




UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

TESIS DOCTORAL

Diseño e implementación de nuevas tecnologías basadas en visión artificial para la inspección no destructiva de la calidad de fruta en campo y mínimamente procesada



Autor

Sergio Cubero García

Directores

José Blasco Ivars
Nuria Aleixos Borrás

Fecha

Valencia, Mayo 2012



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



Diseño e implementación de nuevas
tecnologías basadas en visión artificial para la
inspección no destructiva de la calidad de fruta
en campo y mínimamente procesada

Tesis Doctoral

SERGIO CUBERO GARCÍA

Directores

JOSÉ BLASCO IVARS

NURIA ALEIXOS BORRÁS

Valencia, Mayo 2012

Remontándome en el tiempo, me gustaría recordar el momento en que me recomendaron acceder al Centro de Agroingeniería del IVIA para, en un principio, realizar una estancia en prácticas de unos tres meses. Fue un primer contacto con Enrique y Jose y, aunque nunca creí que sería así, ese fue el comienzo de los casi 10 años hasta ahora en los que he tenido la posibilidad de desarrollar mi labor profesional y que ha desembocado en el desarrollo de esta tesis doctoral como resultado de algunos de los muchos trabajos desarrollados en el laboratorio de Visión por Computador.

¡Gracias a ambos por la acogida que me ofrecisteis!

Y todos esos años sin duda han sido fundamentales en mi crecimiento no sólo profesional sino personal, gracias al enorme grupo de compañeros, muchos de ellos amigos, que he ido conociendo en todo este tiempo y que tanto me han ayudado en todo lo que he necesitado. Algunos ya se fueron, otros siguen desde hace mucho, pero todos han sido importantes para mi y para el desarrollo de mi estancia en el centro.

Imposible sería dar nombres pero todos ellos saben que aparecen en estos agradecimientos.

¡Gracias!

Y fundamentalmente agradezco a todos mis compañeros y excompañeros del laboratorio, esos que más cerca han estado siempre y que tanta ayuda me han prestado en todo lo que he necesitado. De ellos he aprendido y espero seguir haciéndolo. Entre todos se ha conseguido que el grupo sea un referente y seguro que seguirá siéndolo.

¡Gracias a todos!

Pero el gran responsable de que esta tesis haya salido adelante ha sido sin duda José, mi director y mentor y quien más ha confiado en mí durante todo este tiempo y que ha sabido transmitirme sus conocimientos e ilusión para que esta tesis fuera una realidad. Y por supuesto Nuria, mi directora que tanto ha aportado durante la realización de esta tesis. Enorme la dedicación de ambos y su importantísimo trabajo al frente del grupo de investigación.

¡Muchas gracias por vuestro gran esfuerzo!

Y por supuesto, a todos los míos que han aguantado más de cerca mis alegrías y tristezas, los éxitos y los momentos menos buenos. Mil gracias por vuestro apoyo que ha sido fundamental para alcanzar este objetivo.

¡Sabéis que os quiero!

Resumen

Esta tesis trata de avanzar en sistemas de visión por computador aplicados a la inspección automática de la calidad de frutas y verduras en dos entornos en los que hasta la fecha no se ha trabajado en profundidad como son la inspección en campo antes de la recepción de la fruta por la central hortofrutícola y la inspección automática de la calidad de fruta procesada. Se pretende así rellenar un hueco importante en la aplicación de la visión por computador como una herramienta al servicio del sector en la inspección de frutas y verduras. El desarrollo de técnicas de visión por computador en la inspección de la calidad de los productos agrícolas se debe a la necesidad de encontrar una alternativa a los métodos de inspección manual tradicionales para eliminar el contacto con el producto, aumentar la fiabilidad y objetividad, introducir flexibilidad a las líneas de confección e incrementar la productividad y competitividad de nuestras empresas. Esta tecnología está ampliamente extendida para la inspección de fruta en fresco en almacenes de confección pero, sin embargo, todavía no se ha aplicado en campo por las dificultades técnicas que conlleva este entorno, y tampoco en el sector de la fruta mínimamente procesada, debido a la fragilidad y dificultad de manipulación del producto, la complejidad de la inspección y el relativo menor valor económico respecto de la fruta en fresco.

En esta tesis se aborda, por una parte, la creación de un **sistema de visión por computador instalado en una plataforma de asistencia a la recolección de cítricos** sobre la que se analiza la fruta a la vez que se recolecta y se clasifica en diversas categorías en función de su color, tamaño o calidad (presencia de defectos externos). Los mayores problemas del trabajo en campo se refieren a una iluminación inestable, movimientos y vibraciones, energía eléctrica limitada o efectos de la intemperie. Para ello es necesario diseñar un sistema de visión por computador compacto, robusto, rápido y muy eficiente energéticamente y unos algoritmos específicamente adaptados al entorno de campo. Las soluciones propuestas incluyen, entre otras, un diseño compacto, iluminación LED en modo estroboscópico o una cámara inteligente que minimizan el consumo eléctrico. Respecto de los algoritmos, deben ser capaces de adaptarse a problemas como la presencia de pedúnculos o la ausencia de cálices. El principal objetivo de este sistema es realizar una primera tria de la fruta con el objetivo de desviarla directamente a su mercado más adecuado según su calidad, acortando tiempos de manipulación y evitando el gasto de maquinaria, agua y productos como ceras o fungicidas en fruta que será finalmente destinada a la industria o al destrío.

Por otra parte, dado que los hábitos de consumo están cambiando, existe una demanda de frutas y verduras de calidad sencillas de preparar y consumir, donde se encuentran los productos mínimamente procesados pero con características similares a los productos frescos enteros (sin defectos y con elevada calidad). Las industrias de procesado disponen de máquinas que automatizan la mayor parte de los procesos

previos, aunque apenas se ha avanzado en la automatización de la inspección y clasificación, que supone una gran parte del coste final. Esta tesis investiga en la **aplicación de visión por computador para la inspección de fruta procesada**, centrada en el desarrollo de sistemas adaptados a dos productos emergentes y de gran interés en la agricultura mediterránea como son los **gajos de satsuma y arilos de granada** listos para el consumo, que presentan una alta calidad nutricional y grandes beneficios para la salud. Ambos productos presentan cierta problemática común, aunque se deben abordar con distintas soluciones. Es necesario identificar defectos y la presencia de elementos extraños, así como clasificar el producto atendiendo a su calidad. Los mayores problemas corresponden a la complicada individualización y transporte de estos pequeños y pegajosos productos, sincronizando el avance con la expulsión de los mismos y la elección de los sistemas de iluminación y adquisición de imágenes. La tarea más complicada corresponde al desarrollo de algoritmos eficientes de análisis que permitan distinguir entre diferentes niveles de calidad, ajustados por el usuario final mediante cómodas interfaces, debido entre otros a la forma irregular de los gajos y a la similitud de los colores de los arilos. Además debe proporcionar todo tipo de estadísticas y datos referentes a la producción. La aplicación deberá sincronizar todo el sistema, desde el avance de los objetos pasando por la inspección hasta la clasificación final en distintas categorías comerciales.

Las principales contribuciones de la investigación realizada sobre la aplicación de visión por computador en estos entornos se resumen en el desarrollo de unos prototipos operativos que incorporan todos los desarrollos realizados y que se han probado en condiciones reales de funcionamiento. Adicionalmente se han obtenido diversas patentes de invención y se han publicado los resultados de la tesis en varias revistas científicas indexadas en el JCR, en revistas de divulgación profesional, en congresos y en capítulos de libros de carácter internacional.

Summary of the Thesis

This thesis deals with the advance in computer vision systems applied to the automatic inspection of the quality of fruits and vegetables in two scenarios, in which, up to these days, nobody has worked in depth, such as inspection of the product in the field before sending it to the packinghouses, and the automatic inspection of the quality of processed fruit. The general aim is to fill an important gap in the application of computer vision as a tool for industry in the inspection of fruits and vegetables. The development of computer vision techniques to inspect the quality of agricultural products, owing to the need to find an alternative to traditional manual inspection methods and to eliminate contact with the product, increase reliability and objectivity, besides of introducing flexibility to inspection lines and increasing the productivity and competitiveness of our companies. This technology is widely extended for the inspection of fresh fruit in packinghouses but, however, has not been applied in the orchards yet due to technical difficulties associated with this environment, and nor in the field of minimally processed fruit because of fragility, the sometimes stickiness of the product, the complexity of the inspection and the relatively lower economic value of this kind of product on fresh fruit.

This thesis deals with the creation of a **computer vision system coupled to an assistance platform for citrus harvesting**, on which fruit is analysed whilst it is harvested attending to its colour, size and quality (presence of external defects). Major problems working in field are related to unstable lighting, movement and vibration, limited power or effects of weather. Thus, it is necessary to design a computer vision system that is compact, robust, fast and energetically very efficient. Also a very optimised algorithms have to be designed and oriented to work in outdoor conditions. The proposed solutions include, among others, a compact design, illumination by LED in a stroboscopic mode, or the use of an intelligent camera to minimise the electrical consumption. Regarding to the algorithms, they have to be capable of adapting to problems like the presence of stems or absence of calyx. The main objective of this system is to perform a first selection of the fruit with the aim of diverting the fruit directly to the proper market attending to its quality, shortening handling times and thus avoiding the expenses of use of machinery, water and other products like waxes or fungicides that are applied to fruit that finally will be routed to industry or waste.

Additionally, given that consumer habits are changing, there is a more and more demand for minimally processed fruits and vegetables, with high quality, simple to prepare and eat, and with similar characteristics to fresh products. Industries of fruit processing have machines to automate most processes, but little progress has been made in the automation of the inspection and classification, which is a big part of the final cost. This thesis investigates the **application of computer vision for inspection of processed fruit**, focused on the development of systems adapted to two emerging products and great interest in Mediterranean agriculture such as **satsuma segments and pomegranate arils** ready for consumption, which have high nutritional quality

and great health benefits. Both products have some common problems that should be addressed with different solutions. It is necessary to identify defects and the presence of foreign elements in the production lines, and classify the product according to their quality. The major problems are related to the complicated identification and transport of these small and sticky products, identifying their location in the conveyor belts, synchronizing the advance of the conveyors with the expulsion devices, and also the selection of the image acquisition and lighting devices. The most difficult task is the development of efficient image analysis algorithms that can distinguish between different quality levels due, among others, to the irregular shape of the mandarin segments and the similarity of the colors of the pomegranate arils, the small size of the products and the presence of water in the conveyor belts. The application must synchronize the entire system, from the advancement of the objects passing through the inspection until the final classification in different commercial categories.

The main contributions of this research on the application of computer vision in these environments are summarised in the development of operational prototypes incorporating all the engineering and software solutions, which have been built and tested in real operating conditions. Furthermore, we have obtained several invention patents and published the results of this thesis in several scientific journals indexed in the JCR index, professional journals, conferences and international book chapters.

Resum

Esta tesi tracta d'avançar en sistemes de visió per computador aplicats a la inspecció automàtica de la qualitat de fruites i verdures en dos entorns en què fins a la data no s'ha treballat en profunditat com són la inspecció en camp abans de la recepció de la fruita per la central hortofructícola i la inspecció automàtica de la qualitat de fruita processada. Es pretén així omplir un buit important en l'aplicació de la visió per computador com una ferramenta al servici del sector en la inspecció de fruites i verdures. El desenrotllament de tècniques de visió per computador en la inspecció de la qualitat dels productes agrícoles es deu a la necessitat de trobar una alternativa als mètodes d'inspecció manual tradicionals per a eliminar el contacte amb el producte, augmentar la fiabilitat i objectivitat, introduir flexibilitat a les línies de confecció i incrementar la productivitat i competitivitat de les nostres empreses. Esta tecnologia està àmpliament estesa per a la inspecció de fruita en fresc en magatzems de confecció però, no obstant això, encara no s'ha aplicat en camp per les dificultats tècniques que comporta este entorn, i tampoc en el sector de la fruita mínimament processada, a causa de la fragilitat i dificultat de manipulació del producte, la complexitat de la inspecció i el relatiu menor valor econòmic respecte de la fruita en fresc.

En esta tesi s'aborda, d'una banda, la creació d'un **sistema de visió per computador instal·lat en una plataforma d'assistència a la recol·lecció de cítrics** sobre la qual s'analitza la fruita al mateix temps que es recol·lecta i es classifica en diverses categories en funció del seu color, grandària o qualitat (presència de defectes externs). Els majors problemes del treball en camp es referixen a una il·luminació inestable, moviments i vibracions, energia elèctrica limitada o efectes de la intempèrie. Per a això és necessari dissenyar un sistema de visió per computador compacte, robust, ràpid i molt eficient energèticament i uns algorismes específicament adaptats a l'entorn de camp. Les solucions proposades inclouen, entre altres, un disseny compacte, il·luminació LED en mode estroboscòpic o una càmera intel·ligent que minimitzen el consum elèctric. Respecte dels algorismes, han de ser capaços d'adaptar-se a problemes com la presència de peduncles o l'absència de calzes. El principal objectiu d'este sistema és realitzar una primera tria de la fruita amb l'objectiu de desviar-la directament al seu mercat més adequat segons la seua qualitat, acurtant temps de manipulació i evitant el gasto de maquinària, aigua i productes com a ceres o fungicides en fruita que serà finalment destinada a la indústria o al destrio.

D'altra banda, atés que els hàbits de consum estan canviant, hi ha una demanda de fruites i verdures de qualitat senzilles de preparar i consumir, on es troben els productes mínimament processats però amb característiques semblants als productes frescos sencers (sense defectes i amb elevada qualitat). Les indústries de processat disposen de màquines que automatitzen la major part dels processos previs, encara que a penes s'ha avançat en l'automatització de la inspecció i classificació, que suposa una gran part del cost final. Esta tesi investiga en l'**aplicació de visió per computador per a la inspecció de fruita processada**, centrada en el desenrotllament de sistemes

adaptats a dos productes emergents i de gran interès en l'agricultura mediterrània com són els **gallons de satsuma i arils de granada** llestos per al consum, que presenten una alta qualitat nutricional i grans beneficis per a la salut. Ambdós productes presenten certa problemàtica comuna, encara que s'han d'abordar amb distintes solucions. És necessari identificar defectes i la presència d'elements estranys, així com classificar el producte atenent a la seua qualitat. Els majors problemes corresponen a la complicada individualització i transport d'estos xicotets i apegalosos productes, sincronitzant l'avanç amb l'expulsió dels mateixos i l'elecció dels sistemes d'il·luminació i adquisició d'imatges. La tasca més complicada correspon al desenrotllament d'algoritmes eficients d'anàlisi que permeten distingir entre diferents nivells de qualitat, ajustats per l'usuari final per mitjà de còmodes interfícies, degut entre altres a la forma irregular dels gallons i a la similitud dels colors dels arils. A més ha de proporcionar tot tipus d'estadístiques i dades referents a la producció. L'aplicació haurà de sincronitzar tot el sistema, des de l'avanç dels objectes passant per la inspecció fins a la classificació final en distintes categories comercials.

Les principals contribucions de la investigació realitzada sobre l'aplicació de visió per computador en estos entorns es resumixen en el desenrotllament d'uns prototips operatius que incorporen tots els desenrotllaments realitzats i que s'han provat en condicions reals de funcionament. Addicionalment s'han obtingut diverses patents d'invenió i s'han publicat els resultats de la tesi en diverses revistes científiques indexades en el JCR, en revistes de divulgació professional, en congressos i en capítols de llibres de caràcter internacional.

ÍNDICE

LISTADO DE FIGURAS	7
LISTADO DE TABLAS	11
LISTADO DE ACRÓNIMOS Y ABREVIATURAS	13
LISTADO DE UNIDADES	17
1. VISIÓN POR COMPUTADOR EN AGRICULTURA	19
1.1 INTRODUCCIÓN	20
1.2 LOS FUNDAMENTOS DE LOS SISTEMAS DE VISIÓN POR COMPUTADOR.....	21
1.2.1 Iluminación.....	22
1.2.2 Adquisición de imágenes.....	24
1.3 APLICACIONES DE VISIÓN POR COMPUTADOR EN LA INSPECCIÓN DE CARACTERÍSTICAS EXTERNAS ..	27
1.3.1 Uso de la información de color.....	27
1.3.2 Estimación de tamaño y volumen	29
1.3.3 Estimación de la forma.....	30
1.3.4 Textura	31
1.3.5 Detección de defectos externos.....	32
1.4 SISTEMAS DE INSPECCIÓN EN CAMPO	37
1.5 SISTEMAS DE INSPECCIÓN AUTOMÁTICA EN TIEMPO REAL.....	39
1.6 DISCUSIÓN	41
2. MOTIVACIÓN Y OBJETIVOS	43
2.1 MARCO DE LA TESIS.....	46
2.2 ESTRUCTURA DE LA MEMORIA	47

3.	NUEVAS TECNOLOGÍAS PARA LA SELECCIÓN AUTOMÁTICA DE FRUTA EN CAMPO	49
3.1	INTRODUCCIÓN	50
3.2	OBJETIVOS	51
3.3	CREACIÓN DEL SISTEMA DE VISIÓN	52
3.3.1	<i>Diseño de la campana de inspección.....</i>	<i>52</i>
3.3.1.1	Diseño y configuración de la estructura del sistema de visión	53
3.3.2	<i>Diseño del sistema de adquisición de imágenes</i>	<i>58</i>
3.3.2.1	Análisis de la escena	58
3.3.2.2	Cámaras y ópticas empleadas	62
3.3.2.3	Ajustes de las cámaras	64
3.3.2.4	Integración de las cámaras en el sistema	65
3.3.3	<i>Diseño del sistema de iluminación</i>	<i>67</i>
3.3.3.1	Tipos y técnicas de iluminación	67
3.3.3.2	Elección del sistema de iluminación	69
3.3.3.3	Implementación del sistema de iluminación seleccionado	71
3.4	ANÁLISIS DE LA FRUTA	73
3.4.1	<i>Algoritmos de entrenamiento</i>	<i>73</i>
3.4.2	<i>Proceso de inspección en línea usando el Sistema PC.....</i>	<i>76</i>
3.4.2.1	Adquisición de la imagen.....	76
3.4.2.2	Segmentación.....	79
3.4.2.3	Filtrado	80
3.4.2.4	Análisis del contorno	81
3.4.2.5	Detección de los defectos	82
3.4.2.6	Estimación del calibre.....	83

3.4.2.7	Estimación del índice de color	83
3.4.2.8	Envío de resultados al control de la máquina.....	85
3.4.3	<i>Proceso de inspección en línea usando el Sistema Inteligente.....</i>	<i>85</i>
3.4.3.1	Adquisición de la imagen.....	86
3.4.3.2	Segmentación.....	86
3.4.3.3	Estimación del calibre.....	87
3.4.3.4	Estimación del índice de color	88
3.4.3.5	Envío de resultados	88
3.4.4	<i>Ensayos realizados usando el Sistema PC.....</i>	<i>88</i>
3.4.4.1	Estimación del calibre y peso	89
3.4.4.2	Detección de defectos.....	89
3.4.4.3	Estimación del color	90
3.4.5	<i>Ensayos empleando el Sistema Inteligente</i>	<i>90</i>
3.4.5.1	Estimación del calibre.....	91
3.4.5.2	Estimación del color	91
3.5	RESULTADOS	91
3.5.1	<i>Ensayos realizados usando el Sistema PC.....</i>	<i>91</i>
3.5.1.1	Estimación del calibre.....	91
3.5.1.2	Estimación del peso.....	93
3.5.1.3	Estimación del color	94
3.5.1.4	Detección de defectos.....	96
3.5.1.5	Estimación del tiempo de procesamiento	97
3.5.2	<i>Ensayos empleando el Sistema Inteligente</i>	<i>97</i>
3.5.2.1	Estimación del calibre.....	97

3.5.2.2	Estimación del peso.....	99
3.5.2.3	Estimación del color	100
3.5.2.4	Estimación del tiempo de procesamiento.....	103
3.6	DISCUSIÓN.....	104
4.	NUEVAS TECNOLOGÍAS PARA LA SELECCIÓN AUTOMÁTICA DE ARILOS DE GRANADA (<i>PUNICA GRANATUM L</i>) BASADAS EN VISIÓN POR COMPUTADOR.....	107
4.1	INTRODUCCIÓN	108
4.2	OBJETIVOS	110
4.3	MATERIALES Y MÉTODOS	110
4.3.1	<i>Unidad de alimentación: separación y transporte de los objetos</i>	<i>111</i>
4.3.2	<i>Unidad de inspección y sistema de visión por computador.....</i>	<i>112</i>
4.3.2.1	Adquisición y análisis de imágenes en línea	115
4.3.2.2	Selección de la forma de representar el color de los objetos.....	117
4.3.3	<i>El sistema de clasificación</i>	<i>119</i>
4.3.4	<i>Pruebas del prototipo en condiciones comerciales. Evaluación global de su rendimiento.....</i>	<i>123</i>
4.4	RESULTADOS	124
4.4.1	<i>Unidad de alimentación y transporte.....</i>	<i>124</i>
4.4.2	<i>Unidad de inspección y sistema de visión por computador.....</i>	<i>127</i>
4.4.2.1	Optimización del análisis mediante umbrales. Comparación con LDA.....	127
4.4.2.2	Velocidad de procesamiento	130
4.4.3	<i>Unidad de clasificación.....</i>	<i>131</i>
4.4.4	<i>Ensayos intensivos bajo condiciones comerciales</i>	<i>131</i>

4.5	DISCUSIÓN	134
5.	NUEVAS TECNOLOGÍAS PARA LA SELECCIÓN AUTOMÁTICA DE GAJOS DE SATSUMA (CITRUS UNSHIU) BASADAS EN VISIÓN POR COMPUTADOR.....	135
5.1	INTRODUCCIÓN	136
5.2	OBJETIVOS	138
5.3	MATERIALES Y MÉTODOS.....	139
5.3.1	<i>Unidad de alimentación: separación y transporte de los objetos</i>	<i>140</i>
5.3.2	<i>Unidad de inspección y sistema de visión por computador.....</i>	<i>140</i>
5.3.2.1	Adquisición de imágenes y análisis en línea	142
5.3.2.2	Discriminación de los objetos de interés.....	142
5.3.2.3	Análisis de las imágenes. Parámetros morfológicos estudiados	145
5.3.2.4	Análisis estadístico y evaluación de los datos	147
5.3.3	<i>El sistema de clasificación</i>	<i>148</i>
5.3.4	<i>Prueba del prototipo. Evaluación global de su rendimiento</i>	<i>150</i>
5.4	RESULTADOS	152
5.4.1	<i>Unidad de inspección y sistema de visión por computador.....</i>	<i>152</i>
5.4.2	<i>Velocidad de procesamiento</i>	<i>153</i>
5.4.3	<i>Pruebas intensivas en condiciones comerciales</i>	<i>154</i>
5.5	DISCUSIÓN	154
6.	CONTRIBUCIONES DE LA TESIS	155
6.1	REVISTAS RECOGIDAS EN EL JCR	156
6.2	ARTÍCULOS EN OTRAS REVISTAS CIENTÍFICAS INTERNACIONALES.....	156
6.3	LIBROS Y CAPÍTULOS DE LIBROS.....	156

6.4	PUBLICACIONES DE DIVULGACIÓN	156
6.5	CONTRIBUCIONES EN CONGRESOS.....	157
6.6	PATENTES OBTENIDAS	158
7.	CONCLUSIONES.....	159
7.1	SISTEMA DE INSPECCIÓN DE FRUTA EN CAMPO.....	159
7.2	SISTEMA DE INSPECCIÓN DE FRUTA PROCESADA	160
8.	REFERENCIAS BIBLIOGRÁFICAS	163
ANEXO I.	DESCRIPCIÓN DE LA PLATAFORMA MÓVIL DE RECOLECCIÓN	175
ANEXO II.	TÉCNICAS DE ILUMINACIÓN	179
ANEXO III.	SOFTWARE DE ENTRENAMIENTO	183
ANEXO IV.	SOFTWARE DE INSPECCIÓN DE CÍTRICOS.....	189
ANEXO V.	FÓRMULAS DE CONVERSIÓN DE COLOR	193
ANEXO VI.	SOFTWARE DE INSPECCIÓN DE ARILOS DE GRANADA.....	197
ANEXO VII.	SOFTWARE DE INSPECCIÓN DE GAJOS DE SATSUMA.....	199

LISTADO DE FIGURAS

Figura 1.1. Ejemplos de iluminación difusa y direccional orientada a 45° de la muestra	23
Figura 1.2. Izquierda: Imagen de naranjas que muestran diferentes defectos, colores y texturas en la piel. Derecha: la misma imagen segmentada que muestra los defectos encontrados	32
Figura 1.3. Proceso de crecimiento de regiones para detectar defectos en cítricos. a) Imagen de color original de una naranja con manchas causadas por la fitotoxicidad, b) semillas de las regiones de color homogéneo, c) y d) pasos iterativos de crecimiento, e) etapa final de crecimiento, y f) imagen final después de la fusión de las regiones basada en la información de color	33
Figura 1.4. Imágenes de cuatro cítricos con diferentes defectos externos adquiridos con una cámara monocromática B/W (arriba) y las mismas frutas adquiridas en determinadas longitudes de onda (abajo). De izquierda a derecha: 450 nm, 720 nm, 520 nm y 480 nm.....	34
Figura 3.1. Máquina con la cámara orientada verticalmente.....	53
Figura 3.2. Ley de reflexión para espejos planos.....	53
Figura 3.3. Espejo a 45°	54
Figura 3.4. Diferentes configuraciones del espejo situado entre la escena y la cámara	55
Figura 3.5. Diseños iniciales de los soportes del espejo (izquierda) y la cámara (derecha)	55
Figura 3.6. Diseño inicial de la estructura conjunta de la cámara y el espejo	56
Figura 3.7. Diseño definitivo de la estructura de la cámara y el espejo	56
Figura 3.8. Estructura espejo y cámara ensamblada	57
Figura 3.9. a) Diseño completo de la zona de inspección; b) Interior de la zona de inspección.....	58
Figura 3.10. Zona de inspección	59
Figura 3.11. Orientación transversal vs. longitudinal de la cámara.....	60
Figura 3.12. Esquema del <i>Sistema PC</i> , utilizando ordenador, cámara estándar e inversor de potencia.....	66
Figura 3.13. Esquema del <i>Sistema Inteligente</i> , utilizando una cámara con capacidad de procesamiento propio	66
Figura 3.14. Tiras de LED	71
Figura 3.15. Control de la iluminación estroboscópica	72
Figura 3.16. Tiras de LED con los filtros polarizadores integrados	72
Figura 3.17. Pantalla de entrenamiento	74
Figura 3.18. Diagrama de flujo del algoritmo de procesamiento en línea con la configuración de cámara y ordenador	75
Figura 3.19. Modo síncrono secuencial de adquisición de imágenes.....	77
Figura 3.20. Modo asíncrono de adquisición de imágenes con <i>double buffering</i>	78

