- El anterior sistema multiespectral se ha utilizado en tres configuraciones diferentes, dando todas ellas resultados aceptables en la reconstrucción espectral de un conjunto de 125 medidas de luz-cielo en días despejados que se ha recogido en Granada durante 3 meses.

12.- El método de muestreo monocromático no requiere fase de entrenamiento, pero sí un conocimiento exacto de las sensibilidades espectrales de los canales del LCTF y de la propia cámara CCD. Este método no aporta información espectral más allá del intervalo barrido por el LCTF.

13.- Los métodos de regresión lineal y de Imai-Berns con vectores PCA, aplicados al sistema de 33 canales construido con la cámara monocromática, han aportado resultados similares si bien el de Imai-Berns se prefiere por proporcionar la posibilidad de eliminar los efectos del ruido reduciendo la dimensión del problema a sólo las 6 primeras componentes principales de los vectores. En el caso de un sistema de este tipo, con un elevado número de canales, deja de ser cierto que la elección óptima sea  $n = k$ . Asimismo, estos métodos permiten obtener información espectral en todo el intervalo abarcado por las medidas de entrenamiento, si bien requieren de una fase de entrenamiento del sistema, que se ha llevado a cabo simulando las respuestas de la cámara CCD al conjunto de 1567 espectros de luz-cielo medidos en Granada a finales de los 90.

14.- Se ha comprobado que, utilizando un número reducido de sensores óptimos implementables a partir de nuestro LCTF, es posible obtener reconstrucciones espectrales de

calidad similar a la obtenida con los métodos anteriores que usan 33 canales. Sin embargo, el tiempo empleado para la captura de imágenes es mucho menor.

El trabajo futuro, tras la finalización de esta tesis doctoral, pasa por finalizar algunas de las propuestas que hemos dejado inconclusas por falta de tiempo o por ser trabajos demasiado tangenciales a la idea principal de la línea principal escogida. En concreto, pretendemos:

1.- Aumentar la estadística sobre los resultados de estimación de parámetros climáticos a partir de las estimaciones espectrales que se consiguen con la cámara RGB. Asimismo, se pretende realizar el cálculo de esos parámetros utilizando también el sistema multiespectral que hemos implementado con la cámara monocromo y el filtro LCTF.

2.- Elaborar un algoritmo de detección y clasificación automática de nubes a partir de la información espectral, colorimétrica y de textura que de las mismas podemos extraer usando las imágenes registradas con los sistemas estudiados en este trabajo.

3.- Extender el estudio teórico del capítulo 3 a otros algoritmos de estimación espectral, como son el de Wiener, algoritmos de regresión no-lineal y redes neuronales. Compararemos la calidad aportada por estos métodos con la que hemos obtenido y presentado en este trabajo para los métodos que más comúnmente se usan en la bibliografía relacionada con los sistemas multiespectrales.

4.- En colaboración con el prof. N. Shimano de la Universidad de Kinki (Osaka, Japón), ampliar el estudio de optimización de sensores para sistemas híbridos de adquisición de imágenes de iluminantes naturales y reflectancias de objetos en una escena.

5.- Implementar con nuestro sistema multiespectral basado en LCTF y cámara monocromática el resto de ejemplos de sensores óptimos encontrados en el estudio teórico del capítulo 3.

6.- Aumentar el número de medidas realizadas con este sistema multiespectral para poder llevar a cabo una fase de entrenamiento propia para dicho sistema. Pretendemos con ello aumentar significativamente la calidad de las reconstrucciones espectrales que hasta ahora hemos conseguido con él.



**Referencias bibliográficas:**

- Alotto P., Caiti A. Molinari G. y Repetto M. [1996], “A multiquadrics-based algorithm for the acceleration of simulated annealing optimization procedures”, *IEEE Trans. Mag.* **32**, pp. 1198-1201.
- Buschbaum G. y Bloch O. [2002], “Color categories revealed by non-negative matrix factorization of Munsell color spectral”, *Vision Res.* **42**, 559-563.
- Burns P. D. y Berns R. S., [1999], “Quantization in multispectral color image acquisition”, en *Proceedings of the IS&T 7<sup>th</sup> Color Imaging Conference: Color Science, Systems and Applications* (Society for Imaging Science and Technology), pp. 32-35.
- Chandra K. y Healey G. [2004], “Estimating visible through near-infrared spectral reflectance from a sensor radiance spectrum”, *J. Opt. Soc. of Am. A*, **21**, pp. 1825-1833.
- Cheung V., Li C., Westland S., Hardeberg J. Y. y Connah D. [2005], “Characterization of trichromatic color cameras by using a new multispectral imaging technique”, *J. Opt. Soc. Am. A* **22**, 1231-1240.
- Connah D., Westland S. y Thomson M. G. A. [2001], “Recovering spectral information using digital camera systems,” *Color Technol.* **117**, 309-312.
- Connah D., Westland S. y Thomson M. G. A. [2002], “Optimization of a multispectral imaging system,” en *Proceedings of the 1<sup>st</sup> European Conference on Colour Graphics, Image and Vision* (Society for Imaging Science and Technology, Springfield, Va.), pp. 619-622.
- CIE [1994], “Guide to recommended practice of daylight measurement”, CIE Technical Report, Publ. No. CIE 108, 1st ed., Central Bureau of the CIE, Vienna.
- CIE [2004], “Colorimetry”, CIE Technical Report, Publ. No. CIE 15, 3<sup>rd</sup> ed., Central Bureau of the CIE, Vienna.
- Day D. C. [2003], “Filter selection for spectral estimation using a trichromatic camera”, M. Sc. dissertation, Rochester Institute of Technology, (<http://www.art-si.org/PDFs/Acquisition/DCDayMSThesis03.pdf>).
- Day E. A. [2003b], “The effects of multi-channel spectrum imaging on perceived spatial image quality and color reproduction accuracy”, M. Sc. Dissertation, Rochester Institute of Technology, (<http://www.art-si.org/PDFs/Metric/EDayMSThesis03.pdf>).

## Referencias

- de Lasarte M., Pujol J., Arjona M. y Vilaseca M. [2007], “Optimized algorithm for the spatial nonuniformity correction of an imaging system based on a charged-coupled device color camera”, *Appl. Opt.* **46**, 167-174.
- de Lasarte M., Pujol J., Arjona M. y Vilaseca M. [2007b], “Estudio de la influencia del tamaño del conjunto de entrenamiento en la medida del color mediante sistemas multiespectrales”, *actas del VIII Congreso Nacional de Color*, Madrid, pp. 183-184.
- Ferrero A., Campos J., Pons A. [2006] “Apparent violation of the radiant exposure reciprocity law in interline CCDs”, *App. Opt.* **45**, 3991-3997.
- Ferrero A., Campos J. y Pons A. [2006b], “Low-uncertainty absolute radiometric calibration of a CCD”, *Metrología* **43**, S17-S21.
- Ferrero A., Campos J. y Pons A. [2006c], “Experimental assessment of relative temporal fluctuation of CCD pixels”, *Eur. Phys. J. Appl. Phys.* **33**, 225-228.
- Ferrero A., Campos J. y Pons A. [2006d], “Correction of photoresponse nonuniformity for matrix detectors based on prior compensation for their nonlinear behaviour”, *Appl. Opt.* **45**, 2422-2427.
- Foster D. H., Nascimento S. M. C. y Amano K. [2004], “Information limits on neural identification of colored surfaces in natural scenes”, *Vis. Neurosci.*, **21**, 331-336.
- Franco S. [2002], *Design with operational amplifiers and analog integrated circuits*, 3<sup>rd</sup> ed. (McGraw-Hill, Boston), pp. 311-346.
- Goody R. M. y Yung Y. L. [1995], *Atmospheric Radiation, Theoretical Basis*, 2<sup>nd</sup> edition, (Oxford University Press, London). Capítulo 5.
- Haneishi H., Hasegawa T., Hosoi A., Yokoyama Y., Tsumura N., y Miyake Y. [2000], “System design for accurately estimating spectral reflectance of art paintings”, *Appl. Opt.* **39**, 6621-6632.
- Hardeberg J. Y. [1999], “Acquisition and reproduction of color images: colorimetric and multispectral approaches”, Ph. D. dissertation (Ecole Nationale Supérieure des Télécommunications, Paris).

- Healey G. E. y Kondepudy R. [1994], “Radiometric CCD Camera Calibration and Noise Estimation”, *IEEE Trans. Pattern Anal. Machine Intell.* **16**, 267-276.
- Hernández-Andrés J., Romero J., García-Beltrán A. y Nieves J. L. [1998], “Testing linear models on spectral daylight measurements”, *Appl. Opt.* **37**, 971-977.
- Hernández-Andrés J. [1999], “Características espectrales y colorimétricas de la luz-día y luz-cielo en Granada”, Tesis Doctoral, Universidad de Granada.
- Hernández-Andrés J., Nieves J. L., Romero J. y Lee Jr., R. L. [2001], “Color and spectral analysis of daylight in Southern Europe”, *J. Opt. Soc. Am. A* **18**, 1025-1035.
- Hernández-Andrés J., Romero J. y Lee R. L. Jr. [2001b], “Colorimetric and spectroradiometric characteristics of narrow-field-of-view clear skylight in Granada, Spain”, *J. Opt. Soc. Am. A*, **18**, pp. 412-420.
- Hernández-Andrés J., Lee R. L. Jr., Romero J. [2003], “Color and luminance asymmetries in the clear sky”, *Appl. Opt.* **42**, 458-464.
- Hernández-Andrés J., Nieves J. L., Valero E. M. y Romero J. [2004], “Spectral daylight by use of only a few sensors”, *J. Opt. Soc. Am. A* **21**, 13-23.
- Holben B. N., Eck T. F., Slutsker I., Tanre D., Buis J. P., Setzer A., Vermote E., Reagan J. A., Kaufman Y. J., Nakajima T., Lavenue F., Jankowiak I. y Smirnov A. [1998], “AERONET-A federated instrument network and data archive for aerosol characterization”, *Remote Sens. of Environ.* **66**, 1-16.
- Holst G. C. [1996], “*CCD Arrays, Cameras and Displays*”, SPIE Optical Engineering Press, Bellingham Washington USA.
- Holst G. C. [2001], “Solid State Cameras” en *Handbook of Optics* vol. III, McGraw-Hill, New York USA, 4.1-4.21.
- Hong G., Luo M. R. y Rhodes P. A. [2001], “A study of digital camera colorimetric characterization based on polynomial modeling”, *Color Res. Appl.* **26**, 76-84.
- Hoyer P. O. [2004], “Non-negative factorization with sparseness constraints”, *J. Mach. Learn. Res.* **5**, 1457-1469.

## Referencias

- Hubel P. M., Liu J. y Guttosch R. J. [2004], “Spatial frequency response of color image sensors: Bayer color filters and Foveon X3”, in *Proceedings of the SPIE 2004*, Vol. 5301, pp. 402-407.
- Huertas R., Roa R., López-Álvarez M. A., Robledo L. y Melgosa M. [2007], “Comparación entre fuentes simuladoras e iluminantes”, actas del *VIII Congreso Nacional de Color*, Madrid, pp. 37-38.
- Hunt R. W. G. [1998], *Measuring Colour*, 3<sup>rd</sup> ed. (Fountain Press, London), pp. 39-198.
- Hyvärinen A., Karhunen J., y Oja E. [2001], *Independent component analysis*, 1<sup>st</sup> ed. (Wiley, New York), pp. 147-292.
- Imai F. H. y Berns R. S. [1999], “Spectral estimation using trichromatic digital cameras”, en *Proceedings of the International Symposium on Multispectral Imaging and Color Reproduction for Digital Archives* (Society of Multispectral Imaging of Japan, Chiba, Japan), pp. 42-48.
- Imai F. H., Rosen M. R. y Berns R. S. [2002], “Comparative study of metrics for spectral match quality”, en *Proceedings of the 1<sup>st</sup> European Conference on Colour in Graphics, Image and Vision* (Society for Imaging Science and Technology, Springfield, Va.), pp. 492-496.
- Imai F. H., Taplin L. A., Day D. C., Day E. A. y Berns R. S. [2002b], “Imaging at the National Gallery of Art, Washington DC”, Munsell Color Science Lab. Technical Report (<http://art-si.org>).
- Imai F. H., Taplin L. A. y Day E. A. [2003], “Comparative study of spectral reflectance estimation based on broad-band imaging systems”, Munsell Color Lab. Technical Report (<http://art-si.org>).
- Imai F. H., Kuo D. y Motta R. J. [2005], “Colorimetric characterization of a HDR display system”, en *Proceedings of the 10th Congress of the International Colour Association (AIC'05)*, (Granada, Spain, 2005), pp. 653-656.
- Ipson S. S. y Okereke C. [1999], “Vision and image sensors” en *Measurement, Instrumentation and sensors (Handbook)*, John G. Webster ed. (Chapman&Hall, CRCnetBASE), Cap. 64.
- Janesick J. R. [2001], “*Scientific Charge-Coupled Devices*” SPIE Press, Bellingham Washington USA.