Figura 3.21. Regiones de interés (ROI) de la imagen (enmarcadas en rojo).....	79
Figura 3.22. Aspecto visual del ICC de una naranja	84
Figura 3.23. Diagrama de flujo del algoritmo del procesamiento en línea con la configuración de cámara con capacidad de procesamiento.....	87
Figura 3.24. Representación de los modelos polinomial y lineal (Calibre-Diámetro máquina <i>Sistema PC</i>)	92
Figura 3.25. Representación de los modelos polinomial y lineal (Peso – Diámetro máquina <i>Sistema PC</i>).....	94
Figura 3.26. Representación de los modelos polinomial y lineal (ICC colorímetro-máquina <i>Sistema PC</i>).....	96
Figura 3.27. Representación de los modelos polinomial y lineal (Área real-máquina <i>Sistema Inteligente</i>)	99
Figura 3.28. Representación de los modelos polinomial y lineal (Peso-Área máquina <i>Sistema Inteligente</i>)	101
Figura 3.29. Representación de los modelos polinomial y lineal (ICC colorímetro-máquina <i>Sistema Inteligente</i>)	102
Figura 4.1. Esquema del prototipo	111
Figura 4.2. Sistema de recepción e individualización	112
Figura 4.3. Zona de inspección	114
Figura 4.4. Histograma de la imagen en la banda roja	116
Figura 4.5. Distintos tipos de arilos y pieles	117
Figura 4.6. Zona de separación y clasificación de arilos	120
Figura 4.7. Esquema del mecanismo de sincronización	123
Figura 4.8. Prototipo montando en la empresa colaboradora	124
Figura 4.9. Ensayos para elegir el color de la cinta transportadora	125
Figura 4.10. Separación de los colores de las cintas transportadoras probadas y del producto en el cubo RGB.....	127
Figura 4.11. Evolución del color de los granos en granadas de la variedad ‘Mollar de Elche’ a lo largo de una campaña.....	128
Figura 4.12. Granos escogidos al azar de las diferentes salidas del prototipo	131
Figura 4.13. Pantallas de ajuste de parámetros y visualización de la inspección.....	132
Figura 4.14. El prototipo durante los ensayos intensivos.....	133
Figura 5.1. Gajos pertenecientes a las clases entero (izquierda), roto (centro) y mitad (derecha).....	139
Figura 5.2. Cinta transportadora con la iluminación superior e inferior	141
Figura 5.3. Esquema de los principales elementos del prototipo	142

Figura 5.4. Gajos con iluminación direccional y posterior	143
Figura 5.5. Imagen de los gajos sobre las cintas transportadoras (izquierda) e imagen segmentada que muestra en gris claro las semillas, trozos de piel y gajos dobles (derecha).....	144
Figura 5.6. Diagrama de flujo del proceso de análisis de imágenes	146
Figura 5.7. Representación de la simetría de los gajos mediante la proyección de la parte derecha del gajo sobre la parte izquierda. La imagen de la izquierda muestra la simetría de un gajo entero. La imagen de la derecha muestra la simetría de un gajo roto. En gris se resalta la zona de solapamiento	147
Figura 5.8. Firma polar del contorno de los gajos	147
Figura 5.9. Zona de clasificación de los gajos de satsuma	150
Figura 5.10. Imagen del prototipo para la adquisición y procesamiento de gajos de satsuma.....	151
Figura I.1. Plataforma móvil de recolección con el sistema de visión instalado en la parte superior ..	175
Figura I.2. Dimensiones de la máquina.....	176
Figura I.3. Cuadro de control	178
Figura III.1. Pantalla principal del programa.....	183
Figura III.2. Ejemplo de entrenamiento.....	184
Figura III.3. Vista previa de la clase 4 (mancha).....	185
Figura III.4. Muestra de los contornos encontrados.....	187
Figura III.5. Muestra de los contornos encontrados sobre la imagen segmentada.....	187
Figura III.6. Muestra de los contornos encontrados sobre la imagen original	187
Figura IV.1. Pantalla principal de inspección de cítricos.....	189
Figura VI.1. Selección de variedad de granada.....	197
Figura VI.2. Configuración variedades de granada	197
Figura VI.3. Estadísticas	198
Figura VII.1. Pantalla principal de inspección de gajos de satsuma.....	199
Figura VII.2. Parámetros de selección	200
Figura VII.3. Estadísticas	200

LISTADO DE TABLAS

Tabla 1.1. Sistemas publicados de inspección de frutas y verduras basada en visión por computador	35
Tabla 1.2. Sistemas de inspección de frutas y verduras en tiempo real mediante visión por computador	40
Tabla 3.1. Tiempo máximo de procesado para cada imagen en función del número de imágenes adquiridas de cada fruta y el número de frutas por segundo a inspeccionar.	61
Tabla 3.2. Comparativa de ópticas	64
Tabla 3.3. Detalle de mensaje de comunicación entre el autómata y el módulo de visión	85
Tabla 3.4. Análisis de regresión polinomial (Calibre-Diámetro máquina <i>Sistema PC</i>)	92
Tabla 3.5. Análisis de regresión lineal (Calibre-Diámetro máquina <i>Sistema PC</i>)	92
Tabla 3.6. Matriz de confusión de la clasificación automática de la fruta según la característica de tamaño (<i>Sistema PC</i>)	93
Tabla 3.7. Análisis de regresión polinomial (Peso-Diámetro máquina <i>Sistema PC</i>)	93
Tabla 3.8. Análisis de regresión lineal (Peso-Diámetro máquina <i>Sistema PC</i>)	94
Tabla 3.9. Análisis de regresión polinomial (ICC colorímetro-máquina <i>Sistema PC</i>)	95
Tabla 3.10. Análisis de regresión lineal (ICC colorímetro-máquina <i>Sistema PC</i>)	95
Tabla 3.11. Matriz de confusión de la clasificación automática de la fruta según la característica del color (<i>Sistema PC</i>)	96
Tabla 3.12. Tiempos máximos obtenidos para cada operación de procesamiento con el <i>Sistema PC</i>	97
Tabla 3.13. Análisis de regresión polinomial (Área real-máquina <i>Sistema Inteligente</i>)	98
Tabla 3.14. Análisis de regresión lineal (Calibre real-máquina <i>Sistema Inteligente</i>)	98
Tabla 3.15. Matriz de confusión de la clasificación automática de la fruta según la característica de tamaño (<i>Sistema Inteligente</i>)	99
Tabla 3.16. Análisis de regresión polinomial (Peso-Área máquina <i>Sistema Inteligente</i>)	100
Tabla 3.17. Análisis de regresión lineal (Peso-Área máquina <i>Sistema Inteligente</i>)	100
Tabla 3.18. Análisis de regresión polinomial (ICC colorímetro-máquina <i>Sistema Inteligente</i>)	101
Tabla 3.19. Análisis de regresión lineal (ICC colorímetro-máquina <i>Sistema Inteligente</i>)	102
Tabla 3.20. Matriz de confusión obtenida para la clasificación de fruta por la plataforma móvil	103
Tabla 3.21. Estimación de tiempos empleando la configuración de <i>Sistema Inteligente</i>	103
Tabla 3.22. Estimación de tiempos empleando la cámara inteligente y los algoritmos inicialmente implementados para una configuración de cámara y ordenador personal.	103
Tabla 4.1. Estadísticas básicas de las diferentes clases para la ratio R/G	118

Tabla 4.2. Colores promedio en los espacios de color RGB y CIELAB, y distancia entre el color del fondo y los diferentes tipos de objetos sobre las cintas transportadoras.....	126
Tabla 4.3. Porcentajes de éxito en la clasificación sobre el conjunto de validación empleando umbrales en las coordenadas de color (valores en tanto por ciento)	128
Tabla 4.4. Matriz de confusión de la clasificación realizada al comienzo de la temporada utilizando valores de umbral basados en la ratio R/G. Resultados referidos al conjunto de validación (valores en tanto por ciento)	129
Tabla 4.5. Matriz de confusión de la clasificación realizada al final de la temporada utilizando valores de umbral basados en la ratio R/G. Resultados referidos al conjunto de validación	129
Tabla 4.6. Matriz de confusión obtenida al inicio de la campaña usando LDA en el conjunto de validación (valores en tanto por ciento).....	130
Tabla 4.7. Matriz de confusión obtenida al final de la campaña usando LDA en el conjunto de validación (valores en tanto por ciento).....	130
Tabla 4.8. Coeficientes de la función de clasificación obtenida utilizando LDA	130
Tabla 5.1. Estadísticas básicas sobre el color del producto a inspeccionar	143
Tabla 5.2. Matriz de confusión de la clasificación obtenida por el sistema automático (valores en tanto por ciento).....	152
Tabla 5.3. Valores medios del éxito en la clasificación obtenido utilizando cada variable (transformada rápida de Fourier, compacidad, perímetro, área, factor de circularidad, simetría, elongación).....	153

LISTADO DE ACRÓNIMOS Y ABREVIATURAS

3D	3 dimensiones
A	Área
AC	Alternate Current (corriente alterna)
ANN	Artificial Neural Network (redes neuronales artificiales)
ANOVA	Análisis de varianza
AOTF	Acousto-Optic Tunable Filter (filtro sintonizable acústico-óptico)
BMP	Bitmap Image File
CA	Correlation analysis (análisis de correlaciones)
CAD	Computer Aided Desing (diseño asistido por ordenador)
CAE	Computer Aided Manufacturing (fabricación asistida por ordenador)
CAM	Computer Aided Engineering (ingeniería asistida por ordenador)
CAN	Controller Area Network
CART	Classification And Regression Trees (árboles de clasificación y regresión)
CCD	Coupled Charge Device
CCIR	International Radio Consultative Committee (Comité Consultivo Internacional de Radiocomunicaciones)
CDTI	Centro para el Desarrollo Tecnológico Industrial
CIE	International Commission on Illumination (Comisión Internacional de Iluminación)
CM	Compacidad
CMOS	Complementary metal oxide semiconductor
CS	Factor de forma circular
cv	Cultivar
DC	Direct Current (corriente continua)
DSP	Digital Signal Processor (procesador de señales digitales)
EL	Elongación
FEDER	Fondo Europeo De Desarrollo Regional
FFT	Fast Fourier Transform (transformada rápida de Fourier)
GALDA	Algoritmo genético basado en LDA
GPS	Global Positioning System (sistema de posicionamiento global)
HSI	Hue, Saturation, Intensity color space (espacio de color de tono, saturación, intensidad)
HSV	Hue, Saturation, Value color space (espacio de color tono, saturación, valor-brillo)
ICC	Índice de Color de los Cítricos
INIA	Instituto Nacional de Investigaciones Agrarias
IP	Internet Protocol (protocolo de Internet)
IVIA	Instituto Valenciano de Investigaciones Agrarias
JPEG	Joint Photographic Experts Group

k-NN	k-vecinos más cercanos
LCTF	Liquid Crystal Tunable Filter (filtro sintonizable de cristal líquido)
L* a* b*	CIE 1976 (L*,a*,b*) color space (espacio de color CIE L*a*b*)
Lab	Hunter 1948 (L,a,b) color space (espacio de color Hunter Lab)
LDA	Linear Discriminant Analysis (análisis discriminante lineal)
LED	Light Emitting Diode (diodo emisor de luz)
LUT	Look Up Table (tabla de consulta)
Luv	CIE 1976 (L*, u*, v*) color space (espacio de color CIELuv)
Mbps	Megabits por segundo
MI	Mutual Information (información mutua)
MIA	Multivariate Image Analysis (análisis de imágenes multivariante)
NIR	Near Infrared (infrarrojo cercano)
NTSC	National Television System Committee (Comisión Nacional de Sistema de Televisión)
P	Perímetro
PAL	Phase Alternating Line (línea de fase alternada)
PC	Personal Computer (ordenador personal)
PCA	Principal Component Analysis (análisis de componentes principales)
PCI	Peripheral Component Interconnect (interconexión de componentes periféricos)
PLC	Programmable Logic Controller (controlador lógico programable)
PLS	Partial Least Square (análisis parcial de mínimos cuadrados)
PNAS	Proceedings of the National Academy of Sciences
R ²	Coefficiente de determinación
RAM	Random Access Memory (memoria de acceso aleatorio)
RGB	Red, Green, Blue (rojo, verde, azul)
RM	Resonancia Magnética
ROI	Region Of Interest (región de interés)
SECAM	Séquentiel Couleur à Mémoire (color secuencial con memoria)
SM	Simetría
SMD	Surface Mount Devices (dispositivos de montaje superficial)
sRGB	Espacio de color estándar RGB
SW	Análisis multivariante paso a paso
TCP	Transmission Control Protocol (protocolo de control de transmisión)
TIFF	Tagged Image File Format (formato de fichero de imágenes etiquetado)
UE	Unión Europea
UPV	Universidad Politécnica de Valencia
USA	United States of America
USB	Universal Serial Bus (bus universal en serie)
UV	Ultraviolet (Ultravioleta)

UVA	Ultraviolet A
UVFL	Ultraviolet Fluorescence (fluorescencia visible inducida por el ultravioleta)
XYZ	XYZ color space (espacio de color XYZ)

LISTADO DE UNIDADES

A	Amperio
cm	Centímetro
g	Gramo
GB	Gigabyte
GHz	Gigahercio
h	Hora
Hz	Hercio
K	Kelvin
kg	Kilogramo
kHz	Kilohercio
lm	Lumen
m	Metro
MB	Megabyte
Mbps	Megabit por segundo
mm	Milímetro
ms	Milisegundo
nm	Nanómetro
s	Segundo
V	Voltio
Vca	Voltio de corriente alterna
Vcc	Voltio de corriente continua
W	Vatio
µs	Microsegundo

1. Visión por computador en agricultura

Resumen

Este capítulo repasa la bibliografía más reciente sobre visión por computador aplicada a la inspección de frutas y verduras, destacando su importancia y analizando las técnicas más empleadas para estimar diversas propiedades relacionadas con la calidad de forma automática. Los sistemas de visión por computador son potentes herramientas para la inspección automática de frutas y verduras. Los objetivos de las aplicaciones típicas de tales sistemas incluyen la clasificación, estimación de la calidad según características internas o externas, el seguimiento de los procesos de la fruta durante el almacenamiento o la evaluación de los tratamientos experimentales. Las capacidades de un sistema de visión por computador van más allá de la limitada capacidad humana, ya que permiten evaluar a largo plazo los procesos de forma objetiva o apreciar los acontecimientos que tienen lugar fuera del espectro electromagnético visible. El uso del espectro ultravioleta o infrarrojo cercano hace posible explorar los defectos o características que el ojo humano es incapaz de observar. Los sistemas hiperspectrales proporcionan información sobre ciertos componentes o daños que pueden ser percibidos sólo en determinadas longitudes de onda, y pueden ser utilizados como una herramienta para desarrollar nuevos sistemas de visión por computador adaptados a objetivos particulares. Además, los sistemas de clasificación en línea permiten inspeccionar grandes cantidades de frutas o verduras de forma individual y proporcionan estadísticas sobre el lote inspeccionado. En general, los sistemas artificiales no sólo pueden sustituir a la inspección manual, sino que también permiten mejorar sus capacidades. El desarrollo de sistemas de este tipo adaptados a nuestra agricultura es fundamental para que nuestras empresas productoras adquieran ventajas competitivas esenciales frente a terceros países con menores costes de producción.

Palabras clave: visión por computador, análisis de imagen, inspección automática, control de calidad, tiempo real, imagen hiperspectral

1.1 **Introducción**

La aplicación de la visión por computador en la agricultura ha aumentado considerablemente en los últimos años, como por ejemplo cartografía terrestre y aérea de los recursos naturales, monitorización de cultivos, agricultura de precisión, robótica, guiado automático, inspección no destructiva de las propiedades del producto, control de calidad y clasificación en líneas de procesamiento y, en general, en la automatización de procesos. Esta amplia gama de aplicaciones se debe a que los sistemas de visión por computador proporcionan importantes cantidades de información acerca de la naturaleza y atributos de la escena analizada. Por otra parte, esta tecnología permite la posibilidad de estudiar escenas en regiones del espectro electromagnético en las que el ojo humano no es sensible, como es el caso de la radiación ultravioleta (UV) o regiones del infrarrojo (Zude, 2008).

Un campo donde el uso de esta tecnología se ha extendido rápidamente es el de la inspección de productos agroalimentarios (Sun, 2007, Lorente et al., 2012) y en particular en la inspección automática de frutas y verduras. La calidad de una pieza de fruta o verdura, sea fresca o procesada, se define por una serie de características físico-químicas que la hacen más o menos atractiva para el consumidor, tales como su grado de madurez, tamaño, peso, forma, color, la presencia de manchas y enfermedades, la presencia o ausencia de pedúnculo, la presencia de semillas, su contenido en azúcar, etcétera. Estas características cubren todos los factores que influyen en la apariencia del producto, y pueden llegar a abarcar cualidades nutricionales y organolépticas o relacionadas con sus propiedades de conservación. La mayoría de estos factores se han evaluado tradicionalmente mediante inspección visual realizada por personal cualificado, pero hoy en día se ha sustituido en su mayor parte por sistemas comerciales de inspección automática basados en visión por computador y análisis de imagen (Du y Sun, 2006).

En los procesos de clasificación manual existe un riesgo relativamente elevado de error humano, ya que las decisiones tomadas por los operarios se ven afectadas por factores psicológicos tales como la fatiga o los hábitos adquiridos. Un estudio llevado a cabo con diferentes variedades de manzanas, donde personal cualificado comparó varios parámetros de forma, tamaño y color, mostró la limitada capacidad humana para reproducir la estimación de la calidad, lo que los autores definen como “inconsistencia” (Paulus et al., 1997). Por otra parte, las exigencias de calidad son cada vez mayores debido a nuevas normativas oficiales y a la propia petición de los mercados, y es conocido que conforme el número de parámetros considerados en un proceso de toma de decisiones aumenta, lo hace también el error de clasificación.

La visión por computador está simplificando estos tediosos y subjetivos procesos de control de calidad en la industria. Sin embargo, la inspección automatizada de la producción agrícola presenta algunas peculiaridades y problemas que no se encuentran en otros sectores de la producción industrial debido a la naturaleza biológica de los productos analizados. Mientras que los productos manufacturados a menudo presentan

colores, formas, tamaños y otras características externas similares, las frutas y verduras presentan características muy diferentes unas de otras. Una fruta puede tener un color, tamaño y forma diferente de otra, incluso si se ha recolectado el mismo día y del mismo árbol. Los productos agroalimentarios evolucionan de modo natural su color o textura después de haber sido recolectados, y estas características dependen de su madurez y de las condiciones en que se almacenan (humedad y temperatura ambiente, infecciones fúngicas, presencia de sustancias volátiles, duración del almacenamiento, etcétera). Además, el color de una zona particular de la piel de una fruta sana puede coincidir con el color de una mancha en la superficie de otra fruta de la misma variedad. Por otra parte, en una línea de control de calidad es esencial que se detecte la presencia de pedúnculos, hojas, tierra o cualquier material extraño y no se confunda con otros defectos de la piel. Todo esto complica enormemente el desarrollo de algoritmos capaces de extraer decisiones sobre la calidad a partir de imágenes, más teniendo en cuenta que los mercados demandan un procesamiento de imágenes muy rápido para alcanzar producciones comerciales, por lo que es necesario encontrar un compromiso entre velocidad y precisión.

Este capítulo proporciona una revisión exhaustiva de los recientes avances en visión por computador aplicados a la inspección de frutas y verduras. Esto incluye el análisis de las diferentes tecnologías utilizadas, junto con aplicaciones y desarrollos destinados a la inspección de la calidad externa de estos productos. Se describen trabajos basados no sólo en el análisis de imágenes adquiridas en el visible, sino también en imágenes obtenidas mediante fluorescencia inducida en el ultravioleta (UVFL) o adquiridas en el infrarrojo cercano (NIR). Se ha incluido la revisión de otras técnicas avanzadas, como el análisis de imágenes hiperespectrales, producidas por resonancia magnética (RM) o rayos X, ya que en este momento representan las tecnologías más avanzadas en este campo y permiten a los investigadores ampliar el alcance de la inspección de frutas y verduras a sus características de calidad interna.

El objetivo del capítulo es conocer, estudiar y determinar qué técnicas son más adecuadas o se adaptan mejor a las exigencias de los desarrollos de esta tesis, como son el análisis automático de fruta procesada o la inspección de fruta en campo. Esta revisión aborda primero la descripción de los actuales sistemas de iluminación para seguir con los métodos de adquisición de imágenes. A continuación se describen las aplicaciones generales relacionadas con el análisis de las características de calidad externa de las frutas y verduras tales como color, tamaño, forma, textura y la detección de defectos externos, para dar paso a la inspección de la calidad interna. Posteriormente se ofrece una visión general de la automatización y la inspección en línea. Y finalmente se presentan las conclusiones de esta revisión y las tendencias futuras esperadas en visión por computador aplicada al análisis de frutas y verduras.

1.2 Los fundamentos de los sistemas de visión por computador

Debido a la enorme diversidad de formas, texturas y colores, el éxito de un sistema de control en línea de productos hortofrutícolas depende en gran medida de la calidad de

las imágenes que se adquieren, y dos parámetros directamente relacionados con esta calidad son la cámara y la iluminación empleadas. Mientras que la cámara es un dispositivo comercial del cual únicamente es necesario escoger el modelo que mejor se adapta a las necesidades particulares de cada caso, el sistema de iluminación se puede crear y configurar de forma específica. Por ello, es el investigador quien debe decidir cómo diseñar y posteriormente construir el sistema de iluminación, dependiendo de la aplicación particular y la geometría del objeto que se va a inspeccionar.

1.2.1 Iluminación

Un buen sistema de iluminación debe proporcionar una radiación uniforme en toda la escena, evitando la presencia de brillos o sombras, y debe ser en lo posible espectralmente uniforme y estable en el tiempo. Si la escena no está iluminada adecuadamente, además de aumentar la incertidumbre y el error en la clasificación, será necesario realizar un preprocesamiento de las imágenes, aumentando así el tiempo requerido para analizar cada imagen.

La disposición de las fuentes de luz afecta de manera importante a las imágenes adquiridas, ya que algunas zonas pueden recibir más luz que otras, lo que cambia la cantidad total de radiación reflejada por los objetos en estas áreas. Una iluminación desigual se puede corregir calibrando la imagen utilizando una placa blanca de reflectancia conocida (blanco de referencia), aunque esta corrección consume ciertos recursos computacionales. Por otra parte, es muy importante tener en cuenta la geometría de los objetos inspeccionados. Por ejemplo, situar un tipo de iluminación direccional en un ángulo de 45° respecto de la vertical cuando se ilumina un objeto plano es eficaz para evitar reflejos directos hacia la cámara. Fernández et al. (2005) utilizaron esta configuración para iluminar rodajas de manzana para controlar y evaluar su deshidratación mediante el seguimiento de su color y forma. Un sistema similar lo utilizaron posteriormente Pedreschi et al. (2006) para iluminar patatas fritas en un sistema diseñado para medir la cinética de los cambios de color bajo diferentes temperaturas de fritura.

Por otro lado, si el objeto es más o menos esférico, es más conveniente utilizar una campana difusora hemisférica con el fin de iluminarlo de manera uniforme. Riquelme et al. (2008) utilizaron una campana de estas características para iluminar e inspeccionar aceitunas. Sin embargo, en estos sistemas y en aquellos en los que en general se ilumina el objeto desde arriba, la parte superior del objeto aparece más iluminada que en los bordes, creando así un falso cambio de intensidad que es importante corregir posteriormente. Gómez-Sanchis et al. (2008b) propusieron una metodología para la corrección de este efecto en los cítricos mediante la construcción de un modelo de elevación de la fruta que usaron para estimar la altura teórica y el ángulo de incidencia de la luz para cada píxel. Esto hizo posible estimar las correcciones apropiadas de la reflectancia observada. La Figura 1.1 muestra dos ejemplos de sistemas de iluminación para iluminar objetos esféricos y planos.

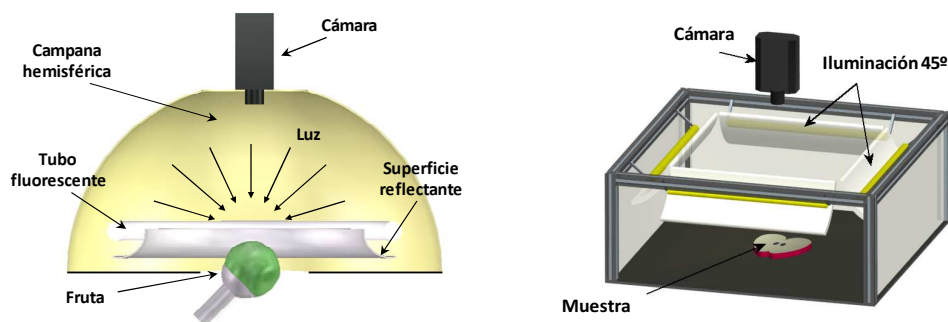


Figura 1.1. Ejemplos de iluminación difusa y direccional orientada a 45° de la muestra

Un sistema eficaz para evitar brillos y reflejos indeseados en los objetos cuando no se puede conseguir directamente a través de un sistema de iluminación eficaz es mediante el uso de filtros polarizadores. El uso de técnicas de polarización cruzada previene la aparición de reflexiones especulares en las imágenes. Blasco et al. (2007a) usaron esta técnica para evitar brillos en las imágenes de cítricos iluminados con tubos fluorescentes y de esta manera estimar su color con mayor precisión y detectar defectos superficiales. Cuando el objeto a inspeccionar es translúcido o cuando la información se va a obtener del análisis de su contorno, se puede utilizar retroiluminación, es decir, que el objeto se sitúa entre la fuente de luz y la cámara. Esta solución la adoptaron Blasco et al. (2009a) para la inspección en línea de gajos de mandarina que se desplazan sobre cintas transportadoras semitransparentes. Al iluminar los gajos desde abajo, éstos mostraron en las imágenes un fuerte contraste con el fondo, lo que hizo más fácil realizar un análisis morfológico del contorno. Al mismo tiempo, las semillas contenidas en algunos gajos aparecían más oscuras que el resto del gajo, lo que facilitó su detección.

El espectro de emisión de la fuente de luz es fundamental para una adecuada adquisición de las imágenes. Los tubos fluorescentes son válidos para aplicaciones en que la luz visible es importante (por ejemplo, la clasificación por color), pero producen poca radiación en la región infrarroja. Por otra parte, con la utilización de balastos convencionales, se produce una oscilación característica de la intensidad lumínica que es importante corregir con el uso de balastos electrónicos de alta frecuencia. Las lámparas incandescentes emiten más radiación infrarroja, pero normalmente generan una gran cantidad de calor, pueden ser consideradas fuentes puntuales y tienen una temperatura de color baja, lo que supone un inconveniente importante para las aplicaciones basadas en el color. En la actualidad, los sistemas de iluminación basados en LED son cada vez más económicos y frecuentes. Normalmente tienen un bajo consumo de energía, son robustos y producen muy poco calor, pero por otro lado, son muy direccionales y su potencia lumínica es todavía bastante limitada.

También se debe hacer una especial mención a los sistemas de iluminación que inducen el fenómeno de la fluorescencia para detectar daños o características invisibles al ojo humano empleando otro tipo de iluminación. En algunas longitudes de onda concretas, la radiación recibida excita ciertas moléculas cuya relajación posterior produce que el cuerpo emita radiación de menor energía lumínica (longitudes de onda más largas). Por ejemplo, la fluorescencia inducida en el ultravioleta permite que algunos tipos de daños externos en frutas se puedan detectar al producir fluorescencia en el visible. Obenland y Neipp (2005) emplearon la fluorescencia de clorofila para localizar lesiones incipientes en la piel causadas por tratamientos de agua caliente en los limones. Por otra parte, Ariana et al. (2006a) utilizaron fluorescencia visible e inducida por ultravioleta (UVFL) para detectar diferentes tipos de defectos en tres variedades de manzanas. La emisión de luz de 740 nm después de la excitación UV les permitió detectar los defectos. Slaughter et al. (2008) utilizaron el mismo método para detectar daños causados por heladas y que son muy difíciles de detectar con luz visible. Sus resultados obtuvieron unas tasas de éxito entre el 64 % y el 88 %, dependiendo de la gravedad de los daños. Otra aplicación de UVFL es la descrita por Lefcote y Kim (2006a) para la detección de contaminantes en las frutas, como es el caso de las manzanas, donde encontraron que 668 nm es el pico de respuesta de fluorescencia de los contaminantes.