- Kirpatrick S., Gelatt Jr. C. D. y Vecchi M. P. [1983], "Optimization by simulated annealing", *Science* **220**, pp. 671-680.
- Kuehni R. G. [2003], *Color space and its divisions: color order from antiquity to the present*, 1<sup>st</sup> ed. (Wiley, New York), pp. 204-270.
- Lathi B. P. [1989], *Modern digital and analog communication systems*, 2<sup>nd</sup> ed. (Oxford University Press).
- Lee D. D. y Seung H. S. [1999], "Learning the parts of objects by non-negative matrix factorization", *Nature (London)* **401**, 788-793.
- Lee T. W., Girolami M., Sejnowski T. J. [1999], "Independent Component Analysis using an extended infomax algorithm for mixed sub-Gaussian and super-Gaussian sources". *Neural Comput.* **11**, 417-441.
- Lerch M. L. F., Rosenfeld A. B., Simmonds P. E., Taylor G. N. y Meikle S. R. [2001], "Spectral characterization of a blue-enhanced silicon photodetector", *IEEE T. Nuc. Sci.* **48**, 1220-1224.
- Lloris A., Prieto A. [1996], *Diseño Lógico*, 1<sup>a</sup> ed. (McGraw-Hill, Madrid).
- López-Álvarez M. A., Hernández-Andrés J., Romero J. y Lee Jr. R. L. [2005], "Designing a practical system for spectral imaging of skylight", *Appl. Opt.* **44**, 5688-5695.
- López-Álvarez M. A., Hernández-Andrés J., Valero E. M. y Nieves J. L. [2005b], "Colorimetric and spectral combined metric for the optimization of multispectral systems", en *Proceedings of the 10th Congress of the International Colour Association (AIC'05)*, (Granada, Spain, 2005), pp. 1685-1688.
- López-Álvarez M. A., Hernández-Andrés J., Romero J. [2005c], "Optimal sensors for spectral imaging of skylight", en *Proceedings of the 10th Congress of the International Colour Association (AIC'05)*, (Granada, Spain, 2005), pp. 156-159.
- López-Álvarez M. A., Hernández-Andrés J., Nieves J. L. y Romero J. [2006] "Influence of the recovery method on the optimum sensors for spectral imaging of skylight", en *SPIE-IS&T Electronic Imaging 2006*, Proc. SPIE **6062**, 606209\_1-606209\_9.

## Referencias

- López-Álvarez M. A., Hernández-Andrés J., Valero E. M. y Romero J. [2007], “Selecting algorithms, sensors, and linear bases for optimum spectral recovery of skylight”, *J. Opt. Soc. Am. A* **24**, 942-956.
- López-Álvarez M. A., Hernández-Andrés J., Campos J., Pons A. y Romero J. [2007b], “Variación del ruido con el tiempo de exposición en una CCD”, actas del *VIII Congreso Nacional de Color*, Madrid, pp. 157-158.
- López-Álvarez M. A., Hernández-Andrés J. y Romero J. [2007c], “Elección de los espectros de entrenamiento para el calibrado de un sistema multiespectral”, actas del *VIII Congreso Nacional de Color*, Madrid, pp. 155-156.
- Luo M. R., Cui G. y Rigg B. [2001], “The development of the CIE 2000 colour-difference formula: CIEDE2000”, *Color Res. Appl.* **26**, pp. 340-350.
- Maloney L. T. y Wandell B. A. [1986], “Color constancy: A method for recovering surface spectral reflectance,” *J. Opt. Soc. Am. A* **3**, 29-33.
- Marimont D. H. y Wandell B. A. [1992], “Linear models of surface and illuminant spectra,” *J. Opt. Soc. Am. A* **9**, 1905-1913.
- Metropolis N., Rosenbluth A., Rosenbluth M., Teller A. y Teller E., [1953] “Equations of state calculations by fast computing machines”, *J. Chem. Phys.* **21**, 1087-1092.
- Michalsky J. J. [1985], “Estimation of continuous solar spectral distributions from discrete filter measurements: II. A demonstration of practicability”, *Sol. Energy* **34**, pp. 439-445.
- Mohammadi M., Nezamabadi M., Berns R. S. y Taplin L. A. [2004], “Spectral imaging target development based on hierarchical cluster analysis”, en *Proceedings of 12<sup>th</sup> Color Imaging Conference: Color Science and Engineering, Systems, Technologies and Applications*, IS&T, Springfield, pp. 59-64, ([www.art-si.org](http://www.art-si.org)).
- Nascimento S. M. C., Ferreira F. P. y Foster D. H. [2002], “Statistics of spatial coneexcitation ratios in natural scenes”, *J. Opt. Soc. Am. A*, **19**, 1484-1490.
- Nieves J. L., Valero E. M., Nascimento S. M. C., Hernández-Andrés J., y Romero J. [2005], “Multispectral synthesis of daylight using a commercial CCD camera”, *Appl. Opt.* **44**, 5696-5703.
- Olmo F. J., Cazorla A., Alados-Arboledas L., López-Álvarez M. A., Hernández-Andrés J., Romero J. [2007], “Using All-Sky Imager to obtain aerosol and cloud optical properties”,

- en *Proceedings of the 9<sup>th</sup> International Meeting on Meteorological Optics*, Montana (USA).
- Oxtoby E.K., Foster D.H., Amano K., Nascimento S.M.C. [2002], “How many basis functions are needed to reproduce coloured patterns under illuminant changes?” in *Proceedings of the XV European Conference on Visual Perception*, Perception, S31, p. 66.
- Pardo G., González Caballero F., Bruque J. M. [1975], *Mecánica*, Ed. Paraninfo, Madrid, pp. 15-125.
- Park S. J. y Eden J. G. [2002], “Photodetection in the visible, ultraviolet, and near-infrared with silicon microdischarge devices”, *Appl. Phys. Lett.* **81**, 4529-4531.
- Pathria R. K. [1996], *Statistical Mechanics*, 2nd edition, Oxford: Butterworth-Heinemann, Cap. 1-2.
- Peralta C., Pons A. y Campos J. [2007], “Caracterización de un LCTF”, en *Actas del VIII Congreso Nacional de Color*, Madrid, pp. 165-166.
- Prieto A., Lloris A., Torres J. C. [2002], *Introducción a la informática*, 2ª edición, McGraw-Hill, Madrid, Cap. 1.
- Pratt W. K. [1991], *Digital image processing*, Wiley Inter Science, pp. 404-406.
- Pratt W. K. y Mancill C. E. [1976], “Spectral estimation techniques for the spectral calibration of a color image scanner”, *App. Opt.* **15**, 73-75.
- Ricchiazzi P., Yang S., Gautier C., Sowle D. [1998], “SBDART: A research and teaching software tool for plane-parallel radiative transfer in the Earth’s atmosphere”, *Bull. Amer. Meteorol. Soc.* **79**, 2101-2113.
- Romero J., García-Beltrán A., y Hernández-Andrés J. [1997], “Linear bases for representation of natural and artificial illuminants,” *J. Opt. Soc. Am. A* **14**, 1007-1014.
- Schettini R., Novati G. y Pellegrini P. [2004] “Training set and filters selection for the efficient use of multispectral acquisition systems”, en *Proceedings of the 2<sup>nd</sup> European Conference on Colour Graphics, Image and Vision (IS&T, Springfield, Va., 2002)*, 422-426.

## Referencias

- Sharma G., Trussell H. J., Vrhel M. J. [1998], "Optimal nonnegative color scanning filters", *IEEE T. Image Process.*, **7**, 129-133.
- Shi M. y Healey G. [2002], "Using reflectance models for color scanner calibration", *J. Opt. Soc. Am. A* **19**, 645-656.
- Shimano N. [2002], "Suppression of noise effects in color correction by spectral sensitivities of image sensors", *Opt. Rev.* **9**, 81-88.
- Shimano N. [2004], "Optimal Spectral Sensitivities of a Color Image Acquisition Device in the Presence of Noise", *Proceedings of the 2<sup>nd</sup> European Conference on Colour Graphics, Imaging and Vision* (Society for Imaging Science and Technology, Springfield, Va., 2004), pp. 379-383.
- Shimano N. [2005], "Evaluation of a multispectral image acquisition system aimed at reconstruction of spectral reflectances", *Opt. Eng.* **44**, 107005\_1-107005\_6.
- Shimano N. [2006], "Optimization of spectral sensitivities with Gaussian distribution functions for a color image acquisition device in the presence of noise", *Opt. Eng.* **45**, 013201\_1-013201\_8.
- Shimano N., Terai K. y Hironaga M. [2007], "Recovery of spectral reflectances of objects being imaged by multispectral cameras", *J. Opt. Soc. Am. A*, aceptado para publicación.
- Stigell P., Miyata K., Hauta-Kasari M. [2005], "The Wiener estimation method in estimation of spectral reflectance from RGB images", *Pattern Recogn. and Image Anal.* **15**, 327-329.
- Sze S. M. [1981], *Physics of semiconductor devices*, 2<sup>nd</sup> ed. (Wiley, New York), pp. 362-510.
- Viggiano J. A. S. [2002], "A perception-referenced method for comparison of radiance ratio spectra and its application as an index of metamerism", *Proc. SPIE* **4421**, pp. 701-704.
- Viggiano J. A. S. [2004], "Metrics for evaluating spectral matches: a quantitative comparison", en *Proceedings of the 2<sup>nd</sup> European Conference on Colour in Graphics, Imaging and Vision* (Society for Imaging Science and Technology, Springfield, Va.), pp. 286-291.
- Vilaseca M., Pujol J. y Arjona M. [2003], "Illuminant influence on the reconstruction of near-infrared spectra", *J. Imag. Sc. and Tech.* **48**, 111-119.