1.2.2 Adquisición de imágenes

Las cámaras son los dispositivos encargados de adquirir las imágenes, convirtiendo la luz que reciben de la escena en señales electrónicas. Las cámaras industriales más populares están basadas en CCD, que consisten en una serie de sensores (píxeles) compuestos cada uno de ellos por una fotocélula y un condensador (Peterson, 2001). La carga adquirida por el condensador depende de la cantidad de luz recibida por la fotocélula. Estas cargas se convierten en tensión eléctrica y posteriormente en señales de vídeo. Algunas cámaras se basan en un CCD lineal, compuesto por una matriz unidimensional de sensores que adquieren una estrecha franja de la escena. Estas cámaras, conocidas como cámaras de escaneo lineal, son adecuadas para aplicaciones donde el objeto se desplaza por debajo de la cámara o donde la cámara se mueve por encima del objeto, de modo que la imagen completa de su superficie se adquiere gradualmente, línea por línea. Sin embargo, las cámaras matriciales son las más extendidas en aplicaciones comerciales. Estas adquieren una escena usando un CCD en forma de matriz de dos dimensiones. Las cámaras de color pueden ser construidas con un único CCD color, compuesto por píxeles que son sensibles a las bandas primarias roja, verde y azul (RGB), pero también están disponibles cámaras más sofisticadas de mayor calidad con tres CCD. En estas cámaras, la luz que entra por la lente principal se divide en tres haces de luz mediante una serie de lentes y espejos, lo que genera tres copias de la escena; una se dirige hacia un filtro rojo, otra hacia un filtro verde y la tercera a un filtro azul. A continuación de cada filtro hay un sensor CCD monocromático, por lo que cada uno adquiere una de las señales RGB individuales. Las cámaras más novedosas están basadas en CMOS. El aumento de la

densidad de sensores en la integración de los semiconductores ha permitido que esta tecnología se desarrolle rápidamente. Estos sensores tienen un menor consumo de energía y menores costes de fabricación, por lo que actualmente se implementan de manera generalizada en cámaras web y dispositivos móviles.

A menudo, la inspección de algunos productos o características concretas requiere de sistemas de adquisición de imágenes que sean sensibles en diferentes longitudes de onda a lo largo del espectro. En estos casos, las cámaras multiespectrales combinan varias bandas visibles e invisibles utilizando filtros y sensores adecuados. Aleixos et al. (2002) desarrollaron una cámara multiespectral para obtener imágenes en el visible y NIR de la misma escena para inspeccionar cítricos en una máquina de clasificación automática. Lleó et al. (2009) utilizaron una cámara sensible a tres bandas del visible y al NIR para estimar la madurez de los melocotones. Throop et al. (2005) propusieron una cámara especial, diseñada para obtener imágenes en 740 y 950 nm en combinación con imágenes visibles para clasificar manzanas en tiempo real. Unay y Gosselin (2006) utilizaron cuatro filtros interferenciales paso-banda centrados en 450 nm, 500 nm, 750 nm y 800 nm para detectar defectos en manzanas.

Más recientemente, se han utilizado sistemas de adquisición de imágenes hiperespectrales para la inspección de frutas y verduras (Sun, 2010). Estos sistemas utilizan filtros de banda estrecha para generar imágenes hiperespectrales compuestas por n imágenes monocromáticas, cada una de ellas correspondiente a la radiancia/reflectancia en una longitud de onda específica. Dependiendo de la tecnología utilizada existen distintos sistemas de adquisición de imágenes hiperespectrales, siendo los tres más populares los espectrógrafos de imagen (Polder et al., 2003), los filtros sintonizables acústico-ópticos (AOTF) (Bei et al., 2004) y los filtros sintonizables de cristal líquido (LCTF) (Evans et al., 1998).

Los espectrógrafos de imagen separan la reflexión de una zona estrecha de la escena en sus componentes espectrales mediante un prisma o una rejilla, y proyectan la información espectral a un sensor de imagen, que por lo general consiste en una cámara CCD o CMOS de escaneo lineal (Kim et al., 2001). Un AOTF es un filtro espectral pasa-banda ajustable electrónicamente. Está formado por un cristal que, al ser excitado con una onda acústica, refracta la onda de una determinada amplitud y por tanto la separa del resto del espectro lumínico. La longitud de onda de la luz separada es función de la frecuencia de la señal acústica aplicada al cristal. El LCTF basa su funcionamiento en la combinación de filtros de *Lyot*. Estos filtros están constituidos por una estructura de *sandwich* compuesta por una lámina de cristal líquido y una lámina de cuarzo entre dos polarizadores lineales. Las láminas de cuarzo y de cristal líquido constituyen un retardador. El principal éxito de los filtros de *Lyot* es controlar electrónicamente el proceso de interferencia entre los haces ordinarios y extraordinarios de la radiación incidente, consiguiendo a la salida la selectividad en frecuencia deseada en la radiación transmitida (Hetchts, 1998). Un LCTF está constituido por una serie de filtros de *Lyot* apilados para conseguir el rango y la selectividad en frecuencia deseada. Todos estos sistemas pueden ser sensibles hasta

cerca de 2500 nm y es muy importante que tanto el espectrógrafo o filtro como la cámara empleada sean sensibles en el mismo rango espectral.

A pesar de que existen diferentes ejemplos de aplicaciones de sistemas hiperespectrales en otros campos, su incorporación en los almacenes comerciales de productos hortofrutícolas resulta muy complicada debido al alto coste computacional requerido para la adquisición y el procesamiento de estas imágenes. Algunos de estos ejemplos son el desarrollado por Nicolaï et al. (2006) para encontrar ciertos tipos de daños en manzanas en la región infrarroja o el realizado por Karimi et al. (2009), que estudiaron los cambios en la reflectancia (350 a 2500 nm) de aguacates recubiertos con diferentes formulaciones.

El aumento de la potencia de cálculo y la mejora de la tecnología de imagen han impulsado el uso de imágenes de alta resolución, lo que se traduce en un aumento en el rendimiento de los sistemas de visión por computador (hoy en día es posible detectar defectos tan pequeños como unos pocos mm²). Otro importante avance es el relacionado con los protocolos de alta velocidad que permiten transferir, empleando poco tiempo, estas grandes imágenes al ordenador, como el USB 2.0 (hasta 480 Mbps), FireWire (800 Mbps) o Giga-Ethernet (1000 Mbps), llegando a ser algunos de ellos incluso más rápidos que las tarjetas de adquisición de imágenes utilizadas anteriormente sobre el bus PCI (133 Mbps). Estos avances han modificado la arquitectura tradicional formada por una cámara de vídeo conectada a una tarjeta de adquisición de imágenes instalada en un ordenador, por una nueva arquitectura en la que hay una comunicación directa entre la cámara y el ordenador. Incluso, están apareciendo nuevas cámaras inteligentes, que incorporan un microprocesador con un sistema operativo sobre el cual el usuario puede desarrollar software de procesamiento de imágenes, de modo que la cámara se convierte también en la unidad de proceso y, por lo tanto, no es necesario un ordenador adicional. Además, el uso de Internet ha incrementado la disponibilidad de las llamadas cámaras IP que son capaces de transferir imágenes a un ordenador remoto mediante el protocolo TCP/IP.

Además de los sistemas tradicionales que adquieren las imágenes mediante cámaras, también se han utilizado escáneres planos para obtener imágenes de objetos pequeños como nueces u hojas (Menesatti et al., 2008), e incluso equipos médicos para el análisis de la calidad interna de frutas y verduras, como los basados en rayos X o en resonancia magnética (Hernández-Sánchez et al., 2007; Milczarek et al., 2009).

Respecto del formato de las imágenes, si éstas se tienen que almacenar para su posterior procesamiento, el formato en el que se guardan puede afectar al posterior procesamiento de las imágenes. Los formatos de compresión como JPEG se aprovechan de las limitaciones inherentes del ojo humano para descartar la información no apreciable, lo que los hace útiles en aplicaciones donde el tamaño de la memoria de almacenamiento es relevante. Sin embargo, este formato reduce la información disponible en la imagen y genera cierto ruido que puede complicar el posterior tratamiento de las imágenes. Los formatos que no reducen la calidad de

imagen, tales como TIFF o BMP son recomendables para aplicaciones en las que esta pérdida de información es un factor importante. En cualquier caso, las aplicaciones en línea no requieren de almacenamiento de las imágenes, sino que se adquieren, procesan y descartan al instante.

1.3 Aplicaciones de visión por computador en la inspección de características externas

El propósito final de muchos sistemas de inspección basados en visión por computador es el de estimar una o varias características de interés de los productos en un momento determinado y relacionarlos con la calidad que aprecia el consumidor. Otros sistemas están dirigidos a determinar la evolución del producto en el tiempo con el fin de determinar si un particular tratamiento o proceso es válido o no. En la mayoría de estas aplicaciones, el análisis de imágenes se utiliza para evaluar características como color, tamaño, forma, textura o presencia de daños. En este apartado se presentan algunas de las recientes investigaciones en visión por computador para la evaluación de la calidad externa de la fruta.

1.3.1 Uso de la información de color

El color es uno de los atributos más importantes en las frutas y verduras, ya que influye directamente en la decisión de los consumidores para aceptar o rechazar un determinado producto. Los productores, por lo tanto, se esfuerzan por evitar que los productos con defectos de coloración lleguen al mercado, así como para asegurar que conjuntos de productos (por ejemplo en lata, embolsados, etcétera) se ofrezcan en lotes con un color similar. En la industria el color se mide utilizando colorímetros (Hoffman, 2010). Las coordenadas de color proporcionadas por estos dispositivos se refieren habitualmente al espacio de color CIE 1931, y se denotan por X, Y y Z. Los colorímetros se utilizan para la medición de pequeñas regiones o en aplicaciones donde la muestra presenta un color uniforme, y no se adaptan bien a la medición de objetos con un color heterogéneo (Gardner, 2007). Cuando es necesario medir el color de áreas mayores o si la muestra presenta diferentes colores que se deben discriminar, es necesario realizarlo de otra manera. El análisis de imagen puede ser una solución efectiva, ya que una cámara proporciona imágenes en las que los colores de los píxeles se determinan individualmente. Por el contrario, los colorímetros son dispositivos fáciles de calibrar, mientras que la calibración de las imágenes depende de muchos factores y es más compleja.

El color de un píxel en una imagen se expresa con tres coordenadas en un espacio de color. Los más ampliamente utilizados en ordenadores e imágenes digitales son los espacios basados en los colores primarios rojo, verde y azul (RGB). Cuando los objetos inspeccionados tienen diferentes colores, a menudo una simple relación entre ellos puede discriminarlos, lo que ahorra tiempo de procesamiento. Por ejemplo, Blasco et al. (2009c) utilizaron este espacio de color para discriminar cuatro categorías de arilos de granada y clasificarlos en tiempo real. Las pruebas mostraron que un

modelo basado en análisis discriminante empleando como variables las coordenadas RGB proporcionaba los mismos resultados de clasificación que una umbralización realizada sobre la relación R/G, con tasas de éxito superiores al 90 %. Sin embargo, este último método reducía considerablemente el tiempo de procesamiento y es más fácil de comprender por un operario en el caso de desarrollar una aplicación industrial.

Es importante destacar que el espacio de color RGB depende del dispositivo, es decir, diferentes dispositivos producen diferentes valores RGB para los mismos píxeles en una escena. Por esta razón, se han desarrollado diferentes intentos de estandarizar los valores, como el espacio de color llamado sRGB (Stokes et al., 1996). Otro espacio de color comúnmente utilizado en la inspección de alimentos, más cercano a la percepción humana del color, es el HSI. Blasco et al. (2007b) compararon cinco espacios de color para la identificación de defectos externos en los cítricos y obtuvieron los mejores resultados con el HSI. Xiaobo et al. (2007) utilizaron tanto RGB como HSI para clasificar manzanas Fuji en cuatro categorías de color. Por su parte, Abdullah et al. (2006) convirtieron coordenadas RGB en coordenadas HSI, y utilizaron el componente H para clasificar carambolas (*Averrhoa carambola*) en cuatro categorías de madurez.

Sin embargo, tanto RGB como HSI son espacios de color no uniformes. Esto significa que la distancia euclídea entre dos puntos de color situados en diferentes regiones de estos espacios no producen la misma diferencia de percepción de un observador estándar. Para intentar solucionar este problema, se definieron espacios uniformes como el CIE $L^*a^*b^*$ y el Hunter Lab (HunterLab, 2008), y que son los que habitualmente se emplean para la comparación de color (León et al., 2006). Mendoza et al., (2006) compararon diferentes espacios de color, como sRGB, el HSV y $L^*a^*b^*$ en términos de su idoneidad para la cuantificación del color en superficies curvas, resultando ser más adecuado el $L^*a^*b^*$.

En algunas ocasiones es suficiente usar una sola coordenada $L^*a^*b^*$ para la establecer alguna clasificación de la fruta. Liming y Yanchao (2010) utilizaron la coordenada a^* para clasificar fresas en tres categorías de color. En comparación con la selección humana, el sistema basado en análisis de imágenes alcanzó un éxito del 89 %. El ángulo del tono y el croma son características de color derivadas de los espacios uniformes antes mencionados. Para analizar el color del mango, Kang et al. (2008) cuantificaron el efecto de la curvatura en el cálculo del ángulo del tono y el croma, y demostraron que el primero proporcionaba una valiosa descripción cuantitativa del color y de los cambios de color tanto en lotes como en mangos individuales con color heterogéneo.

A menudo, es importante determinar el color de las frutas para establecer posteriores tratamientos en poscosecha. Por ejemplo, es frecuente recolectar las mandarinas cuando todavía presentan un color verde y someterlas a un tratamiento de desverdización. En estos casos, la fruta se almacena en una cámara con una humedad específica y con una concentración de etileno determinada. La duración de este

tratamiento depende del color de la fruta en el momento de la recolección, que se expresa como un índice de color estándar (Jiménez-Cuesta et al., 1981). En otro ejemplo, Fathi et al. (2011) utilizaron análisis de imagen para medir la influencia de diferentes tratamientos osmóticos en el color de los kiwis. Para ello convirtieron las coordenadas originales RGB en $L^*a^*b^*$ a fin de evaluar las diferencias de color. Según Xul et al., 2009, a menudo el color de la piel también revela síntomas de lesiones internas en manzanas.

Además de estos ejemplos de la aplicación de la visión por computador en entornos controlados, esta tecnología también tiene una gran aplicación en campo. Un caso típico es la estimación del rendimiento de los cultivos. Okamoto y Lee (2009) lograron detectar cítricos verdes en el árbol entre hojas con un color similar. Para ello, emplearon imágenes hiperespectrales en el rango de 369-1042 nm. Safren et al. (2007) también propusieron un método basado en visión por computador para la estimación automática del rendimiento de cultivos de manzanas *Golden Delicious* analizando imágenes hiperespectrales de árboles en diferentes etapas de crecimiento. Bulanon et al. (2009) persiguieron un objetivo similar aplicado a cítricos, aunque utilizando un enfoque diferente ya que usaron una combinación de imágenes del visible y térmicas, que analizaron mediante dos métodos de fusión de imágenes. De esta forma mejoraron la detección de fruta y demostraron un mejor rendimiento respecto del empleo de imágenes térmicas únicamente.

1.3.2 Estimación de tamaño y volumen

El tamaño es una característica de particular importancia en la industria hortofrutícola ya que el precio de muchos productos está directamente relacionado con su tamaño. La estimación de este atributo en objetos regulares, como por ejemplo frutas esféricas o casi esféricas, es relativamente fácil, pero se vuelve cada vez más complejo en frutas y verduras con forma irregular. Las variables más utilizadas para estimar el tamaño son el área, el perímetro, la longitud o la anchura. Debido a las irregularidades naturales en la forma de los productos agrícolas, a la hora de estimar estas medidas mediante análisis de imagen, puede existir una importante influencia de la orientación del objeto con respecto a la cámara. Por esta razón, muchos autores combinan la información obtenida a partir de imágenes tomadas desde diferentes ángulos entre el objeto y la cámara. Por ejemplo, Blasco et al. (2003) estimaron el tamaño de manzanas *Golden Delicious* adquiriendo cuatro imágenes de cada fruta, y eligiendo la vista en la que el pedúnculo se localizaba más cerca del centroide (centro de masas) del objeto, ya que la normativa exige el diámetro ecuatorial como medida de tamaño. Throop et al. (2005) midieron el tamaño de 14 variedades de manzanas mientras se transportaban por unos rodillos, ajustando la velocidad de traslación y rotación de tal manera que se capturaron imágenes correspondientes a una vuelta completa de cada fruta. Así, calcularon el diámetro ecuatorial y el área de la manzana. Posteriormente asumieron la manzana como una elipse y estimaron la altura a partir de su eje mayor, utilizando este dato para obtener la orientación de la fruta.

El volumen también se ha utilizado como una medida indirecta de tamaño, aunque es un reto particularmente complejo estimar el volumen de objetos naturales partiendo de una imagen plana. En la literatura científica, una de las formas citadas con más frecuencia para estimar mediante visión por computador el volumen de productos agrícolas que presentan simetría en sus ejes, es mediante la subdivisión de los objetos en distintas particiones. Un método consiste en obtener el contorno del objeto a partir de una proyección plana y dividirlo en secciones verticales de una anchura determinada. Una vez hecho esto, rotando la mitad de la altura de cada sección vertical alrededor del eje X, se obtienen rodajas del objeto de esa anchura para las cuales es más sencillo estimar el volumen. Juntando todas estas rodajas se puede estimar el volumen total del objeto. Usando esta teoría, Koc (2007) determinó el volumen de sandías y comparó los resultados con los obtenidos utilizando el método tradicional de desplazamiento de agua, concluyendo que la diferencia entre los volúmenes estimados por el procesamiento de imágenes y por el desplazamiento de agua no eran estadísticamente significativos.

1.3.3 Estimación de la forma

El consumidor siempre es más proclive a adquirir frutas o verduras que presenten su forma característica. Los productos con deformaciones o formas extrañas no se pueden comercializar o tienen precios más bajos. Por ello, los sistemas automáticos de inspección de la calidad de estos productos deben tener en cuenta este hecho. La forma es una medida subjetiva que se puede estimar a partir de mediciones de otras características y lo habitual es establecer categorías. Liming y Yanchao (2010) definieron cuatro clases de formas de fresas: larga-cónica, cuadrada, cónica y redondeada. Para estimar la forma de la fresa extrajeron secuencias lineales (anchuras) del contorno de las frutas, normalizaron su longitud para eliminar la influencia del tamaño y emplearon el método de k -medias para asignar cada fruta a una clase. La circularidad es otra característica que se ha utilizado para determinar la forma de frutas (Unay y Gosselin, 2007). Sadrnia et al. (2007) utilizaron la relación de aspecto (longitud por anchura) para estimar la forma de sandías. Además, estimaron la masa, volumen, dimensiones, densidad, coeficiente de esfericidad y diámetro medio, utilizando los coeficientes de correlación de estos parámetros para generar un modelo con el fin de determinar si una fruta en particular tiene una forma estándar o no.

En otros casos se pueden obtener imágenes de alto contraste utilizando iluminación posterior, donde la silueta del objeto se destaca del fondo. Costa et al. (2009) colocaron naranjas sobre un soporte iluminado lateralmente para determinar su forma. De este modo, extrajeron la firma polar del contorno y calcularon los coeficientes de los armónicos de Fourier para describir el tamaño, forma y orientación de cada fruta. Menesatti et al. (2008) también utilizaron la iluminación posterior para estimar el perfil de avellanas con el fin de discriminar entre diferentes cultivares. Utilizaron el análisis de la elipse de Fourier para extraer características a partir de las cuales estimar la forma mediante un modelo PLS. Antonucci et al. (2010) llevaron a cabo un trabajo similar para discriminar entre variedades de almendra.

1.3.4 Textura

La percepción de un color por un sistema de visión por computador es diferente si las superficies de los objetos tienen diferentes texturas. Por esta razón, el estudio de la textura se integra a menudo en estudios de diferencias de color, incluyendo aquellos para detectar la presencia de defectos externos. La textura puede desempeñar un papel importante en la segmentación de las imágenes, ya que se trata de una herramienta eficaz para solucionar problemas en el reconocimiento de patrones al inspeccionar automáticamente frutas y verduras.

Mientras que la segmentación de imágenes basada en técnicas orientadas a píxel (aquellas que procesan individualmente los píxeles, sin tener en cuenta sus vecinos) es muy sensible al ruido o particularidades locales en la escena, la segmentación basada en la textura de las regiones de interés requiere algoritmos más complejos, que además de analizar el color, también tienen en cuenta las relaciones espaciales entre los píxeles vecinos para caracterizar las distintas regiones de una imagen y detectar los cambios entre ellas (Blasco et al., 2007a).

A menudo, frutas que pertenecen a la misma variedad tienen un alto índice de variabilidad en la textura y el color que complica el análisis de las imágenes. La Figura 1.2 ilustra la amplia variabilidad de colores y texturas en imágenes de naranjas de un mismo cultivar (cv. 'Valencia'). López-García et al. (2010) propusieron un método que combina la información de color y textura en un modelo de PCA para la detección de defectos de la piel en cuatro variedades de cítricos. Para ello, utilizaron los valores RGB de cada píxel y los de sus vecinos (en ventanas de 3x3 y 5x5). Con este método lograron detectar el 91,5 % de todos los defectos en las cuatro variedades de naranjas y mandarinas con tan sólo el 3,5 % de falsas detecciones.

Las matrices de co-ocurrencia de color y sus características matemáticas representan uno de los métodos más utilizados para describir la textura. Pydipati et al. (2006) utilizaron este método para determinar si la textura basada en características de color HSI podría ser utilizada en conjunto con otros estadísticos para identificar hojas enfermas y sanas en árboles de cítricos, en condiciones de laboratorio. Se evaluaron muestras de hojas de cítricos sanas y otras afectadas con melanosis y sarna. Zhao et al. (2009) describieron un método similar para diferenciar entre piel sana y cinco tipos diferentes de daños en imágenes de piel de pomelo adquiridas con un microscopio. Menesatti et al. (2009) utilizaron el contraste, la homogeneidad, el segundo momento angular y la correlación de matrices de co-ocurrencia de niveles de gris para evaluar el contenido de almidón en manzanas, que está directamente relacionado con su madurez. Para estimarlo utilizaron imágenes del visible y del NIR en el rango de 1000-1700 nm. Elmasry et al. (2007) evaluaron la madurez en fresas partiendo de imágenes pseudo-RGB (construidas a partir de imágenes monocromáticas de 450, 500 y 650 nm). Las frutas maduras tenían una textura más rugosa que las verdes.

Otros métodos menos convencionales utilizan características de las texturas fractales derivadas del análisis espectral de Fourier. Un ejemplo lo describen Quevedo et al.

(2008), que supervisaron la maduración de plátanos detectando la senescencia a partir de las manchas de la piel.




Figura 1.2. Izquierda: Imagen de naranjas que muestran diferentes defectos, colores y texturas en la piel. Derecha: la misma imagen segmentada que muestra los defectos encontrados

1.3.5 Detección de defectos externos

La detección de defectos y daños en la piel es la aplicación más extendida del análisis de imágenes en la inspección de productos agroalimentarios. La presencia de daños externos es un claro signo de la pérdida de calidad de un producto, y por ello suscita gran interés la creación de nuevos y avanzados sistemas automáticos y objetivos para detectarlos. Una dificultad común para la mayoría de los productos es la de distinguir zonas defectuosas de otros elementos naturales, como hojas, cáliz o pedúnculo. En este sentido, Bennedsen et al. (2005b) describen un sistema de procesamiento de imágenes para evitar en lo posible esta confusión en manzanas. El sistema descrito minimiza los falsos positivos (elementos propios de la fruta detectados como daños) mediante la adquisición y análisis de múltiples imágenes adquiridas en las bandas 740 y 950 nm mientras las manzanas están rotando. Por su parte, Xing et al. (2007) identificaron por medio de un sistema hiperespectral varias longitudes de onda en el visible y el NIR que podrían ser utilizadas para discriminar entre pedúnculo, cáliz, daños y piel sana en manzanas. Para reducir la dimensionalidad de los datos proporcionados por las imágenes a unas pocas longitudes de onda óptimas utilizaron PCA. Unay y Gosselin (2007) compararon diferentes algoritmos de clasificación (basados en análisis discriminante lineal, k -vecinos más cercanos y máquinas de vector soporte) para reconocer pedúnculo y cáliz en manzanas *Jonagold* sanas y con daños. Dado que esta variedad presenta dos colores en la piel, utilizaron cuatro filtros centrados en longitudes de onda del visible y de infrarrojo cercano.

A pesar de que algunos defectos no evolucionan y sólo deprecian el valor comercial de la fruta, otros como las infecciones por hongos pueden degradar la fruta hasta evitar su comercialización. Éstos son especialmente peligrosos ya que se pueden desarrollar durante el transporte o almacenamiento y diseminarse entre otras frutas sanas,

causando importantes pérdidas económicas. Los defectos que pertenecen a este grupo se deben detectar lo más pronto posible para evitar la propagación de la podredumbre. En estos casos, la mera detección de defectos no es suficiente y además es necesario reconocerlos e identificarlos. Blasco et al. (2007a) utilizaron un algoritmo de crecimiento de regiones para encontrar regiones diferentes en la piel de los cítricos. En un paso final, las regiones encontradas que guardaban cierto grado de similitud se fusionaron utilizando distancias de color en el espacio HSI (Figura 1.3). Asumiendo que la región más grande de las resultantes correspondía a piel sana, este método permitió detectar once tipos diferentes de defectos aunque no los identificaba. Un trabajo posterior combinó información espectral de imágenes de color, NIR, UV y UVFL para identificar estos defectos individualmente (Blasco et al., 2007b). Más recientemente, los resultados han mejorado claramente mediante la adición de parámetros morfológicos al algoritmo de decisión (Blasco et al., 2009b).

Ariana et al. (2006a) integraron información de reflectancia multispectral y fluorescencia para detectar defectos en tres variedades de manzanas mediante una combinación de filtros que van desde el visible al NIR. Utilizaron algoritmos de clasificación a nivel de píxel para distinguir entre tejido sano y tejido afectado por diferentes tipos de daños que lograron identificar.

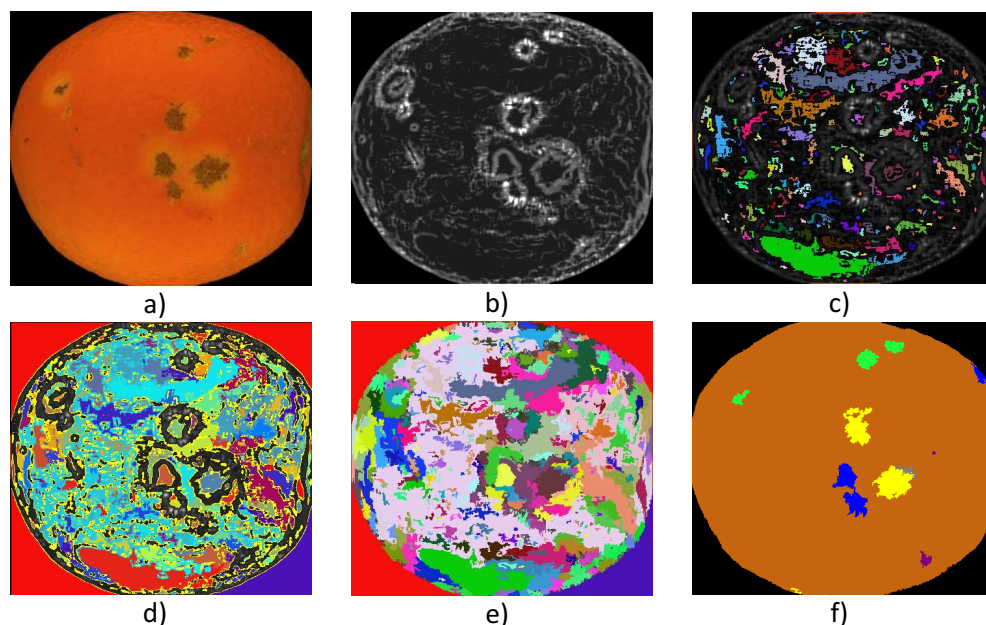


Figura 1.3. Proceso de crecimiento de regiones para detectar defectos en cítricos. a) Imagen de color original de una naranja con manchas causadas por la fitotoxicidad, b) semillas de las regiones de color homogéneo, c) y d) pasos iterativos de crecimiento, e) etapa final de crecimiento, y f) imagen final después de la fusión de las regiones basada en la información de color

La detección temprana de daños y podredumbres ha sido en los últimos años uno de los principales objetivos de investigación sobre la inspección automática de la calidad

de frutas y verduras. Mediante el uso de cámaras convencionales de color, esta detección resulta una tarea muy difícil ya que el color y la textura de la piel sana e infectada son en ocasiones similares en los primeros momentos. Sin embargo, imágenes tomadas en longitudes de onda específicas pueden presentar un mayor contraste entre la piel sana y la afectada. La Figura 1.4 muestra imágenes de naranjas con diferentes defectos, adquiridas con una cámara estándar monocromática visible (arriba) y con un sistema de imágenes hiperespectrales (abajo). Ciertas longitudes de onda (Figura 1.4, abajo) mejoran la apariencia de los daños, lo que simplifica la detección mediante un sistema de inspección automática. Precisamente, Elmasry et al. (2008) investigaron el potencial de los sistemas de imágenes multispectrales para la detección temprana de golpes en manzanas *McIntosh*. Para ello, analizaron la reflectancia espectral entre 400 y 1000 nm, y utilizaron PLS y LDA para la reducción de la dimensionalidad de los datos y la selección de longitudes de onda. Finalmente escogieron tres de ellas (750, 820 y 960 nm) para simular un sistema de imágenes multispectrales y demostraron que las manzanas golpeadas se pueden distinguir con éxito de manzanas sanas ya en las primeras etapas del desarrollo de las manchas. Posteriormente, obtuvieron cinco longitudes de onda óptimas para detectar daños por frío en manzanas *Red Delicious* utilizando redes neuronales artificiales (Elmasry et al., 2009).




Figura 1.4. Imágenes de cuatro cítricos con diferentes defectos externos adquiridos con una cámara monocromática B/W (arriba) y las mismas frutas adquiridas en determinadas longitudes de onda (abajo). De izquierda a derecha: 450 nm, 720 nm, 520 nm y 480 nm

En el caso particular de los cítricos, por ser un producto que representa una parte importante de esta tesis, cabe citar que Gómez Sanchis et al. (2008a) utilizaron imágenes hiperespectrales para detectar daños causados por el hongo *Penicillium digitatum* en cítricos. Emplearon varias técnicas estadísticas (análisis de correlaciones, información mutua, regresión multivariante y algoritmos genéticos) para reducir la dimensionalidad de las imágenes. Después, usaron análisis discriminante lineal y árboles de clasificación y regresión para segmentar las imágenes y discriminar los daños. Qin et al. (2009) detectaron antracnosis, manchas grasientas, daños por

insectos, melanosis, costras y rameados en cítricos utilizando un método de clasificación de la divergencia de la información espectral. Este procedimiento se basa en la cuantificación de las similitudes espectrales utilizando un espectro de referencia predeterminado en la región espectral desde 450 hasta 930 nm. Barnes et al. (2010) detectaron manchas en patatas utilizando diferentes características en función de la información estadística relacionada con el color y la textura optimizada por medio de un algoritmo adaptativo. Otro método no convencional de identificación de defectos en cítricos lo describen Slaughter et al. (2008), quienes detectaron daños por congelación en naranjas cv. 'Navel' utilizando propiedades de fluorescencia UV de los aceites esenciales de la piel.

A continuación se muestra la Tabla 1.1 que resume los trabajos más recientes relacionados con sistemas de inspección de productos hortofrutícolas.

Tabla 1.1. Sistemas publicados de inspección de frutas y verduras basada en visión por computador

Producto	Sistema de imagen	Aplicación (Técnica)	Referencia
Manzanas	Cámara CCD, Tubos fluorescentes UVA, Lámparas halógenas de tungsteno	Defectos (ANN)	Ariana et al. (2006a)
Manzanas	Espectrógrafo de imagen, Lámparas halógenas 45°	Defectos (PLS, SW)	EIMasry et al. (2008)
Manzanas	Espectrógrafo de imagen, Lámparas UV 45°	Defectos (ANN)	EIMasry et al. (2009)
Manzanas	Espectrógrafo de imagen, Lámparas UV, Fluorescencia	Defectos (histograma)	Lefcote y Kim (2006a)
Manzanas	Espectrógrafo de imagen, Lámparas halógenas difusas	Defectos (PLS)	Lefcote et al. (2006b)
Manzanas	Espectrógrafo de imagen, Lámparas halógenas 45°	Color (RGB), texturas (starch, k-NN, PLS, LDA)	Unay y Gosselin (2007)
Manzanas	Espectrógrafo de imagen, Lámparas halógenas	Defectos (PLS)	Xing et al. (2007)
Manzanas	Cámara CCD, Fluorescente en anillo	Color (RGB, HSI)(GALDA)	Xiaobo et al. (2007)
Manzanas	Espectrógrafo de imagen Lámparas halógenas	Detección tallo y cáliz (PCA)	Xing et al. (2007)
Plátanos	Cámara de fotos, Tubos fluorescentes 45°	Textura (descriptores fractales de Fourier)	Quevedo et al. (2008)
Plátanos	Cámara de fotos, Tubos fluorescentes 45°	Color (sRGB, HSV, L*a*b*)	Mendoza et al. (2006)

1. Visión por computador en agricultura

Cítricos	Cámara 3 CCDs, Tubos fluorescentes con filtros polarizados	Color (RGB, HSI), defectos (crecimiento de regiones)	Blasco et al. (2007a)
Cítricos	Cámara 3 CCDs, Tubos fluorescentes con filtros polarizados, Luz negra, Lámparas halógenas	Color (RGB, HSI, Luv, Lab, XYZ), defectos (LDA)	Blasco et al. (2007b)
Cítricos	Cámara RGB + microscopio	Defectos (de textura), texturas (co-ocurrencia de color, SW)	Zhao et al., (2009)
Cítricos	Cámara 3 CCDs, Tubos fluorescentes con filtros polarizadores, Luz negra, Lámparas halógenas	Color (RGB, HSI), forma (área y descriptores de Fourier), defectos (LDA)	Blasco et al. (2009b)
Cítricos	Cámara 3 CCDs, Tubos fluorescentes con Filtros polarizados	Defectos (MIA)	López-García et al. (2010)
Pepinos	Espectrógrafo de imagen, Lámparas halógenas	Defectos (PCA, relación de bandas, diferencia de bandas)	Ariana et al. (2006b)
Pepinos	Espectrógrafo de imagen, Lámparas halógenas	Divergencia información espectral	Qin et al. (2009)
Limonos	Cámara CCD, Lámparas UV	Defectos (umbralización)	Obenland y Neipp (2005)
Mandarinas	LCTF, Lámparas halógenas	Defectos (SW, GALDA, CA, MI, CART, LDA)	Gómez-Sanchis et al. (2008a)
Mandarinas	LCTF, Lámparas halógenas	Forma (elevación digital)	Gómez-Sanchis et al. (2008b)
Mangos	Cámara de fotos, Fluorescencia difusa	Color (L*a*b*)	Kang et al. (2008)
Champiñones	Espectrógrafo de imagen	Color (L), defectos (PCA, LDA)	Gowen et al. (2009)
Olivas	Cámara CCD	Color (RGB, HSV), defectos (ANOVA)	Riquelme et al. (2008)
Naranjas	Cámara de fotos, Luz posterior	Forma (descriptores de Fourier, k-medias)	Costa et al. (2009)
Naranjas	Cámara de fotos, Lámparas UV	Defectos (umbralización)	Slaughter et al. (2008)
Melocotones	Cámara multiespectral, Lámparas halógenas	Maduración, defectos (clustering R/NIR)	Lleó et al. (2009)
Patatas		Defectos (AdaBoost)	Barnes et al. (2010)

Patatas fritas	Cámara de fotos, Tubos Fluorescentes 45°	Color (L*a*b*)	Pedreschi et al. (2006)
Carambolos	Cámara CCD, Fluorescente en anillo	Color (H), forma (descriptores de Fourier)	Abdullah et al. (2006)
Sandías	Cámara CCD	Volumen	Koc (2007)

1.4 Sistemas de inspección en campo

Los sistemas de inspección en campo presentan muchas diferencias con respecto a los empleados en las centrales de confección. En la década de los 90, el IVIA colaboró en un proyecto europeo para el desarrollo de un robot recolector de frutas, que se denominaba *Citrus* en su versión para cítricos y *Magali* en la versión para manzanas (Plá et al., 1991). Como consecuencia del mismo se desarrolló una máquina autopropulsada que era capaz de detectar la fruta, desprenderla con una pinza especialmente diseñada, y cargarla en palots (cajas paletizables de aproximadamente 1 m de lado). La máquina también podía dar la vuelta al final de la calle, todo ello de manera automática. Hubo proyectos similares en Florida e Israel, pero éstos no llegaron a alcanzar el nivel de desarrollo del robot *Citrus*. El robot europeo llegó a establecer velocidades de recolección cercanas a los 2 s por fruto y era capaz de cosechar el 75-80 % de la fruta total.

Sin embargo, este proyecto no llegó al mercado porque en aquellos momentos las empresas participantes no estaban seguras de alcanzar un nivel de producción de máquinas que rentabilizase sus inversiones. Asimismo, hubo un cierto rechazo social porque se creía que reduciría el número de puestos de trabajo en el campo.

Por otra parte, el uso que se vaya a hacer de la fruta recolectada condiciona fuertemente el sistema de recolección. La que se destina a industria tiene parcialmente resuelto el problema de la recolección mecánica, ya que admite la presencia de cierto tipo de daños exteriores. Por el contrario, la fruta destinada al consumo en fresco no debe presentar ningún tipo de daño externo ni interno. En España, y en particular en la Comunidad Valenciana, la producción sigue estando enfocada al consumo en fresco, pero los años de bajos precios, o los restos de producción que quedan sobre el árbol se siguen recogiendo a mano, por lo que el costes de la recolección supera con creces al valor del producto. Por lo tanto, tiene mucho interés poner a punto técnicas de recolección mecánica que los reduzcan.

La Organización Interprofesional Agroalimentaria del sector de la Naranja y el grupo Mandarinas, INTERCITRUS, (Intercitrus, 2009), aprobó no recolectar los cítricos que no presentaran un calibre mínimo para aumentar la calidad de la producción. A pesar de la subjetividad de los diferentes operarios, esto se puede conseguir si la fruta se recolecta a mano pieza a pieza. El problema surge cuando la recolección se mecaniza, ya que no se efectúa pieza a pieza sino de manera global. Las ventajas de mayor rapidez y menor coste que otorga éste tipo de recolección, se ven descompensadas por

la imposibilidad de preseleccionar que fruta se recolecta y cual no. Por ello es muy importante desarrollar sistemas que complementen a este tipo de recolección y que sean capaces de separar la fruta de mayor calidad y que irá al consumo en fresco, de aquella que objetivamente no cumple con los estándares de calidad, ya sea por su pequeño calibre o bien por la presencia de daños en su piel que impidan su comercialización.

Uno de los mayores problemas lo representa la presencia o ausencia de pedúnculos en la fruta recolectada mecánicamente. Plá y Juste (1995) desarrollaron un sistema para detectar y caracterizar los pedúnculos en naranjas de forma que puedan ser eliminados antes del almacenamiento de las frutas. Una vez detectado el pedúnculo como una protuberancia de la fruta, una técnica de esqueletización permite localizar el punto de inserción. Ruiz et al., (1996) también utilizaron la visión artificial para localizar pedúnculos en las naranjas recolectadas. En este estudio se utilizó la segmentación del color y el análisis de la curvatura del contorno como técnicas de análisis de imagen, obteniendo precisiones superiores al 90% para la detección de presencia o ausencia del pedúnculo.

Por otra parte, los datos obtenidos a partir de satélites se han aplicado ampliamente en la estimación del rendimiento de cultivos. Estos datos se pueden obtener a lo largo del año, por lo que esta tecnología es especialmente adecuada para detectar cambios en la cobertura del suelo en cultivos agrícolas, determinar el estado de salud de las plantas, condiciones de humedad, establecer efectos de las prácticas de manejo del cultivo, etcétera. Shrivastava y Gebelein (2007) analizaron la cobertura del suelo de cultivos de cítricos usando imágenes de satélite para obtener una correlación entre la reflectancia espectral de la cubierta y el rendimiento económico de los cultivos.

Una alternativa a la imagen de satélite es la imagen aérea. Ye et al. (2006) usaron un espectrómetro de imagen situado a bordo de un avión para obtener imágenes hiperespectrales de un cultivo de cítricos. El promedio de la reflectancia espectral de las copas de árboles seleccionados se comparó con la fruta recolectada posteriormente de cada árbol. Realizaron modelos de regresión lineal entre los datos obtenidos a partir de las imágenes durante tres meses (abril, mayo y junio) y la cosecha real, obteniendo que únicamente en el mes de mayo se obtenía un valor de R^2 aceptable (0,81). En un trabajo posterior, los autores Ye et al. (2008) usaron estos datos para desarrollar modelos de predicción de cosecha mediante algunos índices de vegetación, CA, PCA y PLS, obteniendo mejores resultados con PLS.

Se han realizado un menor número de trabajos desde tierra firme. Dunn y Martin (2004) usaron fotografía digital para analizar viñedos en campo y predecir la producción. Sin embargo, la mayoría de estos trabajos tienen como objetivo detectar frutas en el árbol, bien para estimación de cosecha o bien para guiar a un robot recolector hasta las frutas. Okamoto y Lee (2009) desarrollaron un método de procesamiento de imágenes para detectar cítricos verdes en los árboles y lo aplicaron a la estimación del rendimiento de los cultivos en una etapa temprana de crecimiento.

Para lograrlo usaron una cámara hiperespectral para adquirir imágenes de frutos verdes de tres variedades diferentes de cítricos ('Tangelo', 'Valencia' y 'Hamlin'). En primer lugar, segmentaron la imagen usando LDA, tras lo que emplearon diversas técnicas de procesamiento de imágenes para obtener una detección entre el 80 % y el 89 % de la fruta expuesta.

1.5 Sistemas de inspección automática en tiempo real

El objetivo final de estos avances es obtener sistemas automáticos que se puedan emplear en la realidad. En las actuales líneas de inspección de la calidad de los almacenes hortofrutícolas, los productos viajan a alta velocidad bajo la cámara de inspección. Con el fin de obtener imágenes con una calidad suficiente, las cámaras congelan el movimiento mediante el uso de obturadores electrónicos de alta velocidad que se combinan con una iluminación adecuada, ya que a medida que aumenta la velocidad de obturación es muy importante aumentar también la intensidad de la iluminación para evitar la subexposición. Por otra parte, las actuales cámaras de escaneado progresivo producen imágenes no entrelazadas, que evitan los problemas relacionados con el desplazamiento de los objetos que presentan las imágenes entrelazadas.

Respecto del transporte del producto, con el fin de inspeccionar toda la superficie, la solución más habitual consiste en hacerlo rotar sobre sí mismo justo cuando pasa por debajo de la cámara. Otras soluciones usan espejos y en otros casos se utilizan varias cámaras que adquieren diferentes imágenes desde distintos puntos de vista. Dependiendo del tamaño que tiene el objeto que se inspecciona y de la resolución necesaria, cada imagen puede estar compuesta por un único objeto o por un grupo de ellos. En este último caso, la posición de cada uno debe ser conocida y registrada, ya que un sistema de clasificación normalmente separa físicamente cada objeto de acuerdo con la decisión tomada por el sistema de visión por computador y por ello debe existir un sincronismo muy preciso entre el paso de la fruta, la adquisición de la imagen y el seguimiento del producto hasta su clasificación.

Con el fin de lograr operar en tiempo real, el procesamiento de las imágenes debe ser muy rápido. Por esta razón, algunos autores han utilizado hardware específico para minimizar el tiempo de procesamiento. Por ejemplo, Aleixos et al. (2002) desarrollaron un sistema multiespectral capaz de adquirir dos imágenes simultáneamente (RGB y NIR) de la misma escena en una línea de inspección de cítricos. Los algoritmos de procesamiento de imágenes se paralelizaron e implementaron en dos DSP para lograr un análisis simultáneo: el color y el tamaño por una parte y la presencia de daños por otra. Los datos obtenidos del análisis de las imágenes se analizaban mediante un análisis discriminante no lineal, tomando como variables las características de color (RGB), tamaño y defectos. Los autores demostraron que el sistema era capaz de clasificar correctamente limones y mandarinas a una velocidad de 10 frutos por segundo.

Los sistemas de inspección automática de manzanas en tiempo real han recibido mucho interés debido a la gran importancia económica de este producto. Leemans y Destain (2004) presentaron un prototipo que era capaz de adquirir imágenes de toda la superficie de manzanas transportadas sobre rodillos giratorios. La velocidad de rotación de los rodillos se ajustó de tal manera que un objeto esférico con un diámetro de 72 mm completaba una rotación en cuatro imágenes, adquiriendo imágenes a una velocidad de 11 imágenes por segundo. Tras la segmentación de la imagen, los defectos se detectaron analizando 16 características que describen su color, forma, textura y posición. El éxito en la clasificación fue del 73 %, siendo los errores debidos en su mayoría a la confusión entre defectos y cáliz. Bennedsen y Peterson (2005a) desarrollaron un sistema que adquiría seis imágenes desde distintos puntos de vista de cada manzana. En un trabajo más reciente, Xiaobo et al., (2010) describen el uso de tres cámaras de color para inspeccionar manzanas mientras rotan, y las clasifican en dos categorías (aceptada o rechazada) en función de la presencia de defectos. Las tres cámaras trabajan simultáneamente para capturar tres puntos de vista diferentes de la fruta. Reese et al. (2010) utilizaron espejos parabólicos para adquirir imágenes de escenas que contienen el objeto y su reflejo en los espejos, que muestran partes de los frutos que permanecen ocultas a la cámara.

Al-Mallahi et al. (2010) desarrollaron un sistema de visión por computador para la clasificación automática de patatas mediante UVFL. El objetivo era discriminar patatas sanas de otros objetos no deseados, como piedras o trozos de plástico, mediante el análisis de tan sólo una imagen por cada patata. Procesando una imagen cada 94 ms alcanzaron una tasa de éxito del 98 % en la detección de las patatas sanas.

La Tabla 1.2 resume los trabajos más recientes relacionados con sistemas de inspección de productos hortofrutícolas en tiempo real.

Tabla 1.2. Sistemas de inspección de frutas y verduras en tiempo real mediante visión por computador

Producto	Sistema de imagen	Aplicación (Técnica)	Referencia
Manzanas	Cámara 3 CCDs, Tubos fluorescentes	Defectos (crecimiento de regiones, código de cadena)	Xiaobo et al. (2010)
Manzanas	Cámara CCD	Defectos (umbralización, ANN, PCA)	Bennedsen y Peterson (2005a)
Manzanas	Cámara CCD	Defectos (umbralización)	Bennedsen et al. (2005b)
Manzanas	Cámara digital con filtros interferométricos, LED difusos de visible y NIR	Tamaño (área, diámetros mayor y menor), Defectos (umbralización)	Throop et al. (2005)
Manzanas	Cámara digital con filtros interferométricos, Tubos fluorescentes difusos	Defectos (umbralización, diferentes clasificadores supervisados y no supervisados)	Unay y Gosselin (2006)

Manzanas	Dos cámaras 3 CCD, Fluorescencia difusa	Color (RGB), Forma (área, perímetro, momento mayor de inercia, relación de los momentos de inercia), textura (desviación típica, RGB), Defectos (<i>k</i> -medias, PCA)	Leemans y Destain (2004)
Cítricos	Multiespectral, Tubos fluorescentes con filtros polarizadores	Color (RGB), Tamaño (diámetro medio), Defectos (LDA bayesiano)	Aleixos et al. (2002)
Naranjas, melocotones, manzanas	Cámara CCD, Tubos fluorescentes con filtros polarizadores	Color (RGB), Tamaño (diámetro ecuatorial), Defectos (LDA bayesiano)	Blasco et al. (2003)
Patatas	Cámara UV, Lámparas de reflectancia		Al-Mallahi et al. (2010)
Fresas	Cámara CCD	Color (a^*), Forma (<i>k</i> -medias), Tamaño (diámetro horizontal)	Liming y Yanchao (2010)
Tamarindo dulce	Cámara CCD	Color (a^*), Forma (<i>k</i> -medias), Tamaño (diámetro horizontal)	Jarimopas y Jaisin (2008)

1.6 Discusión

Este apartado ha resumido el estado del arte actual en la inspección de frutas y verduras basada en visión por computador con el objetivo de repasar lo existente y obtener ideas para esta tesis. Las principales conclusiones que se extraen de este repaso se detallan a continuación:

- Uso de nuevas cámaras: Las cámaras hiperespectrales proporcionan una enorme cantidad de información que actualmente está empezando a ser explotada. Por otra parte, los sistemas de adquisición de UV y NIR están disponibles cada vez más fácilmente. Las *smart cameras* o cámaras “inteligentes” que incorporan procesadores de imagen son muy comunes en otros campos de investigación y su uso es probable que se extienda en los próximos años. Las cámaras IP también se incluirán en breve en aplicaciones de supervisión a distancia o en inspección basada en web de procesos agrícolas incluyendo el almacenamiento de frutas y verduras.
- Desarrollo de técnicas de procesamiento de imagen más potentes: El aumento progresivo de la capacidad computacional estimula el desarrollo de software más potente para el procesamiento de imágenes en tiempo real. Los algoritmos adaptativos han dado resultados prometedores en otros campos. Los sistemas de inspección en la agricultura basados en visión por computador deben adaptarse a objetos y circunstancias que cambian constantemente (como tamaño, color o forma del producto

a lo largo de la temporada de cosecha, acumulación de suciedad en las lentes de la cámara, filtros, lámparas, etc.). Los nuevos avances en el reconocimiento de patrones y el procesamiento masivo de datos deben ser incluidos en futuras aplicaciones de visión por computador para aumentar la robustez y precisión de las decisiones.

- Nuevos sistemas de iluminación: La mejora en los resultados del procesamiento de imágenes viene acompañada de un avance en los sistemas de iluminación. Este avance debe ser tanto espectral como espacial, ya que deben ser capaces de cubrir el cada vez mayor espectro analizado de modo uniforme. Los LED suponen un gran salto tecnológico por todo lo que aportan, tanto desde el punto de vista de eficiencia energética como de la gran variedad de soluciones que permiten abordar, especialmente en el caso de aplicaciones de campo.
- Inspección de fruta en campo: Si bien se encuentran en la literatura científica trabajos sobre la aplicación de sistemas de visión por computador en campo, éstos son principalmente orientados hacia la predicción de cosechas o la detección de frutos en el árbol. La selección de fruta en campo debe ir asociada a un modo de recolección automático o asistido y a una mecánica que permita hacerlo, por ello no se han desarrollado trabajos que tratan específicamente este problema.
- Inspección de fruta procesada: Existen todavía pocos trabajos realizados sobre la aplicación de la visión por computador a la inspección de fruta procesada, probablemente debido a su menor interés económico respecto de la fruta en fresco y a la mayor complejidad del procesamiento de estas frutas. Sin embargo, el estado de los actuales sistemas de inspección abre nuevas posibilidades para la creación de algoritmos complejos y robustos capaces de ejecutarse en tiempo real en líneas de inspección. Por ello, es importante comenzar a desarrollar estos algoritmos y a determinar métodos apropiados de toma de decisiones adaptados a los problemas particulares de estas frutas.

2. Motivación y Objetivos

Dentro del proceso de producción cítrica, la recolección es una fase de enorme importancia económica debido a que la que más influye en los costes finales del cultivo (Juste et al., 2000). En España se realiza generalmente de manera manual y supone aproximadamente el 50 % de los costes totales de producción, llegando a ser 10 veces superior al de otros países competidores. La mecanización y automatización de la recolección de los cultivos y de sus tareas asociadas es una forma de reducir los costes de recolección de estos cultivos, ya que es la componente más importante de los costes de producción. Actualmente, la mayor parte de la recolección de los cítricos se realiza manualmente. Los operarios se desplazan alrededor de los árboles con un recipiente, generalmente una caja, provistos de unas tijeras para evitar separar el pedúnculo del fruto. Una vez han llenado la caja, la transportan hasta la zona de carga, normalmente el final de cada línea de cultivo, y cogen una nueva caja. Dos o tres personas se encargan de cargar las cajas en el vehículo que las transporta al almacén. Según un estudio del Departamento de Mecanización Agraria de la UPV (Gracia, 1999) se estima que el tiempo empleado en recoger la naranja del árbol es el triple del correspondiente al proceso de transporte hasta la zona de carga, y éste es el doble que el necesario para la carga y descarga de los envases. Es decir, que estas tres operaciones; recogida, transporte y carga se encuentran en la relación 6:2:1 aproximadamente. Con la incorporación de una plataforma autopropulsada de asistencia a la recolección, se podrían solapar los tiempos de recogida a los de transporte y carga, ya que éstos son realizados de forma automática por la máquina. Los operarios depositan la fruta que van recolectando sobre las cintas transportadoras que soportan los brazos. Un sistema central recoge la fruta de las cintas y la transporta hasta un mecanismo de llenado automático de los recipientes de carga (palots) situado en la parte trasera de la máquina. Los brazos laterales son regulables lo que permite una mejor adaptabilidad a la posición momentánea de los operarios. Estas máquinas incrementan considerablemente los rendimientos de recolección.

Sin embargo, aprovechando las características de estas máquinas, sería muy importante hacer una primera selección en el campo, que actualmente no se realiza, con el fin de desechar las frutas no comercializables y separar aquellas que no poseen la calidad suficiente para su consumo en fresco, pero que pueden aprovecharse por la industria de transformación. De este modo se consigue tanto evitar los costes de manipulación y tratamiento de poscosecha de estas frutas como ahorrar en el transporte de esta fruta al derivarla directamente a la industria de transformación. Esta selección podría consistir en la detección de fruta con un tamaño o forma no comercial, con la presencia de daños externos o con un color que precise cierto tratamiento antes de su consumo final, como ocurre con la fruta de recolección temprana que precisa de procesos de desverdizado en cámaras antes de su comercialización.