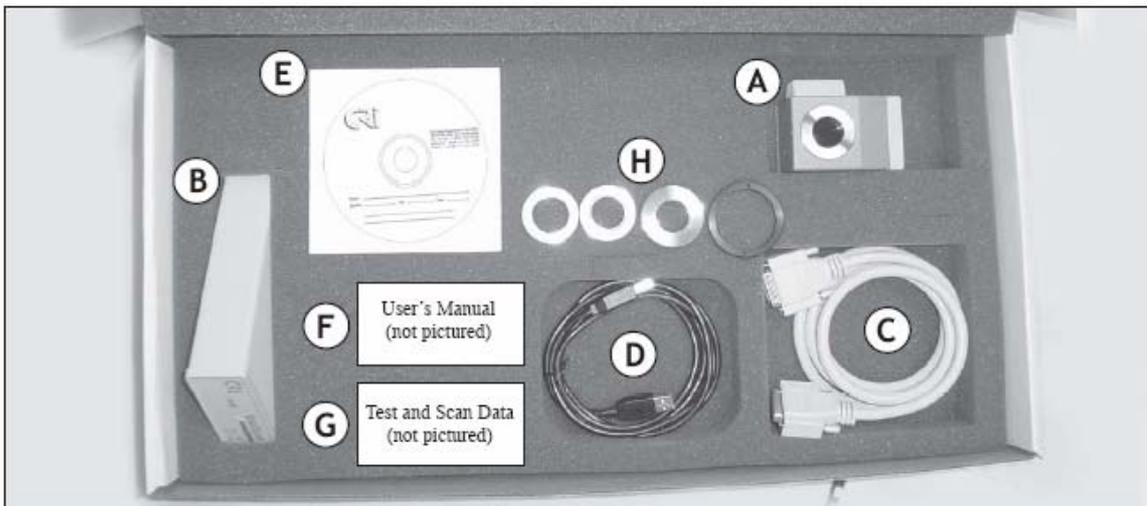
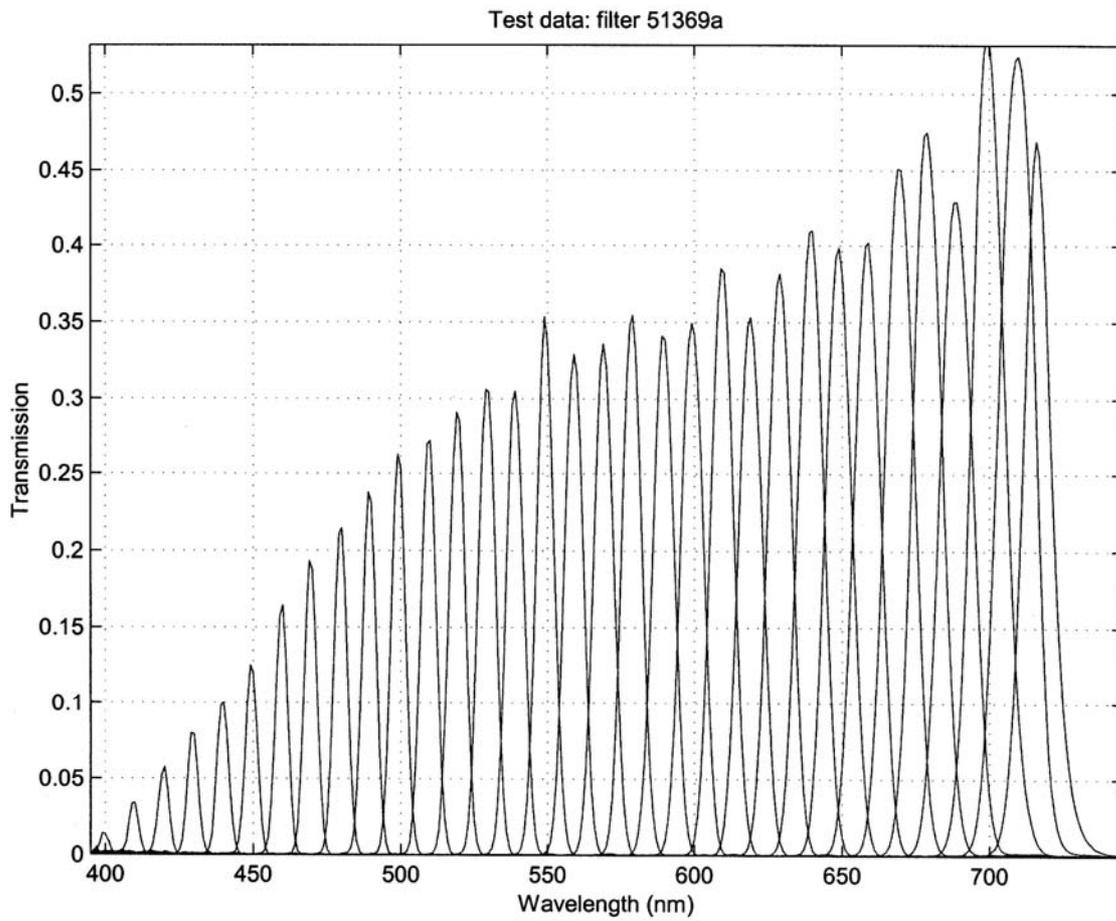
- Vilaseca M. [2005], “Diseño de un nuevo sistema para la reconstrucción de espectros y visualización de imágenes en el infrarrojo próximo (800-1000nm)”, Tesis doctoral, Universidad Politécnica de Cataluña, Tarrasa.
- Wyszecki G. y Stiles W. S. [1982], *Color Science: concepts and methods, quantitative data and formulae*, 2<sup>nd</sup> ed. (Wiley, New York), pp. 117-248.
- Xiong W. y Funt B. [2005], “Independent component analysis and nonnegative linear model analysis of illuminant and reflectance spectra” in *Proceedings of the 10th Congress of the International Colour Association (AIC’05)*, (Granada, Spain, pp. 503-506.
- Yokoyama Y., Tsumura N., Haneishi H., Hayasi J. y Saito M. [1997], “A new color management system based on human perception and its application to recording and reproduction of art paintings”, en *Proceedings of the 5<sup>th</sup> Color Imaging Conference: Color Science, Systems and Applications*, pp. 169-172.
- Yotter R. A. y Wilson D. M. [2003], “A review of photodetectors for sensing light-emitting reporters in biological systems”, *IEEE Sens. J.*, **3**, pp. 288-303.

## Referencias

# **APÉNDICES.**



**APÉNDICE I: Hoja de características del filtro LCTF VariSpec de CRI.**



# Cambridge Research & Instrumentation, Inc.

## VariSpec™ Liquid Crystal Tunable Filter

---



# Specifications

Note that these specifications represent typical VariSpec filters as of June 2004 and are subject to change without notice.

Parameter	VariSpec VIS	VariSpec SNIR	VariSpec LNIR
Wavelength range (nm)	400–720	650–1100	850–1800
Bandwidth, FWHM (nm)	7, 10, or 20	7 or 10	6 or 20
Working aperture (mm)	20 or 35	20	20
Field-of-view (half-angle)	7.5 degrees	7.5 degrees	3.5 degrees
Wavelength accuracy	Bandwidth/8	Bandwidth/8	Bandwidth/8
Maximum optical input	500 mW/cm <sup>2</sup>	500 mW/cm <sup>2</sup>	500 mW/cm <sup>2</sup>
Optics response time (ms) <sup>1</sup>	50	150	150
Operating temperature	10°–40° C	10°–40° C	10°–40° C
Storage temperature	-15°–55° C	-15°–55° C	-15°–55° C
Computer interface	USB 1.1, Type B	USB 1.1, Type B	USB 1.1, Type B
Power supply	USB bus-powered	USB bus-powered	USB bus-powered
Single- or Dual-housing design <sup>2</sup>	Single-housing	Single-housing	Single-housing (6 mm) Dual-housing (20 mm)
Optics module exterior	Blue/Gray painted <sup>3</sup>	Blue/Gray painted	Black-anodized OEM

<sup>1</sup> Optics response time depends on a number of factors including ambient temperature (colder temperatures cause the liquid crystal material to become more viscous and slower to respond) and model (NIR models are slower to respond than VIS models). Older filters (with electronics designed with a RS-232 serial interface) used a microprocessor that was not as fast as newer versions and, unless the 'palette' function was utilized, might respond in 300 ms or more.

<sup>2</sup> Dual-housing filters use two sets of optics and electronics. They must both be sent identical commands, but do not need to be addressed simultaneously.

<sup>3</sup> 35-mm optics enclosures are black-anodized aluminum. See Appendix A: Mechanical Dimensions, for more detail.

**IMPORTANT:** In order for the VariSpec demonstration software to perform properly, your host computer must consist, at minimum, of a Pentium-class CPU with 256 MB RAM, hard drive with reasonable free disk space, Windows™ 2000 or XP Professional, and bus-powered USB 1.1 specification ports (or newer) in sufficient number for the Electronics Module(s) your filter contains.