- Así pues, como primer objetivo importante dentro de esta tesis, se propone el diseño y construcción de un sistema automático de inspección de fruta basado en visión por computador que se pueda instalar en una plataforma móvil de campo ya desarrollada por una empresa colaboradora. Además de la construcción de dicho sistema, también se pretende el desarrollo de los algoritmos necesarios de análisis de imagen en tiempo real, que tengan en cuenta las particularidades de la inspección en un entorno tan complejo.

Por otra parte, los hábitos de consumo están cambiando y existe una demanda creciente de frutas y verduras de calidad que sean sencillas de preparar y consumir. Los productos de IV gama son productos frescos que se procesan mínimamente, con el objetivo de proveer un alimento listo para consumir y con características similares a los productos frescos enteros. Los consumidores esperan que dichos productos se encuentren libres de defectos, que tengan un grado de madurez óptimo y que posean una elevada calidad organoléptica y nutricional, junto a una garantizada seguridad higiénica. Una manera de alcanzar estas exigencias es creando sistemas objetivos y fiables de control de calidad, capaces de garantizar toda la producción.

Una manera de reducir los costes, aumentar la productividad y garantizar la máxima calidad de un producto agroalimentario consiste en la adecuada automatización de los procesos productivos. Este sector industrial ha experimentado, sobre todo en los últimos cinco años, un profundo proceso de reestructuración, motivado por diversos factores. Por un lado, para satisfacer las exigencias de calidad cada vez mayores del consumidor. Por otro lado, la irrupción en el mercado de países con economías emergentes ha supuesto una dura competencia de precios, haciendo peligrar la continuidad de empresas españolas.

Generalmente, las industrias de procesado de fruta disponen de máquinas que automatizan la mayor parte de los procesos previos. Sin embargo, apenas se ha avanzado en la automatización de la inspección y la clasificación de estos productos. Los sistemas de inspección automática basados en visión por computador se emplean en la clasificación de fruta para consumo en fresco desde hace más de dos décadas y sus prestaciones se están mejorando continuamente. Sin embargo, aunque han existido varios intentos para aplicarlos en la selección de fruta procesada, los intentos han fracasado debido a que:

- el procesamiento en tiempo real de las imágenes obtenidas cuando se emplean equipos de visión por computador pensados para otras aplicaciones, se encuentra con problemas derivados del solapamiento de las piezas y de que éstas se encuentran mojadas.
- no existen en el mercado dispositivos mecánicos que permitan manipular y separar fácilmente estos productos, muy deformables y que se rompen fácilmente.
- el posible mercado de estas máquinas es mucho menor que el de las de fruta en fresco, por lo que no se ha dedicado el mismo esfuerzo en ambos casos.

Esto ha provocado que los fabricantes de tecnología no le hayan prestado atención a este sector, creando una carencia de sistemas automáticos de inspección que ha obligado a los productores a mantener los sistemas manuales tradicionales de selección.

La granada es una fruta apreciada durante siglos por sus usos relacionados con la salud. Recientes investigaciones han demostrado el interés del consumo alimentario de sus frutos por la acción beneficiosa de sus componentes. Los constituyentes principales de su zumo y de los extractos de la piel son los polifenoles, potentes antioxidantes capaces de neutralizar moléculas altamente dañinas para nuestro organismo como son los radicales libres y de minimizar con ello el daño celular y fisiológico que ocasionan. Además, son potencialmente beneficiosos para reducir el riesgo cardiovascular, la hipertensión, la arteriosclerosis y el cáncer. Sin embargo, es una fruta difícil de pelar y, por este motivo, actualmente se consume relativamente poco en comparación con otras frutas. Una solución es la comercialización de los granos (arilos) de las granadas, envasados y listos para el consumo. Esta solución, además de ofrecer un producto novedoso, permite dar salida a las frutas que en la actualidad no se pueden comercializar debido a los daños externos que afectan a su piel, pero que conservan toda su calidad y todas las propiedades nutritivas y organolépticas de los granos.

En cuanto a las mandarinas, España es el primer productor mundial con 2.229.626 de toneladas en la campaña 2008/2009. En torno a 50.000 toneladas de estas mandarinas, en su mayoría *satsumas*, se destinan a la industria de gajos en conserva, dando trabajo directo a más de 2.400 empleados. El valor de la conserva de mandarina se sitúa en 40 millones de euros. De la producción de gajos en conserva, más del 95 % se destina a la exportación. Este tipo de industria se caracteriza por dar un elevado número de empleo, así como un alto valor añadido al producto (Intercitrus, 2009). España y China son los principales países exportadores mundiales de gajos de mandarina. La situación actual del sector español exportador de gajos de mandarina es preocupante, debido al incremento de las exportaciones chinas provocado por la reducción de precios que este país puede permitirse, como consecuencia de los bajos niveles salariales. China ha desplazado la producción española de los importantes mercados estadounidense y alemán, y amenaza con copar las exportaciones al resto de países de la UE, obligando a nuestros productores a ofertar el producto a unos precios que los costes de producción y los salarios pagados en España hacen inviables. De hecho, como consecuencia de esta situación, las exportaciones españolas de gajos de mandarina en conserva han descendido en los últimos años, desde 196.000 toneladas en 1992, hasta las 40.000 toneladas actuales (Intercitrus, 2009), lo que está comprometiendo seriamente el futuro de nuestras empresas y de sus empleos directos.

- El segundo objetivo importante de la tesis es pues contribuir con la creación de sistemas automáticos de inspección y control de la calidad de fruta procesada, basados en visión por computador. No únicamente mediante la creación de algoritmos de análisis de imágenes especialmente diseñados para

resolver este problema, sino también aportando soluciones de ingeniería que permiten manipular, seleccionar y separar el producto en diferentes categorías atendiendo a determinados parámetros de calidad, que se pueden ajustar en función de las necesidades de los productores. En concreto, las investigaciones se han centrado en dos productos de importancia para la Comunidad Valenciana: la mandarina satsuma (*Citrus unshiu*) y la granada (*Punica granatum L.*).

En definitiva, nos encontramos con dos subsectores de la agroindustria diferentes pero con necesidades comunes, cuya automatización ayudaría, por un lado, a optimizar los procesos y reducir los costes de producción, y, por otro, a asegurar la calidad del producto, haciendo más competitivas a nuestras industrias. La visión por computador es una técnica ampliamente extendida para automatizar la inspección y el control de la calidad de las frutas, aunque en los casos expuestos todavía no ha penetrado bien debido a dificultades técnicas, como es el caso de trabajar en el campo, o bien al relativo poco valor económico como es el caso de la fruta procesada frente a la fruta de consumo en fresco. Por ello, esta tesis trata de responder a la pregunta de si es viable crear sistemas para el control automático de la calidad del producto, útiles para sector industrial, capaces de adaptarse a productos y entornos de trabajo complejos ofreciendo soluciones que permitan su posible transferencia a la industria. La forma en la que esta tesis pretende responder es mediante el diseño y desarrollo de sistemas de inspección de la calidad externa del producto no destructivos mediante visión por computador que cubran las necesidades y que ayuden a resolver los problemas planteados por estos dos subsectores.

Para conseguirlo, es necesario, además del diseño de algoritmos específicos de análisis de imágenes, investigar soluciones que se adapten a los entornos de aplicación de este trabajo y que incumben a los sistemas de iluminación, sincronización de la cámara con las salidas de producto, la electrónica asociada y la instalación de los sistemas y todo el equipo en los prototipos creados para realizar la selección automática de la fruta. Los objetivos concretos se detallan en cada uno de los capítulos en los que se divide esta tesis y que describen las diferentes contribuciones realizadas.

2.1 Marco de la tesis

Es importante mencionar que esta tesis ha realizado investigaciones en el marco de diferentes proyectos de investigación. En el caso de la aplicación de la automatización de la recolección de cítricos, las investigaciones de esta tesis se han enmarcado en un proyecto del Centro para el Desarrollo Tecnológico Industrial (CDTI) concedido a la empresa Argilés Diseny i Fabricació, S.L., del que se derivó un convenio de colaboración entre el IVIA y la empresa, y en el proyecto de investigación financiado por el INIA y los fondos europeos FEDER *Desarrollo de nuevas tecnologías de automatización, mecanización y agricultura de precisión aplicadas a la recolección de cítricos* (RTA2009-00118-C02-01). Estos proyectos han implicado a otros grupos de investigación y abarcan la creación de una plataforma móvil de asistencia a la

recolección mecanizada y la creación de sistemas automáticos para la inspección y pesaje de la fruta en línea. La labor de esta tesis dentro del proyecto ha consistido en la parte del diseño y desarrollo de todo el sistema de visión por computador para la selección de la fruta en campo.

En el caso de la fruta procesada, las investigaciones comienzan con el proyecto POMEVAL *Development of novel technologies to yield fresh and processed products extracted from pomegranate fruits*, financiado por la UE (Craft QLK-CT-2001-70537) y tienen su continuidad con tres convenios de colaboración firmados entre el IVIA y la empresa productora de granadas Frutas Mira Hermanos, S.L. En el caso de los gajos de Satsuma, es el INIA el que financia el proyecto de investigación *Desarrollo de un sistema automático para la inspección y clasificación de fruta para conserva; Aplicación a la conserva de gajos de satsuma (RTA03-105)*, que tiene su continuidad con el convenio firmado entre el IVIA y la empresa S&C Visión y Análisis de Imagen, S.L. para el *Diseño y construcción de un sistema automático de inspección automática para fruta mínimamente procesada*. Estos proyectos reciben el apoyo del INIA para transferir las investigaciones realizadas a la industria mediante el proyecto de transferencia de tecnología *Desarrollo de prototipos de tecnología avanzada para la inspección y clasificación automática de fruta procesada mediante visión artificial (TRT2006-00046-00-00)*. En estos proyectos, este trabajo ha incluido parte del diseño de los prototipos a todos los niveles (alimentación, transporte, inspección y separación), así como la creación y desarrollo de todo lo relacionado con los sistemas de visión por computador a nivel de software y hardware.

2.2 Estructura de la memoria

La memoria de la tesis se estructura en capítulos que describen por sí mismos las diferentes contribuciones realizadas en dicha tesis.

El capítulo 1 describe el estado del arte en visión por computador aplicado a la inspección y control de la calidad de frutas y verduras, prestando especial atención a las tecnologías empleadas y a los sistemas capaces de trabajar en línea. Con ello se ha conseguido una visión global del punto de partida y comprendido técnicas y conocimientos que se van a emplear en el desarrollo de la tesis.

El capítulo 2 se centra en la motivación y objetivos de la tesis, explicando el porqué de una tesis como esta, así como los problemas y preguntas que se plantean a priori y como se pretenden abordar.

Los capítulos 3, 4 y 5 describen con detalle las contribuciones realizadas, para crear sistemas de visión por computador para la inspección de fruta en campo en el ámbito de una recolección mecanizada, sistemas de visión por computador para la inspección de arilos de granada y sistemas de visión por computador para la inspección de gajos de mandarina *satsuma*, respectivamente. Cada uno de estos capítulos se estructura como un artículo científico, describiendo la metodología empleada en cada caso,

explicando los logros obtenidos y redactando las conclusiones concretas a las que se llega en cada caso.

El capítulo 6 expresa las principales contribuciones científicas y tecnológicas, y el estado en el que ahora se encuentran estas investigaciones, así como propone algunas líneas de actuación de cara a una continuidad de la línea de investigación.

Por último, el capítulo 7 expresa las conclusiones a las que se ha llegado después de estos años de trabajo e investigación.

3. Nuevas tecnologías para la selección automática de fruta en campo

Resumen

La mecanización y automatización de la recolección de cítricos se considera como una de las mejores alternativas para reducir los costes de producción. Por otra parte, la visión por computador es una tecnología de utilidad demostrada para automatizar la inspección de la calidad de frutas y verduras frescas. Esta tecnología se emplea actualmente en las centrales hortofrutícolas para inspeccionar de manera automática la calidad de la fruta fresca y clasificarla en categorías. Sin embargo, debido a las dificultades que presenta su adaptación al trabajo en campo, se ha utilizado en algunos sistemas robotizados recolectores, aunque no para inspeccionar la fruta recolectada. Realizar algún tipo de inspección antes de que la fruta llegue a las centrales puede aportar muchas ventajas, como por ejemplo facilitar información para su valoración precisa y posterior tratamiento o prevenir el gasto que supone transportar y procesar fruta que no es comercializable. Este capítulo presenta el desarrollo de un sistema de visión por computador especialmente diseñado para trabajar en la inspección de cítricos en campo. Este sistema se instaló en una máquina autopropulsada de asistencia a la recolección de fruta en la que los recolectores depositan la fruta directamente en unas cintas transportadoras. Sobre estas cintas se colocó un sistema de visión por computador que permite inspeccionar la fruta y clasificarla automáticamente según el color, tamaño y presencia de defectos. La máquina presenta un sistema de separación mecánica de la fruta en tres categorías. Se han desarrollado los algoritmos de adquisición y análisis de imagen y, además, debido a las restricciones de consumo de energía se ha creado un sistema de iluminación muy eficiente, un hardware de adquisición y procesamiento de imágenes de muy bajo consumo y se ha diseñado una campana de inspección de dimensiones muy reducidas. El sistema ha funcionado bien en condiciones reales, analizando varias imágenes de cada fruta mientras ésta se desplaza y rota sobre la zona de inspección y clasificándola en tiempo real mientras que la máquina estaba en movimiento en un entorno muy complejo como es el campo.

Palabras clave: recolección automática, plataforma móvil, cámara inteligente, preselección de fruta, cítricos

3.1 Introducción

La recolección de productos en el campo representa del 30 % al 60 % de los costes totales de producción, lo que contribuye en gran medida al precio final del producto (Ruiz-Altisent et al., 2007). Los trabajadores recolectan la fruta del árbol y la depositan en unas mochilas que portan a tal efecto (conocidas como *picking bags*) o directamente en cajas situadas a pie del árbol. Cuando una caja está llena se transporta manualmente hasta una zona desde donde finalmente se carga en camiones o remolques y se transporta a la central hortofrutícola. Esta forma de trabajo es ineficiente y genera tiempos muertos que, finalmente, se traducen en pérdida de rendimiento. La mecanización y automatización de la recolección de cítricos es uno de los enfoques más estudiados para reducir el coste de producción (Jutras y Coppock, 1958), siendo el uso de plataformas móviles una de las soluciones más factibles e investigadas para diferentes tipos de cultivos.

Los sistemas robotizados en agricultura han sido ampliamente estudiados con el objetivo de recolectar de forma automática diferentes frutas y verduras. Edan et al. (2000) proponen una plataforma móvil para detectar y recolectar melones mediante visión por computador, aunque necesita unos 15 segundos para detectar y recolectar cada fruta. Baeten (2008) presentó una máquina recolectora de manzanas que consiste en un brazo robótico capaz de detectar la fruta en el árbol utilizando una cámara CCD y recogerla en aproximadamente 10 segundos. En el campo de los cítricos, Muscato et al. (2005) crearon un sistema autónomo robotizado que puede recolectar a una velocidad de unos 9 segundos por fruto. Este sistema se guía empleando un sistema GPS cargado con una ruta pre-programada. Scarfe et al. (2009) presentaron un recolector robotizado de kiwis basado en una plataforma móvil con varios brazos robóticos que permiten recoger el fruto a gran velocidad y depositarlo en cestas. Entre las desventajas más comunes que suelen presentar estos sistemas caben citar el elevado tiempo necesario para cosechar cada fruta, la pérdida de rendimiento debida a fruta que no puede detectar al estar oculta por las hojas u otras frutas y los daños mecánicos que estos sistemas pueden causar a la fruta o incluso al árbol, como por ejemplo la rotura de las ramas.

Un sistema alternativo a la robótica está basado en plataformas móviles de asistencia a la recolección. La principal diferencia es que no tienen capacidad para recolectar automáticamente, pero sí para facilitar la cosecha manual. Una de las principales ventajas de estas plataformas es que, a la vez que se recolecta, facilitan la realización de diferentes operaciones dirigidas a reducir los costes de producción, como por ejemplo la inspección del producto. Los sistemas de visión por computador se han desarrollado en gran medida para la evaluación automática de frutas y hortalizas frescas en línea, como por ejemplo cítricos (Aleixos et al., 2002), manzanas (Unay y Gosselin, 2006) o patatas (Al-Mallahi, 2010). En el caso de esta tesis, se ha desarrollado un sistema automático de visión por computador para trabajar sobre una plataforma móvil de recolección y que permite, por ejemplo, detectar al instante fruta

que no cumple con los estándares mínimos de calidad programados, ya sea por tamaño, color o presencia de defectos. Esta fruta, cuando se recolecta, se envía directamente a cooperativas o almacenes en los que, en muchos de los casos, la fruta se procesa en las líneas de confección donde se lava, encera y trata con fungicidas. Junto con la fruta de calidad adecuada, también llega otra fruta que por su tamaño o por la presencia de defectos superficiales finalmente se descarta y envía a la industria de transformación. Si esta fruta se detecta y descarta directamente en el campo antes de llegar al almacén, se podrían ahorrar todas estas operaciones, lo que se traduciría en beneficios directos tanto económicos como medioambientales. En otros casos, el conocimiento precoz de la calidad de la fruta que entra en los almacenes puede ser utilizado para determinar su precio con mayor precisión o para determinar de manera anticipada la necesidad de algunos tratamientos, como es el caso del desverdizado en mandarinas.

Esta tesis aborda el desarrollo de este sistema basado en visión por computador para una plataforma móvil de asistencia a la recolección, que presenta unas claras diferencias respecto a los típicos sistemas para la inspección de fruta fresca. Estas diferencias están relacionadas con el consumo energético, ya que la plataforma es autopropulsada y todo el sistema se tiene que alimentar de una batería de 12 V, y con el tamaño del sistema completo, ya que, como se detallará en el apartado siguiente, las dimensiones de la plataforma son ya de por sí considerables y existen límites en cuanto a la altura total que puede alcanzar. Por lo tanto, se ha diseñado y construido una campana de inspección de reducido tamaño, un sistema de iluminación de bajo consumo basado en LED, dos configuraciones de visión por computador, una que consiste en una adaptación del sistema típico utilizado en las líneas de inspección y clasificación actuales y el otro más novedoso basado en una cámara inteligente, así como todo el software necesario de análisis e inspección de frutas en tiempo real.

El trabajo desarrollado en esta tesis parte de una máquina de ayuda a la recolección previamente construida por lo que se imponen ciertas restricciones al diseño del sistema de inspección a desarrollar. El Anexo I detalla una completa descripción de esta máquina.

3.2 Objetivos

El objetivo de esta parte de la tesis es el desarrollo de un sistema de visión por computador específicamente diseñado para trabajar en campo y que pudiera funcionar sobre la plataforma autónoma móvil de recolección de cítricos detallada anteriormente. El sistema debe ser capaz de inspeccionar el tamaño, color y defectos de los cítricos a una velocidad de ocho frutas por segundo desplazándose sobre una línea doble. Se debe montar sobre una plataforma autopropulsada y que suministra energía únicamente a través de su batería siendo éste un factor crítico a tener en cuenta. Por lo tanto, partiendo de la máquina previamente construida, se deben cumplir varios requisitos que son los que fijan los objetivos de este capítulo:

- Desarrollar una campana de inspección de reducidas dimensiones. Puesto que se debe colocar en la parte superior de la plataforma, se debe aumentar lo menos posible la altura total de la máquina.
- Desarrollar un sistema de iluminación uniforme, robusto y eficiente. Resulta muy importante minimizar el uso de energía porque la suministra la propia máquina mediante una batería de 12 V. Por otro lado, es muy importante que sea robusto, soporte las condiciones de campo y permita un mantenimiento sencillo. Y todo ello proporcionando una iluminación uniforme de toda la escena.
- Desarrollar software para la adquisición y procesamiento de las imágenes de la fruta en tiempo real, lo que incluye el desarrollo de algoritmos para la segmentación de las imágenes, extracción de características de la fruta y toma de decisiones. El sistema debe clasificar y separar el fruto de forma fiable en el campo en tres categorías posibles, dependiendo del tamaño, el color o la presencia de defectos externos.
- Para facilitar las pruebas de todo el sistema hay que desarrollar una interfaz amigable que permita a un operador tanto entrenar el sistema como también ajustar los parámetros del procesamiento y los algoritmos de decisión.
- El sistema debe ser capaz de trabajar en condiciones de campo sobre una plataforma que se está moviendo continuamente.

3.3 Creación del sistema de visión

3.3.1 Diseño de la campana de inspección

En un diseño tradicional como el que se utiliza habitualmente en las máquinas de inspección de las empresas de procesado de fruta, la cámara se encuentra en posición cenital respecto de la escena, lo que conlleva aparejada una estructura de aproximadamente un metro sobre la máquina que tiene 3230 mm de alto. Esta máquina, además, deberá ser transportada por carretera y guardada en un almacén, por lo que, en este caso, la campana de inspección se debe poder desmontar fácilmente lo que introduce nuevos condicionantes en el diseño y montaje, especialmente de conexiones, soportes y reglajes unido a lo complicado que resulta manejar la cámara a esa altura (Figura 3.1).

Respecto del transporte por carretera, según indica la legislación vigente (BOE, 2010), la altura máxima permitida en el transporte de mercancías (incluido el vehículo de transporte) está establecido en 4 m de altura por lo que hay que tener en cuenta este dato a la hora de diseñar la campana de inspección para esta aplicación para no superar esta altura. Se trata pues de realizar un nuevo diseño evitando la configuración tradicional, para lo cual se llevó a cabo un estudio de las características que debe cumplir el sistema de visión.



Figura 3.1. Máquina con la cámara orientada verticalmente

3.3.1.1 Diseño y configuración de la estructura del sistema de visión

Según las leyes de la reflexión, cuando la luz llega a la superficie de un cuerpo, ésta se refleja parcial o totalmente en todas direcciones. Si la superficie es especular, los rayos se reflejan en una sola dirección. En el caso de los espejos planos, el ángulo del rayo de luz incidente respecto de la dirección normal del plano de reflexión es exactamente igual que el ángulo que forman el rayo reflejado y la normal del plano del espejo (Figura 3.2). Además, el rayo incidente, la normal y el ángulo reflejado deben estar situados en un mismo plano (Foley et al., 1996).




Figura 3.2. Ley de reflexión para espejos planos

Basándonos en esta ley, se puede interponer un espejo entre los objetos y la cámara sin alterar la escena, simplemente haciendo coincidir ambos ángulos. Para conseguirlo, es necesario diseñar una estructura que mantenga la cámara con un cierto ángulo de incidencia sobre el espejo y que sea igual al ángulo de reflexión entre los objetos y el espejo. Aparentemente, la estructura puede parecer compleja, pero si se parte de unos soportes completamente paralelos a la escena, puede ser incluso más sencilla. Si elegimos como ángulo de incidencia y de reflexión 45° , conseguimos que la cámara se encuentre paralela a la escena y a los soportes de la máquina.

La imagen formada utilizando esta técnica es simétrica a la real siempre que sumando la distancia de los objetos y de la cámara al espejo sea la misma que la distancia entre la cámara y los objetos sin utilizar el espejo. Además, los objetos de la imagen reflejada conservan el tamaño del objeto real y su orientación. Por tanto, se ha utilizado un espejo situado a 45° del plano de la escena y orientado hacia la cámara que se sitúa en paralelo a la escena, como se observa en la Figura 3.3.

El tamaño del espejo depende de la posición que ocupa entre la escena y la cámara. Es más, la posición de ambos está relacionada ya que la distancia desde la óptica a la escena deberá ser siempre la misma para capturar los mismos objetos y con el mismo tamaño. En la Figura 3.3 se observa como la distancia entre la cámara y el espejo es d_1 y la distancia entre el espejo y los objetos es d_2 . La suma de estos dos valores coincide con la distancia que debería haber entre la óptica y los objetos sin utilizar el espejo. Por tanto, siempre que la suma de los dos valores coincida con la distancia desde el sensor a los objetos, es posible situar la cámara a mayor o menor altura. Eso sí, el centro del espejo debe situarse en la vertical del centro de la escena y a su vez en la horizontal del centro de la cámara.




Figura 3.3. Espejo a 45°

El tamaño del espejo depende de la altura a la que se sitúe. Si el espejo se sitúa muy cerca de la cámara, su tamaño será menor, pero la cámara deberá estar situada a mayor altura por lo que la altura total de la estructura se reduce relativamente poco (Figura 3.4a). Sin embargo, si el espejo se sitúa cerca de los objetos, su tamaño será mayor que el de la propia escena, pero la cámara se podrá situar a escasa altura, por lo que la altura total de la estructura sería sustancialmente menor (Figura 3.4b).

Este segundo caso es preferible para disminuir la altura total de la estructura. Por tanto, la solución óptima pasa por situar el espejo lo más cerca posible de la escena. La estructura necesaria para sujetar el espejo debe asegurar que éste se encuentre a 45° exactos entre la cámara y la escena, condición necesaria para evitar defectos de perspectiva en la imagen. Además, debe ser lo suficientemente firme para que no se mueva ni vibre. También se debe poder ajustar su posición a lo largo de la zona de rodillos. Lo que es aconsejable es que la altura del espejo sobre la escena sea lo menor posible y que se permita ajustar la distancia entre la cámara y el espejo.




Figura 3.4. Diferentes configuraciones del espejo situado entre la escena y la cámara

La estructura de la cámara se debe poder desplazar a lo largo de la zona de rodillos para ajustar la distancia a la que se encuentra la cámara del espejo. Asimismo, es importante permitir ajustes en altura y anchura para adecuarse a la posición exacta del espejo. Esta estructura debe ser lo suficientemente rígida para evitar vibraciones ya que, en caso de producirse, la imagen puede salir borrosa.

Para la realización de los diseños de las estructuras se ha utilizado el software de diseño paramétrico, análisis y fabricación CAD/CAE/CAM de Siemens PLM, UNIGRAPHICS, concretamente la versión NX6.0.

Inicialmente se diseñaron y construyeron dos estructuras independientes, una para el espejo y otra para la cámara (Figura 3.5), sin embargo esta solución no resultó ser muy robusta respecto de las vibraciones de la máquina, además que resulta complicado alinear correctamente el espejo respecto de la cámara y la escena.




Figura 3.5. Diseños iniciales de los soportes del espejo (izquierda) y la cámara (derecha)

Partiendo de este diseño, se observó que lo más conveniente es situar en una misma estructura el espejo y la cámara, de forma que ambas partes formen un conjunto (Figura 3.6), con la ventaja que se puede desmontar sin mover ningún reglaje, además de simplificar los anclajes necesarios sobre la máquina.




Figura 3.6. Diseño inicial de la estructura conjunta de la cámara y el espejo

El diseño definitivo que se ha realizado de la estructura (Figura 3.7) permite ajustar la separación de los laterales al ancho de la zona de inspección, aumentando los apoyos de la cámara y haciendo que se necesite menos material, con el consiguiente ahorro en peso y coste. Resulta muy importante destacar que con este diseño es posible ajustar la cámara respecto del espejo tanto en altura como en distancia, para conseguir un enfoque lo más ajustado posible a las dimensiones de la escena a inspeccionar. Además también se puede desplazar todo el conjunto a lo largo de la zona de rodillos para conseguir una correcta alineación de la fruta con el inicio de la imagen y evitar adquirir imágenes de frutas no completas.

Como se observa en la Figura 3.6 y en la Figura 3.7 correspondientes a los diseños de las estructuras, ha sido muy importante realizar el modelo 3D de la zona de la máquina donde se ubicará el sistema de visión para ajustar todas las dimensiones antes de pasar al proceso de montaje definitivo.




Figura 3.7. Diseño definitivo de la estructura de la cámara y el espejo

La Figura 3.8 muestra dos vistas diferentes del diseño del ensamblaje del espejo con la cámara (arriba) y su montaje final siguiendo tal diseño (abajo).




Figura 3.8. Estructura espejo y cámara ensamblada

La estructura creada mide únicamente 310 mm de alto, y aproximadamente 700 mm de largo, aunque esta última medida no se considera tan importante porque no aumenta las dimensiones totales de la máquina y la zona está libre para poderla situar. Eso sí, el largo total de la estructura dependerá sobre todo de la distancia a la que se sitúe la cámara.

Además hay que dotar la zona de inspección de un entorno o cubierta que aisle la escena de luz exterior y suciedad, y que albergue en su interior los elementos necesarios para la inspección como la estructura ensamblada de espejo-cámara y la iluminación. La cubierta creada tan solo tiene 2 cm más de alto que la estructura, es decir, 330 mm, y se ajusta al perfil del espejo para disminuir la altura total de la máquina una vez esté situada en su posición.

La máquina mide 3230 mm de alto, a los que habría que sumar el alto de la campana (330 mm), que al estar inclinada por su parte frontal, únicamente aumenta la altura total de la máquina en 250 mm, por lo que se cumple uno de los principales objetivos, que el sistema tenga la menor altura posible. Otro de los requisitos importantes que cumple este diseño es que la estructura es ligera y se puede montar y desmontar con facilidad. Para facilitar esta labor, cuenta con asideros que permiten manejar mejor la estructura, sobre todo cuando se manipula en la parte superior de la máquina. El diseño final de toda la zona de inspección se puede observar en la Figura 3.9a, mientras que la Figura 3.9b muestra la escena y su imagen reflejada en el espejo. Para evitar posibles problemas con la temperatura en el interior de la campana se han

practicado dos orificios en la parte superior trasera en los que se han instalado dos ventiladores que fuerzan la extracción de aire caliente, con una visera para su protección.




Figura 3.9. a) Diseño completo de la zona de inspección; b) Interior de la zona de inspección

3.3.2 Diseño del sistema de adquisición de imágenes

3.3.2.1 Análisis de la escena

El objetivo es conseguir un sistema que sea capaz de capturar imágenes que representen el color de las frutas con la mayor fidelidad posible. Esta información se empleará para estimar el color promedio de la piel, el calibre y la presencia de defectos y daños superficiales. Además, es importante hacer un diseño que permita la inspección de varias frutas de manera simultánea y en tiempo real mientras se desplazan. Como ya se describió, la fruta va alineada en dos filas (carriles) y rota mientras se transporta por debajo de la cámara para adquirir imágenes de la mayor parte de la superficie de la fruta. Desde que entra en la escena hasta que sale de la misma, la fruta debe dar teóricamente una vuelta completa, siendo la velocidad de avance y rotación de la fruta variable. De partida, la máquina funciona a una velocidad máxima de avance de 8 frutas por segundo (cuatro por cada carril). Es importante que la zona de inspección se encuentre despejada en su parte superior para que ningún elemento interfiera entre la escena, la iluminación y la cámara. En la Figura 3.10 se observa el modelo de cómo es la zona de inspección por la que pasará la fruta alineada en dos carriles y rotando a su vez.




Figura 3.10. Zona de inspección

Para fijar correctamente todos los elementos del sistema de visión, se diseñaron unos soportes fijados a los dos laterales de la zona de inspección. Éstos deben estar sujetos fuertemente al chasis principal de la máquina para reducir el impacto de las vibraciones, y además poseen una superficie plana en la parte superior para sujetar correcta y fuertemente la estructura de iluminación, la de soporte de la cámara y la cubierta.

Antes de decidir qué tipo de iluminación, cámara y óptica se van a emplear, es muy importante calcular qué tamaño tendrá la escena que se debe inspeccionar. El tamaño de la escena repercutirá en la distancia de la cámara a la fruta, aunque como se verá a continuación, eligiendo una óptica u otra se podrá alterar también dicha distancia. La única restricción previa desde la que se parte es la proporción de las imágenes, que está definida por el sensor de la cámara. Habitualmente, las cámaras de vídeo industriales basadas en sensores matriciales tienen una proporción 4:3 (ancho:alto), por lo que es necesario ajustarse a esta proporción para maximizar el contenido de la escena. Sin embargo, lo que sí es configurable es la orientación transversal o longitudinal de la cámara respecto del sentido de avance de la fruta. En la Figura 3.11 se comparan las dos configuraciones posibles, intentando conseguir siempre que en la mayor parte de la escena aparezcan los objetos a analizar y evitar así zonas sin información importante.

La separación entre dos rodillos, o lo que es lo mismo, desde el centro de una fruta al centro de la siguiente viene dada y es de 95 mm. Los dos carriles por los que pasará la fruta están separados de centro a centro 184 mm. Entre los laterales de la zona de inspección, por donde pasan los rodillos, se estima una distancia de 295 mm. En la Figura 3.11 se observa cómo varía la escena en función de la orientación de la cámara, la distancia focal y la distancia entre los laterales de la máquina. Esa medida de aproximadamente 290 mm marca la referencia en cualquiera de las configuraciones.

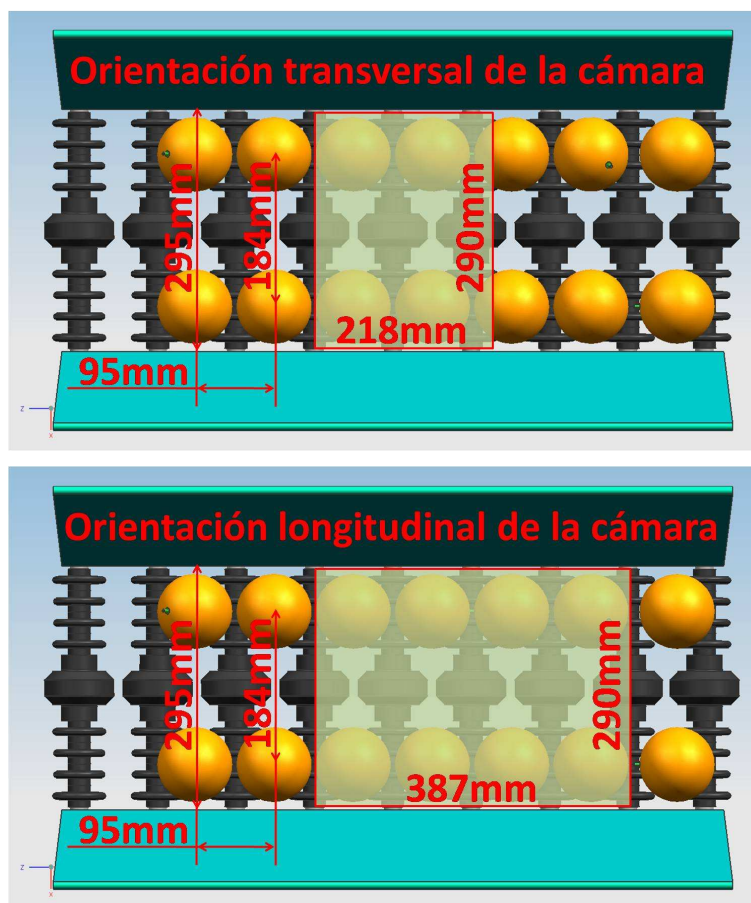


Figura 3.11. Orientación transversal vs. longitudinal de la cámara

Ambas configuraciones tienen ventajas e inconvenientes. Si se sitúa la cámara en sentido transversal al avance de la fruta (Figura 3.11 superior), se puede tomar una imagen desde menor distancia lo que implica que, para las mismas dimensiones de la escena, se obtenga una mayor resolución, por lo que el análisis será más preciso. Como se observa en la Figura 3.11 (inferior), si se sitúa la cámara en sentido longitudinal, ésta deberá encontrarse a mayor distancia ya que la escena es mayor, y las frutas serán capturadas con prácticamente la mitad de resolución. Por el contrario se tiene la ventaja de que en una misma imagen se pueden analizar el doble de frutas que con la configuración anterior, lo que hará necesarias menos fotos para cubrir todas las frutas.

Partiendo de la velocidad máxima a la que puede funcionar la máquina de 8 frutas por segundo (cuatro frutas por segundo y carril) y teniendo en cuenta la separación de 95 mm entre dos rodillos consecutivos, la velocidad de avance de la cinta transportadora

debe ser de 380 mm/s. Los requisitos en cuanto a la velocidad de procesamiento dependerán del número de imágenes que se desean adquirir de cada fruta. Cuantas más imágenes se tomen, más preciso será el análisis. Para analizar las imágenes se dispone de 285 mm en el caso de la configuración longitudinal y de 123 mm en el caso de la configuración transversal. Estos números son el resultado de sustraer al tamaño de la escena la distancia entre dos rodillos, asumiendo que la mitad de cada rodillo por delante y por detrás de la imagen está fuera del campo de visión de la cámara ya que la fruta está entrando o saliendo de la imagen.

Así pues, una fruta permanece dentro de la escena durante 750 ms en el caso de la configuración longitudinal y de 323 ms en el caso de la configuración transversal. Asumiendo que se necesite adquirir un total de cuatro imágenes de cada fruta para observar su superficie completa, se dispone de un tiempo máximo de $750/4 = 187,5$ ms y $323/4 = 80,75$ ms respectivamente para analizar cada imagen. Teniendo en cuenta que habitualmente las cámaras necesitan para adquirir una imagen 40 ms, para cumplir estos requerimientos temporales, los tiempos obtenidos tendrían que rebajarse al múltiplo de 40 ms inferior, o sea, 160 ms y 80 ms, lo que implicaría una frecuencia por segundo de adquisición de imágenes de 6,25 y 12,5 para cada configuración. La Tabla 3.1 muestra los tiempos máximos de procesamiento (en milisegundos) requeridos para las dos configuraciones teniendo en cuenta diferentes parámetros de velocidad y número de imágenes a adquirir de cada fruta. Hay que tener en cuenta que el tiempo de procesamiento incluye el de su adquisición, que como ya se ha dicho es de 40 ms, por tanto una imagen no se puede procesar en menos de 40 ms.

Tabla 3.1. Tiempo máximo de procesado para cada imagen en función del número de imágenes adquiridas de cada fruta y el número de frutas por segundo a inspeccionar.

		Imágenes analizadas de cada fruta										
	frutas/s	1	2	3	4	5	6	7	8	9	10	11
Trans.	8	720	360	240	160	120	120	80	80	80	40	40
	6	1000	480	320	240	200	160	120	120	80	80	80
	4	1480	720	480	360	280	240	200	160	160	120	
Long.	8	320	160	80	80	40	40	40	40	-	-	-
	6	400	200	120	80	80	40	40	40	40	40	-
	4	640	320	200	160	120	80	80	80	40	40	40

Para este trabajo se ha considerado más adecuada la configuración de la cámara en sentido longitudinal al avance de la fruta, ya que cubre más espacio en cada foto, lo que implica reducir tiempos en la realización de las fotos, envío de las imágenes al PC y procesamiento. Además existe una limitación mecánica debido a la necesidad de rotar la fruta una vuelta completa mientras está dentro de la escena. En la configuración longitudinal, esta rotación se tiene que efectuar en 750 ms mientras que en la segunda en apenas 323 ms lo que, debido a la alta velocidad de rotación, provoca saltos en la fruta que perjudican la adquisición y un posterior análisis de las imágenes. Como principal desventaja, la cámara deberá estar un poco más alejada de la escena por lo que la precisión se ve reducida.

3.3.2.2 Cámaras y ópticas empleadas

Para adquirir las imágenes se ha experimentado con dos sistemas distintos. La primera aproximación consiste en la adaptación natural de un sistema de inspección típico compuesto por una cámara estándar conectada a un ordenador, mientras que la segunda y más novedosa presenta la incorporación de una cámara inteligente con capacidad de procesamiento. Este tipo de cámaras inteligentes permiten capturar y procesar las imágenes en la misma cámara, sin necesidad de un ordenador. Esto presenta algunas ventajas, como por ejemplo la posibilidad de alimentar todo el sistema con corriente continua a 12 Vcc (como el resto de la máquina), evitando la necesidad de usar corriente alterna a 220 Vac, lo que simplifica considerablemente la instalación y reduce el consumo energético. Por el contrario, su capacidad de procesamiento es enormemente inferior a la de un ordenador personal, lo que obliga a realizar algoritmos más optimizados y renunciar a la obtención de algunos resultados al no poder alcanzar el rendimiento deseado. Ante las ventajas e inconvenientes de ambas, se decidió investigar las dos soluciones.

Para la primera aproximación se ha empleado una cámara de color y muestro progresivo de la marca JAI, modelo CV-M77 con salida de video en formato RGB, capaz de adquirir hasta 25 imágenes por segundo. Esta cámara cuenta con un sensor de 1/3" de una resolución de 1028 x 770 píxeles. Tiene sincronización mediante disparo externo y velocidades de obturación programables hasta 1/10000 s. Para adquirir imágenes con esta cámara es necesario utilizar una tarjeta digitalizadora de imágenes instalada en el PC. La tarjeta de digitalización utilizada para este trabajo ha sido una CORECO (PC-RGB) con interfaz PCI que dispone, entre otras características, de una entrada de disparo opto-acoplada (inmune a interferencias electromagnéticas) y una salida de activación de iluminación. Posteriormente se comprobará la importancia de ambas señales para la adquisición de las imágenes. Se ha utilizado esta cámara y tarjeta de digitalización por su disponibilidad y experiencia en su manejo, y porque se adaptaba completamente a los requerimientos necesarios para lograr los objetivos.

Para la colocación de la cámara sobre la estructura creada, se deben tener en cuenta distintos parámetros, como la orientación de la misma, el tamaño de la escena, la distancia desde el sensor de la cámara hasta el objeto o la óptica que se utilizará. Como ya se comentó anteriormente se ha decidido utilizar la cámara con orientación longitudinal por lo que el tamaño de la escena queda definido en 387 mm x 290 mm. La distancia desde el sensor de la cámara hasta la fruta depende principalmente de la óptica a utilizar, como se verá posteriormente, aunque la estructura creada permite ajustar dicha distancia hasta adecuarse al tamaño de la escena.

La segunda aproximación consiste en el uso de una *smart camera* o cámara inteligente. En este caso se ha escogido una de muestro progresivo en color de la marca SONY (XCI-SX100C/XP), capaz de adquirir hasta 30 imágenes por segundo en formato RGB. Esta cámara cuenta con un sensor CCD de 1/3" que tiene una

resolución de 1280 x 960 píxeles. Además de adquirir las imágenes, la propia cámara es capaz de analizarlas debido a que cuenta con un procesador VIA Eden ULV a 1 GHz y 512 MB de memoria RAM, que hacen funcionar un sistema operativo Windows XP Embedded. Otra característica importante que posee es la salida para activar la iluminación, así como una entrada que permite el disparo externo y la posibilidad de utilizar distintas velocidades de obturación que van desde los 2 s hasta 1/100000 s. También cuenta con múltiples opciones de comunicación como son un puerto serie RS-232C, otro Giga-Ethernet, dos USB 2.0 y varias entradas/salidas digitales. Incluso posee una salida de vídeo que nos permite conectar un monitor para facilitar las labores de configuración y ajuste de los parámetros. Y todo ello alimentado con corriente continua entre 10,5 y 26,4 Vcc con un consumo máximo de 18,2 W. Esta cámara se consideró la más adecuada para su utilización en este trabajo por tratarse de uno de los modelos con mayor potencia de procesamiento del mercado en el momento en que se adquirió y porque cumplía con los requerimientos necesarios.

Como se ha comentado anteriormente, para la colocación de la cámara se deben tener en cuenta distintos parámetros, como el tamaño de la escena, la distancia desde el sensor de la cámara hasta el objeto o la óptica que se utilizará. La distancia D desde el sensor de la cámara hasta el objeto depende del tamaño de la escena (*largo x ancho*) a capturar y de la distancia focal f del objetivo que se utilice, y se puede calcular mediante la Ecuación 3.1 (Cox, 1979), válida para cámaras con sensores de tamaño 1/3", como son las dos utilizadas en este trabajo.

$$D = \text{mayor} \left[\text{largo} * \left(\frac{f}{4,8} \right), \quad \text{ancho} * \left(\frac{f}{3,6} \right) \right] \quad (3.1)$$

La distancia focal (f) influye en el ángulo de visión. A menor f mayor es el ángulo de visión y más cerca podrá estar la cámara de la escena. Sin embargo, las ópticas con gran angular pueden provocar aberraciones en la imagen como, por ejemplo, el efecto barril, por lo que su uso es desaconsejable en muchas aplicaciones de visión por computador. Por el contrario, los teleobjetivos necesitan que las distancias entre la cámara y el objeto sean muy grandes por lo que también complican su utilización en labores de inspección. Para inspeccionar la escena establecida de 387 mm x 290 mm, se puede observar en la Tabla 3.2 la distancia a la que se debe situar la cámara dependiendo de la óptica que se utilice.

Se ha considerado que la óptica más aconsejable para utilizar en este trabajo es una estándar de focal fija de 8 mm, lo que implica, según la Tabla 3.2, tener que situar el sensor y ajustar el enfoque a 645 mm de la escena, completamente viable sobre la estructura creada. Como se ha explicado anteriormente, la altura de la cámara depende de la óptica que se utilice. Como se observa en la tabla, una óptica de estándar de 8 mm se debe situar a una distancia desde el sensor hasta los objetos de 645 mm para adquirir la escena necesaria, a los que hay que sumar unos 250 mm del cuerpo de la cámara y los cables, por lo que la altura del conjunto puede alcanzar los 900 mm. Sin

embargo, merced al diseño en espejo propuesto, esta distancia de 900 mm se va a dividir en dos tramos, vertical y horizontal como se ha explicado en el punto anterior.

Tabla 3.2. Comparativa de ópticas

Tipo óptica	Focal (mm)	Ángulo visión	Distancia cámara-objeto (mm)
Gran angular	4	64°	323
	6	47°	484
Estándar	8	35°	645
	12	29°	968
Tele objetivo	16	18°	1290

3.3.2.3 Ajustes de las cámaras

La captura de una imagen comienza en el momento en el que la tarjeta de adquisición de imágenes o la cámara inteligente reciben una señal externa proveniente del autómatas que gobierna la máquina. Esta señal es conocida como *trigger* o señal de disparo. El autómatas recibe pulsos del codificador, que proporciona exactamente 128 pulsos entre cada paso de los rodillos. Por lo tanto, asumiendo que en cada imagen hay exactamente cuatro frutas (rodillos) por cada carril, para capturar una única imagen de cada fruta, se ha sincronizado el disparo de la cámara cada $128 \times 4 = 512$ pulsos del codificador. Sin embargo, como ya se ha comentado anteriormente, para cubrir un mayor porcentaje de su superficie es necesario capturar y analizar varias imágenes de una misma fruta en distintas posiciones mientras se traslada rotando sobre sí misma. De este modo, para capturar cuatro imágenes de cada fruta, el autómatas deberá enviar una señal de disparo a la tarjeta de adquisición de imágenes cada 128 pulsos, lo que significa que se adquiere una imagen en cada paso de los rodillos.

Otro de los parámetros importantes en la adquisición de imágenes en movimiento es el tiempo de exposición del sensor de la cámara regulado por el *shutter*. Este periodo de tiempo es el que transcurre mientras el sensor está recibiendo luz y formando la imagen, y se expresa en fracciones de segundo. Habitualmente, las cámaras industriales se pueden configurar desde valores lentos de 1/25 s donde el sensor recibe luz durante 40 ms (valor por defecto), hasta valores extremadamente cortos de 1/100000 s en los que se adquiere la imagen durante tan sólo 1 μ s. Eligiendo valores largos de exposición, el sensor recibe luz de la escena durante más tiempo. Éste modo se utiliza para capturar escenas estáticas. Sin embargo, al elegir valores cortos de exposición, el sensor recibe la luz durante menos tiempo por lo que es necesario iluminar la escena con mayor intensidad. Cuanto más corto es el tiempo de exposición, más intensidad lumínica se necesita. Como ventaja, se puede capturar el movimiento con facilidad lo que permite obtener imágenes nítidas que permitirán un buen análisis de los objetos de la imagen.

En este trabajo se ha establecido un tiempo de adquisición de 1/500 s, suficiente para adquirir de forma nítida las imágenes de la fruta a pesar de que se puedan mover a velocidades de alrededor de 4 frutas por segundo y línea. Suponiendo una velocidad

de avance de la línea de 380 mm/s, durante 1/500 s, la fruta se desplaza 0,76 mm durante la adquisición, lo que da una elevada precisión al sistema. Cada fruta se inspeccionará cuatro veces, por lo que la señal de disparo se debe producir cada vez que un nuevo rodillo alcanza una posición fija. Es decir, cada vez que entra por completo una fruta nueva en la escena, como ya se describió anteriormente.

3.3.2.4 Integración de las cámaras en el sistema

La primera aproximación consiste en el empleo de un sistema de inspección típico como el que se puede encontrar en cualquier máquina de inspección mediante visión por computador para la inspección de productos hortofrutícolas. Esto es, una cámara conectada a un ordenador personal mediante una tarjeta de adquisición de imágenes cuyo esquema se muestra en la Figura 3.12. Este sistema, que se ha denominado *Sistema PC*, necesita un inversor de potencia para poder alimentarse de la batería de la máquina. El segundo sistema de inspección que se ha utilizado en este trabajo, llamado *Sistema Inteligente* consiste en la utilización de una cámara con capacidad de procesamiento para realizar todas las tareas inherentes a la inspección y que por lo tanto no necesita estar conectada a un ordenador. La Figura 3.13 muestra el esquema con esta configuración, en el que se aprecia una menor complejidad, además de traducirse en un importante ahorro energético.

Las principales diferencias entre los dos sistemas residen en la alimentación y el número de elementos que lo configuran. Para poder utilizar un PC en una máquina alimentada con baterías de corriente continua es necesario utilizar un inversor de potencia que proporcione corriente alterna necesaria para utilizar la fuente de alimentación estándar del PC. Este inversor de potencia se debe situar en un nuevo cuadro eléctrico protegido lo más cerca posible de la batería y resulta muy ineficiente ya que además del consumo de los equipos, se pierde aproximadamente un 15% más únicamente por la conversión de corriente. Además el PC se debe situar también en un cuadro protegido cerca de la zona de inspección, igual que la placa de control de la iluminación, por lo que el cableado se complica enormemente como se observa en la Figura 3.12. Sin embargo con la segunda solución, es posible situar tanto la cámara como la placa de control de la iluminación en el interior de la campana de inspección, facilitando su montaje y mantenimiento.

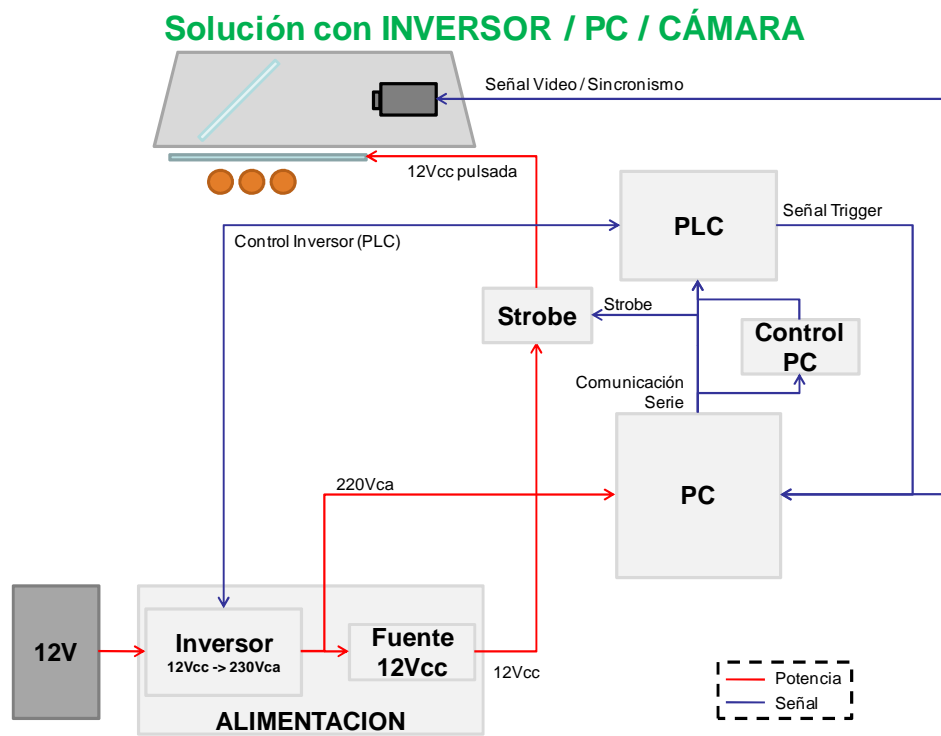


Figura 3.12. Esquema del *Sistema PC*, utilizando ordenador, cámara estándar e inversor de potencia.

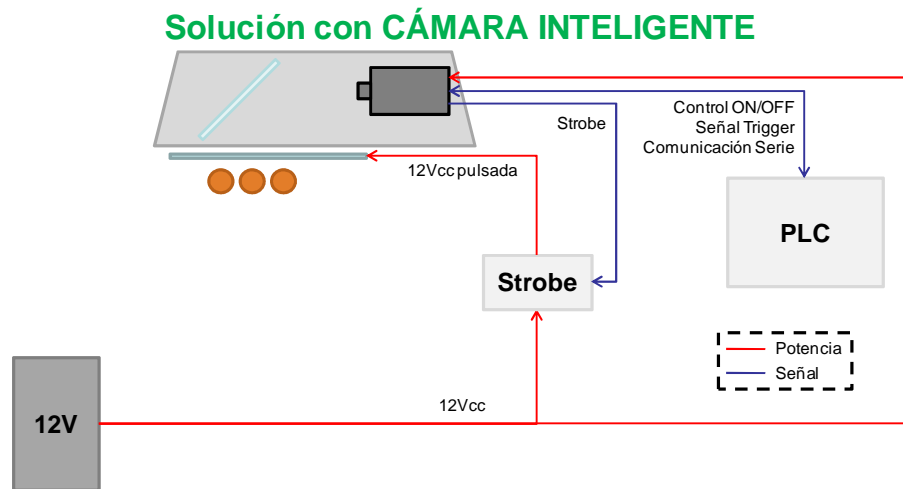


Figura 3.13. Esquema del *Sistema Inteligente*, utilizando una cámara con capacidad de procesamiento propio.

3.3.3 Diseño del sistema de iluminación

3.3.3.1 Tipos y técnicas de iluminación

La iluminación es una de las partes más importantes de cualquier sistema de visión por computador. Del buen diseño del sistema de iluminación dependerá el éxito del sistema automático de inspección. Sin embargo, no hay una forma ideal para iluminar correctamente una escena, ya que la elección depende de varios factores, por lo que deberá ser convenientemente estudiada. En este punto del diseño de un sistema de visión por computador es conveniente pararse y analizar con detenimiento qué tipo y técnica de iluminación se deberá utilizar, qué características tienen los objetos a analizar, y qué distribución espacial deberá haber entre los objetos y las fuentes de luz.