**APÉNDICE II: Hoja de características de la cámara Retiga QImaging SRV-1394.**



**RETIGA-SRV *FAST1394***

Deep-Cooled, High-Sensitivity IEEE 1394 FireWire® Digital CCD Camera

The QImaging® Retiga-SRV CCD digital camera has been specially engineered for low-light, high-speed, high-sensitivity applications. A three-stage Peltier device and an all-metal, hermetic-vacuum-sealed CCD chamber provide state-of-the-art cooling to -30°C; the camera's software-selectable, regulated cooling enables precise control in single-degree increments. The Retiga-SRV features a 1.4-megapixel CCD, 12-bit digital output, and an IEEE 1394 interface for enhanced connectivity and noise-shielding performance. Additionally, the camera comes with iGlo™ Technology, which features an Organic Light Emitting Diode (OLED) display that provides users with key information about camera settings in a convenient, ergonomic way.



*Note: Lens shown for illustration only and is not included.*

**camera models**

*Includes: IEEE 1394 FireWire cable, IEEE 1394 PCI card, power supply, QCapture Suite software and access to SDK*

- **Monochrome Retiga-SRV:**  
Model: RET-SRV-F-M-12-C  
Model: RET-SRV-F-M-12-C-IR

**camera options**

- Removable IR-Cutoff Filter
- RGB Color Filter for monochrome cameras (F-mount interface required), refer to data sheet for more details
- Extended Warranty



features	benefits
iGlo™	<ul style="list-style-type: none"> <li>▪ OLED display for easy-to-verify key camera information in a simple, ergonomic design</li> </ul>
Black-Out Mode	<ul style="list-style-type: none"> <li>▪ Turns all lights off for low-light imaging applications</li> </ul>
High Quantum Efficiency	<ul style="list-style-type: none"> <li>▪ Very high sensitivity for demanding low-light &amp; fluorescent imaging; "High Sensitivity" mode provides increased QE in the 500 to 1000nm spectral range and is easily switched on/off through software control</li> </ul>
High-Resolution, 1.4-Million-Pixel Sensor	<ul style="list-style-type: none"> <li>▪ Highly detailed, sharp images</li> </ul>
High-Speed Readout	<ul style="list-style-type: none"> <li>▪ Previewing &amp; focusing in real time</li> <li>▪ 110fps with 8x8 binning &amp; ROI</li> <li>▪ 11fps full resolution @ 12 bits</li> <li>▪ Ideal for automated imaging applications</li> </ul>
Low-Noise Electronics	<ul style="list-style-type: none"> <li>▪ Quantitation &amp; imaging of low light levels</li> </ul>
Optional/Removable IR-Cutoff Filter	<ul style="list-style-type: none"> <li>▪ High-contrast visible-range images with IR filter in place</li> <li>▪ Removable for IR applications</li> </ul>
Flexible Exposure Control from 1µs to 17.9min	<ul style="list-style-type: none"> <li>▪ Optimal integration over a wide range of light levels</li> </ul>
External Sync & Trigger	<ul style="list-style-type: none"> <li>▪ Tight synchronization with flashlamps, automated filters, shutters, &amp; microscope stages</li> </ul>
Three-Stage Peltier Cooling w/ Vacuum Seal	<ul style="list-style-type: none"> <li>▪ Reduced thermal noise for low-light, long exposures</li> </ul>
Binning	<ul style="list-style-type: none"> <li>▪ Increases sensitivity for quantitation &amp; imaging of very low light levels</li> <li>▪ Increases frame rate</li> </ul>
Extended IR Sensitivity	<ul style="list-style-type: none"> <li>▪ High-performance imaging outside the visible range</li> </ul>
IEEE 1394 FireWire Connection	<ul style="list-style-type: none"> <li>▪ Simple connectivity</li> <li>▪ Better noise performance</li> <li>▪ Excellent connectivity ability</li> <li>▪ Ease of use &amp; installation</li> <li>▪ Portability with laptop computer</li> <li>▪ Simultaneous use of multiple cameras through a single port</li> </ul>
Extensive Application Software Support	<ul style="list-style-type: none"> <li>▪ Choose from a large selection of life science &amp; industrial software for microscopy, machine vision, &amp; video-streaming functions</li> </ul>

## RETIGA-SRV FAST1394 Specifications

ccd sensor	
Enhanced Sensitivity	Software controlled to provide enhanced QE from 500 to 1000nm
Light-Sensitive Pixels	1.4 million; 1392 x 1040
Binning Modes	2x2, 4x4, 8x8
ROI (Region of Interest)	From 1x1 pixels up to full resolution, continuously variable in single-pixel increments
Exposure/Integration Control	1µs to 17.9min in 1µs increments
Sensor Type	Sony® ICX285 progressive-scan interline CCD (monochrome)
Pixel Size	6.45µm x 6.45µm
Linear Full Well	18,000e- (22,000e- with 2x2 binning)
Read Noise	8e-
Dark Current	0.05e-/pix/s
Cooling Technology	Three-stage Peltier cooling with all-metal hermetic-vacuum-sealed chamber assembled in a Class 1,000 cleanroom
Cooling Type	Down to -30°C, regulated, with software control in 1°C increments
Digital Output	12 bits
Readout Frequency	20, 10, 5MHz
Frame Rate	11fps full resolution @ 12 bits (165fps maximum with binning and ROI functions)
camera	
Black-Out Mode	Turns all camera lights off to reduce light reflection during low-light applications; software controlled
iGlo™ Display	Provides key camera information to the user, allowing easy verification of camera settings
Computer Platforms/ Operating Systems	Windows® & Mac OS*
Digital Interface	IEEE 1394 FireWire
External Trigger	TTL Input (optically coupled)
Trigger Types	Internal, Software, External
External Sync	TTL Output (optically coupled)
Gain Control	0.817 to 39 times
Offset Control	-2048 to 2047
Optical Interface	2/3", C-mount optical format
Threadmount	1/4" – 20 mount
Power Requirements	30W; 12–24VDC
Weight	1.1kg
Warranty	2 years
Operating Environment	0 to 40°C
Storage Temperature	0 to 50°C
Humidity	Less than 80% relative humidity

\*Refer to Qimaging website for detailed listing of supported operating systems.

Note: Specifications are nominal and subject to change.

iGlo is a trademark and Qimaging is a registered trademark of Qimaging Corporation. FireWire and Mac OS are trademarks of Apple Computer, Inc., registered in the U.S. and other countries. Sony is a registered trademark of Sony Corporation. Windows is a registered trademark of Microsoft Corporation in the United States and other countries. Other brand and product names are the trademarks or registered trademarks of their respective owners and manufacturers.