Existen diversos tipos de iluminación atendiendo a las características tanto físicas como químicas del propio emisor de luz. La presencia de lámparas fluorescentes en aplicaciones de visión por computador está muy extendida, ya que presentan la ventaja de la distribución de la luz, que no se encuentra alrededor de una ampolla, sino a lo largo de un tubo normalmente cilíndrico, con un diámetro normalizado y cerrado en sus dos extremos con un casquillo de dos contactos que permiten alimentar el electrodo allí alojado. Estos tubos fluorescentes cilíndricos se presentan en diferentes formas, longitudes, diámetros, potencias y temperaturas de color, lo que permite utilizarlos en prácticamente todas las aplicaciones de inspección que precisen iluminar una escena relativamente grande con luz difusa. La luz difusa es una luz suave que llega al objeto desde múltiples direcciones e ilumina varios planos a la vez provocando pocas sombras. Sin embargo, los tubos fluorescentes estándar no tienen un balance de color uniforme, por lo que se deberán utilizar fluorescentes con espectro conocido y de apertura, que ofrecen una mejor respuesta en todo el espectro y mayor intensidad de iluminación.

Estas lámparas, por el contrario, presentan un grave problema que es imprescindible solucionar para poderlas utilizar en una aplicación de inspección a alta velocidad ya que si se alimentan con los balastos habituales no proporcionan una luz continua sino que muestran un parpadeo que depende de la corriente eléctrica aplicada (en España la corriente alterna oscila a 50 Hz o ciclos por segundo). El ojo humano no es capaz de apreciar directamente ese parpadeo, aunque las cámaras de video industriales, configuradas con un breve tiempo de exposición para capturar imágenes de objetos en movimiento, se ven muy afectadas por los cambios de intensidad debidos a ese parpadeo, ya que distintas imágenes pueden tener diferente intensidad lumínica en función de cómo se hayan sincronizado con el parpadeo. Para solucionar este problema se utilizan balastos electrónicos de alta frecuencia, que hacen funcionar al tubo exactamente de la misma manera que en la forma tradicional pero incrementando la frecuencia hasta los 100 kHz (2000 veces mayor que con un balastro tradicional), lo que provoca que se minimice el efecto parpadeo al ser una frecuencia muy elevada incluso para tiempos de exposición extremadamente cortos. Otras mejoras obtenidas son la reducción de ruidos eléctricos que pueden afectar a las cámaras, menor

consumo y calor disipado y mayor vida útil de los tubos. Otro de los mayores inconvenientes que presenta el uso de los tubos fluorescentes es el de la complejidad del cableado necesario para su utilización. Cada tubo requiere cuatro cables, dos de ellos conectados a cada electrodo, que llegan al balastro. Si, por ejemplo, una aplicación requiere ocho tubos fluorescentes, serán necesarios cuatro cables hasta cada uno de los ocho balastros, lo que hace un total de 32 cables. Si comparamos con una aplicación con ocho lámparas incandescentes, simplemente conectando todas ellas en paralelo, con dos cables sería suficiente.

En la actualidad está emergiendo fuertemente una nueva forma de iluminación basada en LED. Un LED o diodo emisor de luz, es un dispositivo semiconductor que funciona por efecto de electroluminiscencia. La estructura básica de un LED consiste en una o más capas orgánicas semiconductoras situadas entre dos electrodos. Aunque existen LED desde hace mucho tiempo, no se han utilizado hasta hace relativamente pocos años en inspección por visión ya que anteriormente utilizaban resistencias para su alimentación que provocaban que cada unidad se alimentara de forma distinta y la luz no fuera siempre igual. Los modelos modernos han solucionado ese problema al utilizar chips de corriente (fuentes de corriente) de mayor calidad y miniaturizados. Los LED proporcionan una intensidad lumínica adecuada a un coste muy bajo, además de ofrecer una larga vida media útil de aproximadamente 100000 horas (100 veces más que una lámpara incandescente o diez veces más que un tubo fluorescente). La intensidad lumínica que ofrecen los LED no es generalmente tan intensa como la de otros tipos de lámparas, aunque actualmente están apareciendo diodos de alta intensidad que ofrecen prestaciones muy similares a otras muy utilizadas. Además, la tecnología actual ha permitido reducir considerablemente el tamaño de estos diodos hasta hacerlos de tipo SMD (dispositivos de montaje superficial), con unos escasos 5 mm³ de volumen, lo que hace factible la concentración de un gran número de estos LED en una superficie muy reducida, y por tanto aumentar más aún su potencia lumínica. Su reducido tamaño también permite que se puedan disponer en cualquier forma, ofreciendo distintas configuraciones para adaptarse a las necesidades de la aplicación. El rendimiento lumínico por cada vatio de potencia de un LED de alta luminosidad se puede aproximar a los 125 lm/W funcionando con un voltaje de poco más de 3 V. En la actualidad pueden proporcionar, aunque con limitaciones, luz difusa debido a una pequeña óptica integrada, con unos ángulos de emisión de luz determinados, pero es necesario concentrar muchas unidades para obtener una luz completamente uniforme en toda la escena. Otro inconveniente es su emisión espectral que es menos uniforme a lo largo del espectro que la proporcionada por otros sistemas de iluminación, lo que puede alterar el color del producto que se inspecciona. Como ventaja adicional, el montaje de estos dispositivos es muy sencillo ya que con un par de cables de iluminación y corriente continua, se puede alimentar una enorme batería de diodos.

Una ventaja adicional de los LED la posibilidad de iluminar la escena con una frecuencia continua o variable. La luz de frecuencia variable o estroboscópica consiste

en sincronizar el momento de la iluminación de la escena con el de la adquisición de la imagen. Además de para lo anteriormente citado, esta técnica se suele utilizar para solucionar problemas derivados de la inspección de objetos a alta velocidad. Cuando la velocidad a la que pasan los objetos por delante de la cámara es muy elevada, la imagen capturada puede aparecer movida debido a la velocidad a la que avanza el objeto mientras se adquiere la imagen. Para eliminar este efecto hay dos posibles soluciones, una es disminuir el tiempo de obturación o *shutter* de la cámara, de forma que el tiempo de exposición sea muy corto, lo que implica la necesidad de una mayor intensidad de luz para que el sensor CCD de la cámara se excite de la misma forma pero en menos tiempo. Otra opción es utilizar luz con una frecuencia determinada, que iluminará la escena durante un muy breve espacio de tiempo de forma que el CCD de la cámara únicamente recibe luz del objeto durante el tiempo que dura el destello de luz.

Un problema típico que presentan los sistemas de iluminación, sobre todo cuando el objeto a iluminar es esférico, es el de los múltiples brillos que aparecen en la superficie de las frutas, aunque se puede solucionar incorporando una técnica denominada polarización de la luz. Para conseguir el efecto de polarización de la luz es necesario colocar un filtro polarizador entre la fuente de luz y la escena, que es capaz de absorber toda la luz que aparece en todos los planos excepto en uno, el plano del polarizador. Su funcionamiento es similar al de una rejilla, dejando pasar únicamente la luz que oscila en el mismo plano de la rejilla. De este modo, solamente la luz reflejada por el objeto en una única dirección alcanza la cámara. Sin embargo, es también aconsejable colocar en la óptica otro filtro polarizador para obtener el efecto de polarización cruzada. Mediante la polarización cruzada se elimina aproximadamente el 60 % de la luz debido a la absorción de los filtros pero se reducen los brillos y reflejos puntuales prácticamente hasta su desaparición.

3.3.3.2 Elección del sistema de iluminación

La elección del tipo de iluminación puede variar en función de la técnica de iluminación más adecuada para nuestra aplicación. En este caso se tiene en cuenta la forma en la que se debe disponer la luz para resaltar los detalles de interés de la imagen. Existen diversas disposiciones que se suelen utilizar en sistemas de visión por computador, como por ejemplo, iluminación direccional, lateral, difusa, coaxial, por campo oscuro, por retroiluminación o estructurada y que se describen con detalle en el Anexo II.

Para inspeccionar correctamente la escena que analizará la cámara de la máquina de asistencia a la recolección, se debe proporcionar una iluminación uniforme y estable en toda la escena. Además, en este caso concreto y particular de montar el sistema de inspección sobre un vehículo autónomo, es muy importante tener en cuenta las limitaciones energéticas derivadas del uso de la batería de la máquina, por lo que se priman las soluciones que presentan un menor consumo eléctrico y una mayor facilidad de implementación en la estructura de la máquina. Otro factor a tener en

cuenta es que la máquina se diseña para ser utilizada en el campo, lo que condiciona la robustez del sistema y hace necesario buscar soluciones que impliquen un bajo mantenimiento.

La escena a inspeccionar tiene dos carriles separados y abarca una zona de, aproximadamente, 400 mm de largo. Las lámparas deberían iluminar una zona ligeramente mayor para obtener en los extremos la misma intensidad que en el centro de la imagen. Debido a la experiencia previa del grupo de investigación, la primera solución contemplada está basada en cuatro tubos fluorescentes alimentados con dos balastos electrónicos de alta frecuencia. El problema de esta solución se encuentra, en primer lugar, en la energía necesaria para alimentar a los tubos y, en segundo lugar, en la fragilidad y posibilidad de rotura dada la aplicación de campo. Los tubos utilizados tienen la particularidad de que los cuatro conectores están en el mismo extremo, lo que facilita el conexionado y ofrecen una intensidad lumínica de 63 lm/cm, aproximadamente 3000 lm por tubo. Otro de los mayores problemas que tienen tubos fluorescentes para esta aplicación concreta es el alto calor que desprenden, lo que complica la elección de la cubierta, que debe resistir el calor generado por los tubos, además del calor del sol, pues el sistema trabajara en campo a cielo abierto.

Otra solución se basa en la utilización de LED de alta luminosidad dispuestos en tiras, que ofrecen una luz suficientemente uniforme sin necesidad de ningún tipo de electrónica para hacerlos funcionar (únicamente dos cables directos a la batería) y con un consumo de corriente menor al de otros sistemas de iluminación. Los LED, así como sus soportes y cubiertas, facilitan montajes similares al mostrado anteriormente para los tubos fluorescentes. Como ya se comentó en el capítulo anterior, los LED pueden funcionar en modo estroboscópico, lo que reduce significativamente el consumo de energía, crítico para esta aplicación.

Así pues, basándonos en todo lo comentado, para este trabajo se ha considerado que la mejor forma de iluminar la escena es mediante luz frontal o direccional, ya que la disposición de los objetos en la escena hace que sea la mejor solución posible, y para hacerlo se ha escogido como el sistema más adecuado el basado en tiras de LED de alta luminosidad con funcionamiento estroboscópico y utilizando polarización cruzada.

En este caso, se ha optado por un fabricante que ofrece unos perfiles de aluminio de la misma longitud de las tiras de LED, con una carcasa de protección acoplable, así como las tapas de los laterales y unos enganches para poner y quitar fácilmente los perfiles de su sujeción. Este perfil de aluminio cumple una doble función, la primera ya mencionada y la segunda, y más importante, sirve de radiador para la disipación pasiva del calor generado por la placa donde están insertados los LED. Además, como la luz emitida por los diodos es completamente direccional, no existen problemas de emisión de luz directa hacia la cámara, evitándose poner ningún tipo de cubierta a las tiras ya que el propio aluminio cumple esa función.

Estas tiras, mostradas en la Figura 3.14, contienen LED tipo PLCC2 SMD, de tan sólo 3 mm de grosor y separados entre sí 10 mm. Cada diodo tiene un ángulo de visión o cono lumínico de 120°. La longitud de cada tira es de 600 mm y su ancho 9 mm. Sin embargo, cada 30 mm se pueden cortar para ajustarlas al tamaño deseado. La intensidad lumínica es de aproximadamente un tercio respecto a la que ofrecen los tubos fluorescentes antes citados, con 20 lm/cm, aunque se realizaron diversas pruebas que indicaron que es suficiente para esta aplicación. El funcionamiento estroboscópico presenta la ventaja adicional de que evita que los LED se calienten demasiado, lo que permite ubicar el filtro polarizador dentro de la vaina protectora, simplificando con ello el montaje de manera importante.



Figura 3.14. Tiras de LED

3.3.3.3 Implementación del sistema de iluminación seleccionado

Para crear el efecto estroboscópico es necesario disponer de un dispositivo electrónico que emita un pulso eléctrico capaz de encender los LED durante la fracción de segundo en la que se adquiere la imagen. Además, ese pulso debe estar sincronizado con la cámara para asegurarse que coincide exactamente con el comienzo de captura de cada imagen. Para ello se utiliza la señal de salida de iluminación proporcionada por la cámara, también denominada *strobe*, que hace funcionar la iluminación de modo similar al flash de una cámara fotográfica.

El dispositivo electrónico diseñado para realizar el funcionamiento estroboscópico de la luz se ha tenido que diseñar para esta aplicación y consiste en una tarjeta electrónica basada en microcontrolador, que recibe la señal de sincronismo de la tarjeta de adquisición de imágenes y proporciona la energía y potencia suficiente para el encendido de los LED. Según las estimaciones realizadas, teniendo en cuenta una ratio de captura de 6,25 imágenes por segundo y un tiempo de encendido de 11 ms, los LED tan sólo permanecen encendidos un 7 % del tiempo, con el considerable ahorro de un 93 % del consumo energético, aumento de la vida útil de los diodos y reduciendo al máximo la disipación de calor. Estas estimaciones se han podido corroborar en laboratorio utilizando un osciloscopio. En la Figura 3.15 se muestra el circuito impreso diseñado con la colaboración del Laboratorio de Sensores y Calidad del Centro de Agroingeniería del IVIA.



Figura 3.15. Control de la iluminación estroboscópica

Los filtros polarizadores, necesarios para eliminar los brillos indeseados sobre la superficie de la fruta, se han instalado dentro de la carcasa de protección de las tiras de LED. Con el funcionamiento estroboscópico el aire del interior de esta carcasa no alcanza temperaturas elevadas, permitiendo así la integración de LED y filtros polarizadores en el mismo elemento.




Figura 3.16. Tiras de LED con los filtros polarizadores integrados

Para implementar el sistema de iluminación sobre la máquina, es necesario diseñar los soportes adecuados para el sistema de iluminación elegido y que incluyan la posibilidad de efectuar ciertos reglajes. Un ajuste importante es la disposición a lo ancho de la escena para evitar que los elementos de iluminación interfieran en la inspección de los objetos y otro que incluya la posibilidad de orientar la luz directamente hacia los objetos. También se tiene que ofrecer facilidad para el reemplazo de cada uno de los elementos de iluminación con conectores y enganches cómodos de manipular y que no impliquen volver a reajustar los reglajes. Los anclajes diseñados para las tiras de LED seleccionados cumplen con estos requisitos.

En la Figura 3.16 se muestra el diseño realizado que incluye las barras de aluminio con las tiras de LED, cubiertas por la carcasa y con el filtro polarizador en su interior.

3.4 Análisis de la fruta

Para realizar el análisis de la fruta en línea, ha sido necesario programar tres aplicaciones de usuario que implementan los algoritmos necesarios para todo el proceso. La primera aplicación se ha desarrollado para entrenar el sistema de forma que sea capaz de clasificar los píxeles de las imágenes de las frutas en las clases predefinidas de fondo, piel sana y daños. Y las otras dos se han desarrollado para cada las dos configuraciones de adquisición empleadas, el *Sistema PC* y el *Sistema Inteligente*. Ciertos algoritmos son comunes para ambos sistemas, pero otros se han tenido que programar específicamente para cada uno de ellos.

Todo el software desarrollado ha sido implementado en C++ utilizando la versión 6.0 de la plataforma Ms. Visual Studio, y no se ha utilizado ninguna librería externa salvo las necesarias para la adquisición de imágenes proporcionadas por el fabricante del hardware. Así pues, todos los algoritmos de análisis de imágenes se han diseñado e implementado a medida en el Laboratorio de Visión por Computador del Centro de Agroingeniería.

3.4.1 Algoritmos de entrenamiento

El entrenamiento se realiza sobre imágenes de fruta adquirida en condiciones normales de inspección. Para realizar dicho entrenamiento, se ha creado una aplicación que permite cargar estas imágenes y realizar de forma manual pequeñas selecciones de grupos de píxeles y asociarlos con una clase concreta de entre las clases predefinidas, que son fondo, piel sana, piel con defecto, pedúnculo (Figura 3.17). Cada clase tiene asociado un identificador, así como un nombre y color para comprobar después la bondad del entrenamiento realizado.

En el Anexo III se describe detalladamente cómo funciona la aplicación de entrenamiento del sistema.

Todos los valores RGB seleccionados durante el entrenamiento se almacenan en una lista. Una vez terminado el entrenamiento, ya se está en disposición de generar y guardar una tabla de consulta (LUT, del inglés *lookup table*). La LUT es una tabla que se almacena en la memoria del ordenador y asocia todos los posibles valores de RGB con su clase correspondiente, obtenida mediante un clasificador bayesiano. El clasificador bayesiano es un clasificador probabilístico que se basa en la aplicación del Teorema de Bayes (Bayes, 1783), que permite clasificar una observación en función del resultado que da la distribución de probabilidad condicional de una variable aleatoria A dada B en términos de la distribución de probabilidad condicional de la variable B dada A y la distribución de probabilidad marginal de sólo A .

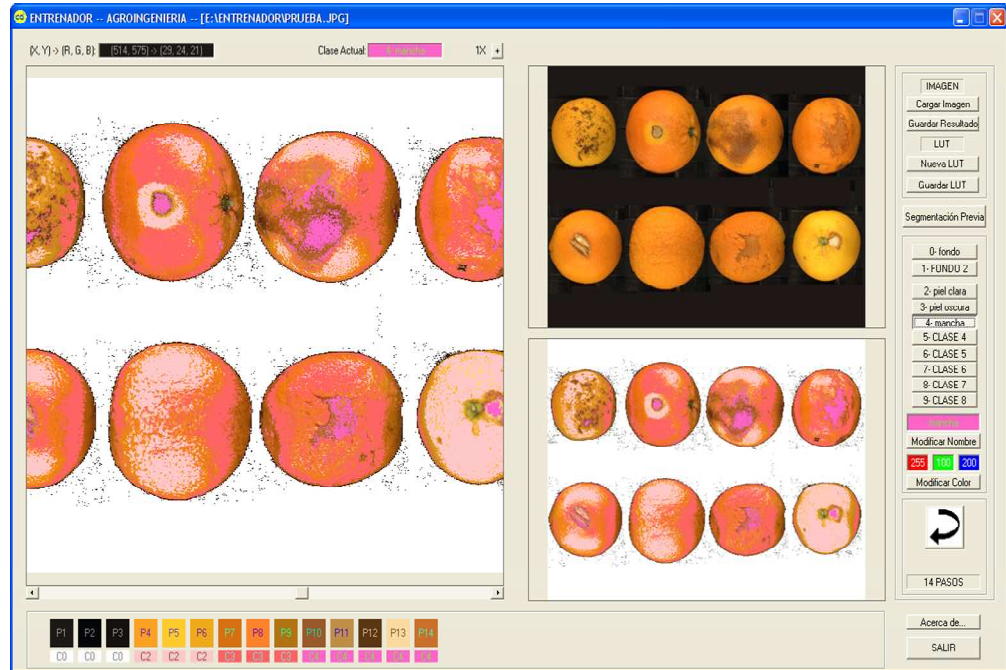


Figura 3.17. Pantalla de entrenamiento

La generación de la LUT se basa en un análisis discriminante bayesiano utilizando los valores del entrenamiento. Este método de clasificación se basa en la regla de decisión de Bayes (Kopparapu y Desai, 2001). Para generar el modelo, las coordenadas de color de cada uno de los píxeles de las regiones seleccionadas se introducen en el análisis como variables independientes (idéntica probabilidad a priori), mientras que la clase a la que pertenecen es la variable categórica. Una vez generado el modelo, se crean unas funciones de clasificación que se emplean para estimar la probabilidad de que una combinación particular del vector RGB de un píxel pertenezca a una clase o a otra. Para cada clase se crea una función diferente. Cada valor RGB se introduce en cada una de las funciones de cada clase y se asigna a aquella con la que obtenga un mayor valor. Estas funciones son del tipo que muestra la Ecuación 3.2:

$$Z_{xyj} = w_j^R * R + w_j^G * G + w_j^B * B + c_j \quad (3.2)$$

donde Z_{xyj} es el valor de clasificación del píxel xy para la clase j , las variables R, G, B son las coordenadas de color del píxel xy , w_j^R, w_j^G, w_j^B son los coeficientes que representan la importancia de cada variable para cada clase, y c_j es el sesgo del clasificador.

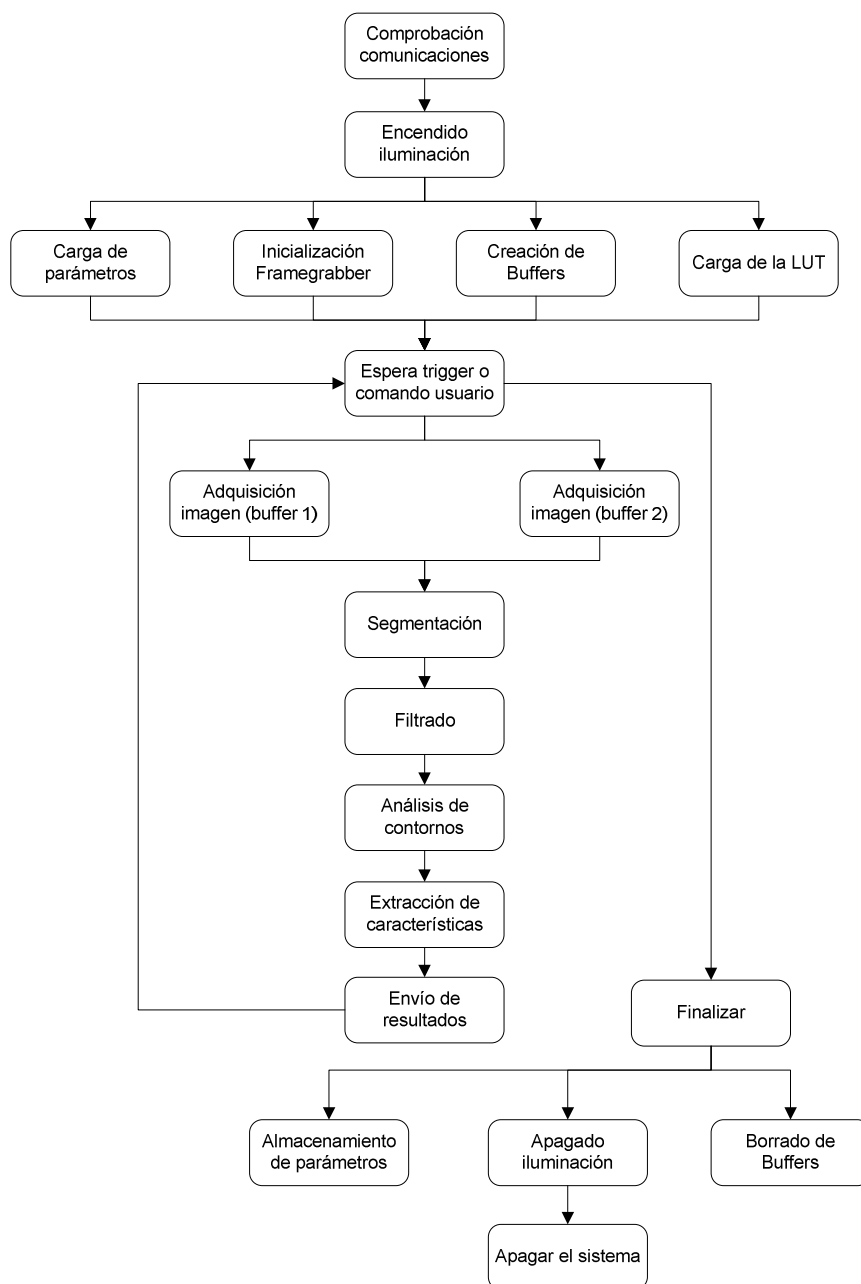


Figura 3.18. Diagrama de flujo del algoritmo de procesamiento en línea con la configuración de cámara y ordenador

Mediante un proceso iterativo, se calcula el valor de Z_j para todas las posibles combinaciones de RGB en una imagen y se va completando la LUT. Finalmente, la LUT se almacena en un fichero que se carga en memoria y es utilizado para el análisis de imágenes en línea. De esta forma, dado un pixel xy , en lugar de calcular el valor de Z_j para todas las clases posibles y asignarle una, simplemente se accede a la tabla residente en la memoria del ordenador mediante los valores RGB y se obtiene directamente el valor de la clase a la que pertenece. Se escogió este método de segmentación por ser rápido, fácil de entrenar e implementar en un sistema de inspección en línea y porque continúa trabajos previos del grupo en el cual se ha desarrollado esta tesis (Aleixos et al., 2002; Blasco et al., 2003 y 2007b).

Utilizando este método, es posible realizar LUT con diferentes tamaños. Una LUT mayor aportará una mejor precisión pero requerirá más espacio en memoria y por lo tanto mayores tiempos de acceso y procesamiento. Por el contrario, agrupando valores cercanos entre sí se consigue reducir la cantidad de información, disminuyendo las necesidades de memoria y tiempo de cálculo a costa de una menor precisión. Para este trabajo se ha probado con dos opciones, la primera con una LUT de 8 bits por canal, es decir, algo más de 16 millones de combinaciones ($2^8 * 2^8 * 2^8$) donde no existe pérdida de información y la segunda de 5 bits por canal, donde se reducen las combinaciones de valores RGB a 32768 ($2^5 * 2^5 * 2^5$). Se ha comprobado que con ambas opciones los tiempos de cálculo son muy similares y es posible ubicar ambas tablas en memoria, por lo que se ha optado por utilizar la LUT de mayor tamaño para mejorar la precisión del análisis.

3.4.2 Proceso de inspección en línea usando el *Sistema PC*

Para realizar las operaciones de inspección en línea con este sistema se ha realizado una aplicación a medida (se detalla en el Anexo IV). Cuando el usuario selecciona la inspección por visión, el autómata o PLC enciende automáticamente el equipo de inspección que carga la aplicación. Dicha aplicación, en primer lugar se encarga de encender el sistema de iluminación y comprobar la comunicación con el PLC. Después de estas tareas de inicialización, la aplicación básicamente entra en un bucle donde se capturan y procesan las imágenes hasta que el PLC envíe una señal de finalización. A continuación se describen los distintos pasos efectuados para la inspección en línea de la fruta. La Figura 3.18 muestra el diagrama de flujo de la aplicación.

3.4.2.1 Adquisición de la imagen

La adquisición de las imágenes viene sincronizada por parte del PLC que se encargará de enviar señales o pulsos a la entrada de disparo de la cámara o *trigger* del sistema de adquisición para que tome las imágenes. Desde el momento en que se recibe un pulso hasta que la imagen está disponible en memoria, transcurre un intervalo de tiempo durante el que se está en espera y que depende de las características de la cámara. Con la que se ha empleado para este trabajo, este tiempo es de 40 ms, ya que la cámara

captura 25 cuadros por segundo siguiendo el estándar CCIR. Esto ocurre funcionando en modo síncrono, en el que hasta que no se ha completado la adquisición no se puede seguir con la ejecución. Sin embargo, la tarjeta de adquisición que se ha utilizado en este caso posee un modo de adquisición asíncrono, de forma que es posible solapar el tiempo propio de la adquisición de una imagen con el tiempo de procesamiento de la imagen recibida anteriormente. De este modo se optimiza el proceso al analizar una imagen mientras se adquiere la siguiente de forma simultánea. El tiempo ahorrado siguiendo este método es de 40 ms que pueden ser fundamentales para un correcto y más complejo análisis en tiempo real. Para analizar una imagen en paralelo con la adquisición de otra nueva, es necesario disponer de dos regiones de memoria donde almacenarlas. A esta técnica se le denomina *double buffering* y consiste en utilizar dos buffers o zonas de memoria de modo alternativo para ir capturando, almacenando y procesando las imágenes. En la Figura 3.19 se muestra un gráfico que describe este proceso. En comparación con la Figura 3.20, se observa cómo se pueden disminuir los tiempos por ciclo y aumentar el número de imágenes que se pueden capturar y procesar en el mismo intervalo de tiempo.