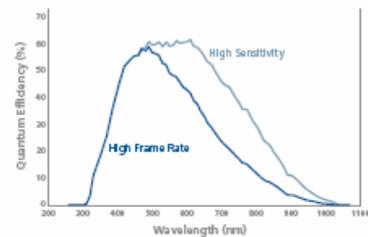


iGlo™ Technology features essential information about camera settings.

### applications

- Quantitative Fluorescence Microscopy
- FRET
- Live-Cell Fluorescent Protein Imaging
- Ratiometric Analysis (Ca<sup>2+</sup>, pH, etc.)
- Whole Animal Fluorescence
- FRAP
- FISH

### spectral response



Tel 604.708.5061 • Fax 604.708.5081 • info@qimaging.com  
www.qimaging.com

04-0019A-D

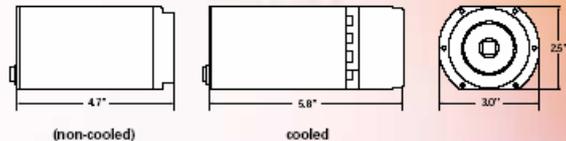
**APÉNDICE III: Hoja de características de la cámara Retiga QImaging Q1300C.**



**RETIGA 1300**

High Sensitivity IEEE 1394 FireWire™ Digital CCD Camera – Monochrome or Color

The QImaging Retiga 1300 CCD digital camera features enhanced visible quantum efficiency resulting in high sensitivity, ideal for demanding low light and fluorescence imaging applications. A progressive scan interline CCD sensor gives a resolution of 1.3 million pixels in a 12-bit digital output. High-speed low noise electronics provide linear digital data for rapid image capture. The IEEE 1394 FireWire™ digital interface allows ease of use and installation with a single wire requiring no framegrabber or external power supply. The Retiga 1300 includes QCapture Software for Microsoft Windows® and Mac® OS based systems for real time image preview and capture. A Software Development Kit (SDK) is available upon request for interfacing with custom software.



Note: Lenses are shown for illustration only and are not included.

CAMERA MODELS	FEATURES	BENEFITS
<p><i>Includes: IEEE 1394 FireWire™ cable, IEEE 1394 PCI card, QCapture software and access to SDK</i></p> <ul style="list-style-type: none"> <li>■ <b>Monochrome Retiga 1300 Cooled</b> Model: RET-1300-M-12-C</li> <li>■ <b>Monochrome Retiga 1300 Non-cooled</b> Model: RET-1300-M-12</li> <li>■ <b>Color Retiga 1300 Cooled</b> Model: RET-1300-CLR-12-C</li> <li>■ <b>Color Retiga 1300 Non-cooled</b> Model: RET-1300-CLR-12</li> </ul>	High Resolution 1.3 Million pixel sensor	■ Highly detailed, sharp images
	Large Pixels 6.7µm x 6.7µm	■ High Sensitivity, high dynamic range, large well capacity
	High Speed Readout	<ul style="list-style-type: none"> <li>■ Previewing &amp; focusing in real time</li> <li>■ 70fps in 4x4 binning &amp; ROI</li> <li>■ 12fps full resolution</li> <li>■ Ideal for automated imaging applications</li> </ul>
	Low Noise Electronics	■ Quantitation & imaging of low light levels
	12-bit digitization/ 36-bit color digitization	<ul style="list-style-type: none"> <li>■ 4096 grey levels for precise light intensity discrimination</li> <li>■ 4096 levels per channel for superior colour images</li> </ul>
	External Sync and Trigger	■ Tight synchronization with flashlamps, automated filters, shutters & microscope stages
	Peltier Cooling	■ Minimizes thermal noise during low light long exposure imaging
<b>CAMERA OPTIONS</b>	Binning	<ul style="list-style-type: none"> <li>■ Increased sensitivity for quantitation &amp; imaging of very low light levels</li> <li>■ Increased frame rate</li> </ul>
<ul style="list-style-type: none"> <li>■ <b>RGB Color Filter</b> for monochrome cameras (F-mount interface required). Refer to spec sheet for more details.</li> <li>■ <b>Extended Warranty</b></li> </ul> 	IEEE 1394 FireWire™	<ul style="list-style-type: none"> <li>■ Simple connectivity</li> <li>■ Ease of use &amp; installation</li> <li>■ Portability with laptop computer</li> <li>■ Simultaneous use of multiple cameras through a single port</li> <li>■ Single cable operation, no external power supply or control unit</li> </ul>
	Extensive application software support	■ Choose from a large selection of life science & industrial software for microscopy, machine vision and video streaming functions

### APPLICATIONS

- Brightfield, Phase Contrast and Dark-field Microscopy
- Fluorescence Microscopy
- Live Cell Imaging
- Pathology, Histology, Cytology
- Green Fluorescent Protein (GFP) Application
- FISH
- Ca<sup>++</sup> Ratio Analysis
- Motility and Motion Analysis
- DNA Analysis
- Metallurgical Microscopy
- Semiconductor Inspection
- Manufacturing Quality Control
- Failure Analysis
- Forensic Analysis

## RETIGA 1300 SPECIFICATIONS

CCD SENSOR	
Light Sensitive Pixels	1.3 million; 1280 x 1024
Binning Modes	2x2, 3x3, 4x4
ROI (Region Of Interest)	From 1x1 pixels up to full resolution, continuously variable in single pixel increments
Exposure/Integration Control	40µs to 17.9min in 1µs increments
Sensor Type	Sony ICX085 Progressive Scan Interline CCD, Monochrome or Color
Pixel Size	6.7µm x 6.7µm
Linear Full Well	18,000e <sup>-</sup>
Dark Current	0.15e <sup>-</sup> /pix/s cooled
Cooling Available	Yes
Cooling Type	Peltier thermoelectric cooling to 25 degrees Celsius below ambient
Digital Output	12-bit
Readout Frequency	20, 10, 5, 2.5MHz
Frame Rate	12fps full resolution, higher speeds with binning and ROI functions
CAMERA	
Computer Platforms/Operating Systems	Microsoft Windows* & Mac* OS*
Digital Interface	IEEE 1394 FireWire™
Shutter Control	Electronic shutter, no moving parts
External Trigger	TTL Input
Trigger Types	Internal, Software, External
External Sync	TTL Output
Gain Control	Controlled in Software
Offset Control	Controlled in Software
Optical Interface	2/3", C-Mount optical format
Threadmount	1/4" – 20 Mount
Power Requirements	6 watts non-cooled; 11 watts cooled; 8-24V
Weight	595g; cooled 865g
Warranty	2 years
Operating environment	0 to 35 degrees Celsius (32 to 95F)
Humidity	Less than 80% at 35 degrees Celsius (95F)

### SPECTRAL RESPONSE

\*Refer to QImaging website for detailed listing of supported operating systems.  
Note: Specifications are nominal and subject to change.

04-0008-A



4401 Still Creek Drive, Suite 100  
 Burnaby BC Canada V5C 6G9  
 Tel 604.708.5061  
 Fax 604.708.5081  
 INFO@QIMAGING.COM  
[WWW.QIMAGING.COM](http://WWW.QIMAGING.COM)

**APÉNDICE IV: Hoja de características del espectrorradiómetro SpectraScan PR650.**

**PHOTO RESEARCH®**  
**PR®-650 SpectraScan® Colorimeter**



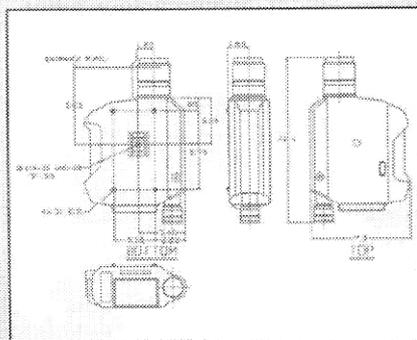
**Optional Accessories**

<b>Optical</b>	
<b>0.5X Supplementary</b> Spot Size 3.15" (2.54mm) Requires MS-75 Lens	SL-0.5X
<b>1X Supplementary Close-up Lens</b> Spot size 0.652" (1.38mm) Requires MS-75 Lens	SL-1X
<b>2.5X Supplementary Close-up Lens</b> 0.26" (0.51mm)	MS-2.5X
<b>Integrating Sphere</b>	IS-650
<b>CR-650 Cosine Receptor</b> For cosine corrected illuminance/radiance measurements	CR-650
<b>RS-3 Reflectance Standard, 2" x 2"</b> For illuminance/radiance or reflectance measurements	RS-3
<b>SRS-3 Reflectance Standard, 2" x 2"</b> Spectrally calibrated RS-3	SRS-3
<b>Filter Holder, 2" x 2" (Requires MS-75 lens)</b> For external 2" x 2" (50 mm x 50 mm) filters	PH-650
<b>ND-2 Neutral Density Filter</b> X-100 Absorbance, requires MS-75 lens	ND-650-2
<b>Flexible Probs., 2 feet</b> For luminance/radiance calibration only	FP-650
<b>Luminance Adaptor, 12.5", w/ Ambient Light Cup</b> For surface luminance and radiance of backlit sources or CRTs	LA-650
<b>Miscellaneous</b>	
<b>AC Adaptor and Rapid Charger</b> (Allows for 9V/255 VAC and 1 hour simultaneous recharge of up to two battery packs)	AC-650
<b>Molded Carrying Case with Foam Lining</b>	CC-650
<b>RS-232 Host CTRL/XFER Cable</b> (Control Transfer Interface Cable for Host PC Remote Control, Data Save, and ICM Card Program Restore)	IPC-650
<b>RS-232 Serial Printer Cable</b>	PC-650
<b>Spare Battery Pack</b> (Rapid Charge NiCad battery pack)	BP-650

**PR-650 Specifications**

<b>Spectral Range</b>	360-780 nm
<b>Spectral Bandwidth</b>	8 nm (fwhm)
<b>Spectral Accuracy</b>	± 2 nm
<b>Wavelength Resolution</b>	Less than 3.5 nm/pixel
<b>Luminance Accuracy</b>	± 4% of calculated luminance at 2850K @ 23° C. ± 1 digit (resolution is 0.01 units)
<b>Color Accuracy for Illuminant A</b>	± 0.015 x, ± 0.01 y (resolution is 0.001 units) (Typically ± .006 x, y for common CRT phosphors)
<b>Digital Resolution</b>	14 bit A/D (1 part in 16,000)
<b>AutoSync Range</b>	40 - 250 Hz
<b>Measuring and Viewing Field</b>	1" (measuring) and 7" (viewing) with MS-75 lens (at infinity)
<b>Battery</b>	Nickel cadmium rechargeable battery, (optional rapid charger <1 hour) (minimum 2 hours continuous operation)
<b>Operating Temperatures</b>	34° to 95°F (1° to 35°C)
<b>Operating Humidity</b>	Not greater than 90% non-condensing
<b>Non-Operating Temperatures</b>	-4° to 149°F (-20° to 65°C)
<b>Non-Operating Humidity</b>	Not greater than 90% non-condensing
<b>Size (approx.) including lens</b>	12" (305mm) L x 7" (178mm) W x 3" (76mm) H
<b>Weight (approx.)</b>	4 lbs. 12oz. (2.15 kg.), including lens and battery

**Field Coverage/Sensitivity Chart**



ACCESSORY	WORKING DISTANCE	SPOT SIZE	SENSITIVITY
MS-75 (1X to Infinity)	14 in. (35.5cm)	0.208" (5.25mm)	<1.0 to >5,000 fL
	1000ft (305m)	209" (5.32m)	<1.7 to >17,000 cd/m <sup>2</sup>
SL-0.5X (0.5X Mag)	3.6 in. (94.4mm)	0.059" (1.5mm)	<1.0 to >5,000 fL
	5.4 in. (137mm)	0.10 in. (2.54mm)	<1.7 to >17,000 cd/m <sup>2</sup>
SL-1X (1X Mag)	1.8 in. (46 mm)	0.035 in. (0.89mm)	<1.0 to 5,000 fL
	2.6 in. (66mm)	0.052 (1.32mm)	<1.7 to 17,000 cd/m <sup>2</sup>
MS-2.5X (2.5X Mag)	1.81 in. (46mm)	0.020 in. (0.51mm)	<3.0 to 15,000 fL <5 to 51,400 cd/m <sup>2</sup>
CR-650	N/A	N/A	<2.0 to >10,000 fL <11.5 to >107,700 lux
LA-650	Contact	0.52 in. (13.2mm)	<1.0 to >5,000 fL <1.7 to >17,000 cd/m <sup>2</sup>
FP-650	Contact	0.125 in. (3.17mm)	<2.5 to >12,000 fL <4.5 to >43,000 cd/m <sup>2</sup>

All specifications subject to change without notice.

Notes: For the ND-650-2 (used only with the MS-75, SL-1X or SL-0.5X), multiply the MS-75 sensitivity values by 100.  
 All values calculated measuring Illuminant A @ > 100:1 signal to noise.