MODO ADQUISICIÓN SÍNCRONO




Figura 3.19. Modo síncrono secuencial de adquisición de imágenes

En definitiva, con este método se consigue adquirir y procesar concurrentemente, ya que la captura no influye en el procesamiento al ser una tarea específica del hardware de adquisición, y no se hace uso del procesador ni de la memoria del sistema. Suponiendo que el tiempo de adquisición es de 40 ms y el tiempo de procesamiento es de 60 ms, se observa que las diferencias son importantes ya que con el modo síncrono se podrían analizar 10 imágenes por segundo, mientras que con el modo asíncrono la cantidad asciende a 16 imágenes por segundo.

MODO ADQUISICIÓN *DOUBLE BUFFERING*

Tiempo adquisición: 40 ms.
Total: 60 ms. por imagen

Tiempo procesamiento: 60 ms.
Máximo 16 imágenes/segundo




Figura 3.20. Modo asíncrono de adquisición de imágenes con *double buffering*

Una vez recibida la imagen en la memoria del sistema, ésta se procesa. Procesar la imagen en este caso consiste en segmentarla píxel a píxel, filtrar el resultado obtenido, buscar los objetos individuales en la imagen, extraer la información necesaria de cada uno de ellos, enviar los resultados al autómata de control y, si se requiere en modo de prueba, mostrar toda la información en pantalla o almacenarla en disco. Todos estos algoritmos, que se detallarán a continuación, se ejecutan en un tiempo inferior al que transcurre entre dos pulsos consecutivos de captura de imágenes. Este tiempo debe cumplirse obligatoriamente ya que en caso contrario la siguiente captura no se procesará. Por lo tanto, el tiempo de procesamiento se debe ajustar a la velocidad máxima de funcionamiento de la máquina, y en caso de que no se pueda cumplir, se deberá condicionar la velocidad de ésta al tiempo que el sistema de visión necesite.

Para optimizar el proceso se pueden descartar regiones en la imagen que no es necesario analizar. Por ejemplo, en el caso de la escena real, la zona central es de separación entre los dos carriles por lo que no deberá haber ninguna fruta en esa zona. Además, las propias tiras de LED ocupan esa zona de la escena ya que no se encuentran entre ningún objeto y la cámara. Las zonas en las que sí que pueden encontrarse objetos se denominan regiones de interés (ROI) de la imagen. En este caso aparecen dos ROI, una para cada carril, según se observa en la Figura 3.21.




Figura 3.21. Regiones de interés (ROI) de la imagen (enmarcadas en rojo)

Toda información de la imagen que se encuentra fuera de estas regiones no se analiza, lo que supone optimizar en gran medida el tiempo de computación. Por lo tanto, a partir de ahora, cuando se hable del análisis de la imagen, realmente se pretende hablar del análisis de sus zonas de interés.

Como ya se comentó anteriormente, de cada una de las frutas se toman hasta cuatro imágenes de diferentes vistas según la fruta avanza rotando a lo largo de la escena. A través del codificador de pulsos, el PLC sincroniza la adquisición de cada imagen con el paso de la fruta, por lo que las frutas están siempre en posiciones conocidas de la imagen y que permite dividirla en zonas que se analizan de forma independiente y en las que se supone que hay una única fruta. Internamente, se crea una matriz de $M \times N \times Q$, donde M es la posición de la fruta en un buffer circular, N es el número de rodillos que se analizan en cada imagen y Q el número de carriles. En este caso, M vale 6, que son los rodillos que pasan desde que una fruta aparece por primera vez por la zona de inspección hasta que se analiza su última vista y se envía (exactamente son los 4 rodillos de la imagen más otros 2 de retardo que necesita el PLC para sincronizar los resultados obtenidos con el pesaje), N es igual a 4, que son los rodillos de la imagen y Q vale 2, que es el número de carriles por los que pasa fruta. En esta matriz se almacena toda la información necesaria de cada imagen de cada fruta para luego ser combinada y obtener valores medios de todas las fotos de la misma fruta.

3.4.2.2 Segmentación

La segmentación de la imagen consiste en la división de la imagen en las distintas regiones que la componen, de las que se obtienen los objetos de interés en la imagen. Una forma de segmentar una imagen es clasificando cada píxel como perteneciente a

una clase, para lo que existen numerosos métodos descritos en la bibliografía (Gonzalez y Woods, 2002; Russ, 2006). Para estos ensayos se ha empleado un método sencillo y rápido motivado por la necesidad de realizar esta operación en línea y conseguir alcanzar el objetivo de procesar imágenes en tiempo real. La técnica principalmente consiste en comprobar el valor del píxel definido previamente en la LUT generada durante el entrenamiento previo. Es importante, como ya se comentó anteriormente, que el entrenamiento contenga la mayor información posible de los valores RGB que corresponden a cada clase y que se realice empleando distintas imágenes. Normalmente, las clases que se definen se corresponden con el fondo de la imagen compuesto por los rodillos de transporte, la piel sana de la fruta (verde y naranja), el pedúnculo y distintos tipos de defectos.

Para segmentar la imagen, se recorre secuencialmente desde la coordenada $(x=0, y=0)$. Una vez obtenido el valor RGB de un píxel se clasifica utilizando la LUT y se obtiene la clase con la que se etiqueta ese píxel. El resultado de este proceso es una nueva imagen en la que cada píxel tiene un valor entre 0 y 9. Este método ha sido probado con anterioridad en problemas similares y tiene la ventaja de ser muy rápido desde el punto de vista computacional, ya que, para cada píxel, simplemente se tiene que acceder a la LUT almacenada en la memoria del ordenador para comprobar cuál es su valor asociado o comprobar si pertenece a un intervalo determinado. Como desventaja, decir que es un método supervisado que necesita de un entrenamiento previo y que, en ocasiones, éste se debe realizar de nuevo cuando varían las condiciones originales. El algoritmo seguido para segmentar la imagen es el siguiente:

```
Para cada píxel en la ROI de la Imagen Original  
{  
Extraer RGB del píxel  
Comprobar la clase a la que pertenece el píxel en la LUT  
Copiar el valor obtenido de la clase en la Imagen Segmentada  
}
```

Para comprobar el resultado de la segmentación, a cada clase resultante se le asigna un color RGB diferente que permite visualmente identificarlas en la imagen.

3.4.2.3 Filtrado

Posteriormente a la segmentación se realiza un filtrado de las imágenes. En este caso consiste en un filtro de moda que suaviza los bordes entre regiones de diferentes clases y elimina los píxeles aislados que no forman ninguna región y que sólo constituyen ruido en la imagen. Para la aplicación de este filtro, se recorre la imagen segmentada y se calcula, para cada píxel, el valor que aparece con más frecuencia en la ventana de 8-vecinos. Se podría haber aplicado un filtro de mediana, pero se consideró más apropiado el filtro de moda ya que con este último se consigue, además, suavizar la

frontera entre regiones adyacentes, lo que permite acelerar los procesos siguientes de extracción y análisis de contornos.

Al igual que en el caso anterior, se crea una nueva imagen similar a la segmentada pero ya filtrada, que servirá tanto para seguir con el análisis como para poderla visualizar en pantalla. El algoritmo seguido para filtrar la imagen es el siguiente:

```
Para cada píxel en la ROI de la Imagen Segmentada  
{  
Calcular el valor más repetido de los 8-vecinos del píxel  
Copiar el valor obtenido en la Imagen Filtrada  
}
```

Para comprobar el resultado del filtrado, al igual que en el caso de la segmentación, se le asigna a cada clase un color RGB diferente que permite visualmente identificarlas en la imagen.

3.4.2.4 Análisis del contorno

Para estimar el tamaño de la fruta entera y el tamaño de las áreas pertenecientes a diferentes clases se tuvieron que extraer los contornos de los objetos de la fruta para caracterizarlos, ya sea para estimar el color o la presencia de defectos. Los píxeles en los que algún vecino tiene un valor diferente del suyo, se supone que pertenecen a un contorno. Estos píxeles se incluyeron para formar una imagen de los contornos, que luego fueron procesados.

El procesamiento de la imagen del contorno se llevó a cabo utilizando un método de código de cadena (Freeman, 1961). Este código se aplica a todos los píxeles de la imagen. Cuando se encuentra un píxel perteneciente a un contorno, se inspeccionan todos sus vecinos en el sentido de las agujas del reloj (siempre empezando desde el mismo píxel, por ejemplo el situado a la derecha) en busca de los píxeles que continúan el contorno hasta llegar de nuevo al píxel inicial. En el caso de que se llegue a una frontera abierta, todos los píxeles de este contorno se descartan y se continúa el proceso alrededor buscando otro píxel perteneciente a un nuevo contorno.

Los objetos reales están formados por contornos cerrados, aunque antes de validar un objeto debe cumplir una serie de restricciones para eliminar la posible presencia de ruido (consistente en objetos muy pequeños) o para diferenciar entre los frutos u otras áreas de interés, como pedúnculos, defectos o áreas de color. Aquellos que no cumplían con ciertas especificaciones fueron descartados y eliminados del análisis. El resultado de este proceso fue una nueva imagen que contiene sólo los contornos de los objetos válidos. El algoritmo seguido para buscar los contornos en la imagen es el siguiente:

Para cada píxel en la ROI de la Imagen Filtrada

{

Si el píxel pertenece a un contorno:

Buscar en sus vecinos si también pertenecen a contorno

Repetir la búsqueda hasta encontrar el píxel inicial

Si no se encuentra, descartar los píxeles encontrados y seguir con el siguiente píxel de la ROI

Si no seguir con el siguiente píxel de la ROI

}

Para cada contorno cerrado encontrado:

{

Descartar los objetos muy pequeños (ruido)

Copiar el valor de la clase de los píxeles de los contornos en la Imagen Contornos

}

En este caso se crea una nueva imagen que incluye únicamente los contornos de los objetos, que también pueden ser visualizados asignándoles un color RGB según a la clase a la que pertenezca el objeto.

3.4.2.5 Detección de los defectos

Para cada objeto encontrado en la imagen se calculó el área y el perímetro partiendo de la información obtenida de la segmentación y del análisis de los contornos. En el entrenamiento previo se deben identificar zonas de la imagen que corresponden a fondo, piel sana de diversos colores como pueden ser naranja y verde, diferentes defectos e incluso el pedúnculo de la fruta. A partir de los objetos que pertenecen a clases de defectos se calcula el área defectuosa en relación con el área total de la fruta. Los píxeles que pertenecen al pedúnculo, a la clase de verde y a la de naranja son considerados como piel sana. El área de un objeto son todos aquellos píxeles encerrados dentro del contorno del objeto, y el perímetro únicamente el número de píxeles que pertenecen al borde o contorno.

Hay que tener en cuenta que normalmente los objetos considerados como defectos suelen aparecer en el interior de otros objetos identificados como piel sana. Esto es importante a la hora de calcular las áreas de los objetos, a fin de calcular qué porcentaje de superficie de la fruta está o no dañada.

3.4.2.6 Estimación del calibre

El tamaño de la fruta se calcula como el diámetro máximo, que es la línea entre los dos puntos opuestos que atraviesan el centro de gravedad de la fruta. Este centro de gravedad o centroide se calcula como la coordenada promedio (x, y) de todos los píxeles del contorno de la fruta. Para cada punto del perímetro se deben calcular todos los ejes que atraviesan dicho centro de gravedad, quedándonos con el de mayor valor y obteniendo así el diámetro máximo de la fruta.

3.4.2.7 Estimación del índice de color

Puesto que la posibilidad de separar fruta con distintos niveles de color es una de las aplicaciones más importantes de esta máquina, se le ha prestado una atención especial a la precisión del análisis del color. Las mandarinas tempranas se recolectan normalmente de color verde o virando a naranja. Puesto que interiormente ya han alcanzado su madurez, se les aplica un tratamiento con etileno que únicamente afecta a su color. La duración de este tratamiento depende del color inicial de la fruta, así que sería de gran utilidad que la fruta pudiera llegar al almacén previamente clasificada.

Para medir el color de este tipo de fruta se utiliza el Índice de Color de los Cítricos (ICC) (Jiménez-Cuesta et al., 1981) que se calcula según la Ecuación 3.3 a partir de los valores Hunter Lab obtenidos por un colorímetro.

$$ICC = 1000 \times a/L \times b \quad (3.3)$$

Puesto que los valores de color en la imagen se ofrecen en coordenadas de color RGB, es necesario convertirlos a Hunter Lab en un primer paso para estimar posteriormente el índice de color.

Para realizar la conversión del espacio de color RGB a cualquier otro es necesario convertir previamente los valores originales al espacio XYZ. Este paso representa una pérdida de precisión ya que el espacio RGB es limitado en cuanto a número de colores; en RGB no se pueden definir todos los colores posibles que, por ejemplo, aporta un espectro. Por otra parte, existen multitud de matrices para la conversión de RGB a XYZ. Esto es debido a que existe una dependencia del espacio RGB en el que estamos trabajando (Adobe RGB, Apple RGB, CIE RGB, NTSC RGB, PAL/SECAM RGB, sRGB, etc.). Normalmente, las cámaras de vídeo trabajan en el espacio sRGB, por lo que utilizaremos las matrices correspondientes a ese espacio de color. Uno de los puntos importantes a tener en cuenta al aplicar estas matrices en las conversiones es elegir el iluminante-observador utilizado. En esta plataforma se han utilizado unos LED que tienen una temperatura de color de 6000°K, así que para hacer las conversiones se han empleado formulas que incluyen el iluminante D65 (6500°K) y el observador 10°. La descripción de las formulas empleadas para realizar la conversión se detalla en el Anexo V.

Sin embargo, este proceso es computacionalmente muy costoso, especialmente si se debe realizar para cada píxel. Para agilizar el proceso se ha recurrido de nuevo a una tabla. En este caso, mediante las ecuaciones descritas en el Anexo V se calcula el ICC de todos los posibles valores de RGB y se almacenan en una LUT. De esta forma, se puede recorrer la imagen y para cada uno de los píxeles correspondientes a piel de fruta se obtiene el ICC simplemente consultando en memoria esa tabla. Así se reduce ingentemente el coste computacional, pero a cambio de requerir una mayor cantidad de memoria libre para almacenar la tabla.

Algoritmos para decidir el color de una fruta

Al igual que ocurre con el tamaño, para estimar el ICC de una fruta se tienen en cuenta el análisis de todas las imágenes adquiridas mientras la fruta viaja rotando bajo la cámara. Para ello, existen diversas estrategias que influirán tanto en el índice final estimado como en el tiempo de proceso requerido para ello. Todas ellas parten de la imagen segmentada de la fruta para discriminar entre fruta y fondo, y descartan las regiones correspondientes a defectos o pedúnculo. En concreto los algoritmos desarrollados son:

- 1) Se estima la media aritmética de todos los valores RGB pertenecientes a fruta de cada imagen. El valor de la media se convierte finalmente a espacio Hunter Lab para obtener el ICC de cada fruta.
- 2) Se calcula el ICC de cada píxel perteneciente a fruta a partir de su valor RGB. El ICC de cada fruta se calcula como la media aritmética de los ICC de todos los píxeles de la fruta.

El cálculo del ICC de cada píxel se ha realizado de dos formas, ambas con idéntico resultado pero con distinto coste computacional y requerimientos de memoria. Por un lado, se han empleado las formulas de conversión sobre el valor RGB de cada píxel y por otro, usando la LUT para obtener el valor ICC de cada píxel a partir de su valor RGB. Este último proceso es muy rápido pero requiere una gran cantidad de memoria del sistema disponible, concretamente 64 MB.

Por último, el ICC de la fruta se calcula como la media de los valores de ICC parciales de todas las imágenes de la misma fruta. La Figura 3.22 muestra un ejemplo del aspecto visual del ICC de una naranja.




Figura 3.22. Aspecto visual del ICC de una naranja

3.4.2.8 Envío de resultados al control de la máquina

Una vez obtenidos los datos del análisis, estos se transfieren al PLC para que tome una decisión sobre su clasificación según los parámetros introducidos por el usuario. El PLC utilizado cuenta con un puerto de comunicaciones estándar industrial RS-485, similar al RS-232 que poseen algunos ordenadores personales, pero más robusto e inmune a interferencias electromagnéticas. Para utilizarlo en el PC, ha sido necesario utilizar una tarjeta PCI que proporciona un puerto RS-485 auxiliar. Una vez establecida la comunicación física, se ha creado un protocolo de comunicaciones en el que se establece un paso de mensajes con el formato de la Tabla 3.3.

Tabla 3.3. Detalle de mensaje de comunicación entre el autómatas y el módulo de visión

Carácter	Significado
Carácter inicial	I
Remitente	V
Byte Control	b7...b0
1 ^{er} . Dato	Color del carril A
2 ^o . Dato	Defecto carril A
3 ^o . Dato	Calibre carril A
4 ^o . Dato	Color carril B
5 ^o . Dato	Defecto carril B
6 ^o . Dato	Calibre carril B
Carácter Final	F

El módulo de visión envía información sobre el color, porcentaje de superficie manchada y calibre de la fruta para los dos carriles A y B cada vez que se adquiere una imagen. Además se utiliza un byte de control (b7...b0) en el que se le proporciona al autómatas el estado del sistema de visión. Los datos que se enviarán son relativos al estado (b0: activo/inactivo), validez (b1: correcto/incorrecto), iluminación (b2: correcta/incorrecta), ajuste de la cámara (b3: correcto/incorrecto), existencia de fruta (b4: existe/no existe), y cabe la posibilidad de aumentar el número de mensajes de control a enviar según surjan nuevas necesidades.

Es importante destacar que al terminar la ejecución de la aplicación, se realiza una parada ordenada del sistema para finalizarla de forma correcta, sin provocar errores en el sistema operativo. Además, la tarjeta de adquisición debe recibir una orden de fin de aplicación para que ésta quede liberada y pueda ser utilizada por otra aplicación, como podría ser, por ejemplo, el software de configuración de la propia cámara. Al finalizar la ejecución, se procederá al apagado de la iluminación a través del envío de una señal a una de las salidas digitales de las que dispone la tarjeta digitalizadora. Una vez realizados todos estos pasos, se guardan los parámetros modificados para que se vuelvan a cargar al iniciar de nuevo la aplicación.

3.4.3 Proceso de inspección en línea usando el *Sistema Inteligente*

Al igual que ocurre en el *Sistema PC*, ha sido necesario realizar una aplicación a medida similar a la anterior pero adaptada a las características de la cámara

inteligente, que nos permita inspeccionar la fruta. El interfaz de la aplicación es muy similar al detallado en el Anexo IV, pero los algoritmos se han adaptado a esta cámara.

En el caso del *Sistema Inteligente* compuesto por la cámara con capacidad de procesamiento, se han intentado reproducir todos los cálculos que previamente se han realizado utilizando el *Sistema PC*, pero centrando los esfuerzos en la estimación del color de la fruta, principal objetivo del proyecto asociado a este trabajo.

El mayor problema de esta configuración es la poca capacidad computacional de la cámara. A igualdad de operaciones, esta configuración necesita aproximadamente 10 veces más tiempo para analizar la misma imagen, lo que hace inviable su aplicación directa. Por ello se ha tenido que llegar a un compromiso entre rendimiento y velocidad, que ha obligado a suprimir algunas operaciones, como la búsqueda de contornos (aparejada a la detección de defectos), y optimizar otras, como la estimación del calibre aún a costa de perder exactitud. Por lo tanto, todos los algoritmos se han basado en el análisis de color y la estimación del tamaño. La Figura 3.23 muestra el diagrama de flujo de la aplicación, similar al del *Sistema PC*.

3.4.3.1 Adquisición de la imagen

Este proceso se efectúa de forma idéntica al caso del *Sistema PC*. El PLC envía un pulso a la entrada de disparo de la cámara que hace que se tome la imagen. Las imágenes se adquieren en dos buffers de forma alternativa que permiten solapar la adquisición con el análisis de las mismas. Además se han establecido ROI de modo similar al caso anterior, aunque con diferentes valores ya que cada cámara tiene una resolución distinta. Y como en el caso anterior, el tratamiento de los datos obtenidos del análisis de cada una de las cuatro vistas de la fruta se ha realizado empleando una matriz idéntica, de tamaño $M \times N \times Q$.

3.4.3.2 Segmentación

Debido a las necesidades de optimización de los algoritmos para poder alcanzar el rendimiento requerido, se ha tenido que realizar todo el proceso de análisis de la imagen en un único barrido de la misma. Por ello, se ha usado un método de segmentación que permite realizar la extracción de características en el mismo paso.

Para segmentar la imagen se ha utilizado la ratio entre el valor de la banda verde y la banda azul (G/B) del valor RGB de cada píxel, de tal forma que aquellos píxeles cuyo valor está por encima de un umbral determinado se consideran fruta y el resto fondo. Esta ratio se estableció debido a que la fruta presenta valores muy bajos de azul y valores muy elevados de verde en todos los estados de maduración, mientras que el fondo presenta siempre valores bajos de ambos valores, facilitando así la discriminación.

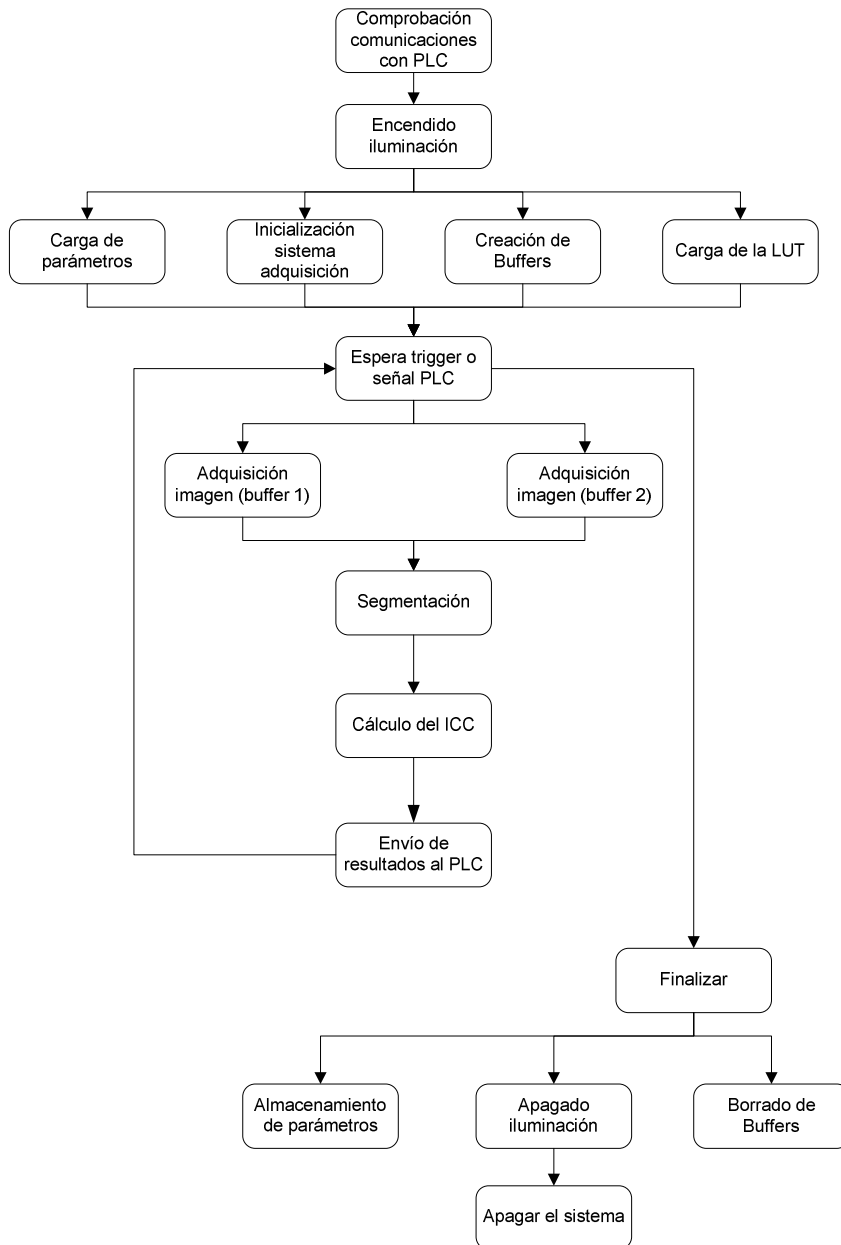


Figura 3.23. Diagrama de flujo del algoritmo del procesamiento en línea con la configuración de cámara con capacidad de procesamiento

3.4.3.3 Estimación del calibre

Dado que con el *Sistema Inteligente* no se realiza una búsqueda de objetos como la realizada con el *Sistema PC*, no se puede obtener el valor del perímetro de la fruta,

aunque sí que se puede calcular el área. Por lo tanto, la estimación del calibre de la fruta se realiza como una medida indirecta del área. En primer lugar se estima el área cómo la suma de todos los píxeles pertenecientes a la fruta a la vez que se segmenta la imagen. Posteriormente se asume la fruta esférica para calcular el calibre mediante la Ecuación 3.4.

$$r = \sqrt{A/\pi} \quad (3.4)$$

donde r es el radio y A es el área obtenida.

De esta forma se puede obtener la estimación del diámetro de la fruta, que se comparó con el diámetro medio medido a mano usando un calibre (pie de rey) digital.

3.4.3.4 Estimación del índice de color

Este proceso se efectúa de forma similar al caso de la configuración correspondiente al *Sistema PC*, con la conversión del valor de cada píxel RGB a Hunter Lab y el cálculo del ICC. Sin embargo, utilizando este sistema tan sólo es posible calcular el ICC de cada píxel utilizando la LUT, ya que para calcular el ICC de cada píxel utilizando las fórmulas de conversión se precisa algo más de un segundo en procesar cada imagen, imposibilitando el funcionamiento en línea.

3.4.3.5 Envío de resultados

El envío de resultados con la cámara inteligente se produce de la misma forma que con el *Sistema PC*, ya que la propia cámara cuenta con un puerto de comunicaciones serie al que se le ha añadido un módulo de conversión de RS-232 a RS-485 para enviar los datos en el mismo formato que reconoce el PLC. El protocolo de comunicaciones utilizado es exactamente el mismo que en el caso anterior.

3.4.4 Ensayos realizados usando el *Sistema PC*

Para los experimentos se utilizó un conjunto de 170 naranjas del cultivar ‘Navelina’. Las frutas se seleccionaron de modo aleatorio y tenían diferentes calibres comprendidos entre 58 mm y 95 mm, diferentes colores variando desde el típico naranja hasta verde intenso y la presencia de diversos tipos y tamaños de defectos, la mayoría de ellos cicatrices causadas por el viento. De estas frutas se extrajeron 10 para entrenar y poner a punto el sistema. El resto de las frutas se etiquetaron y se inspeccionaron de forma individual por la máquina para comparar los valores obtenidos por el sistema automático con los valores obtenidos manualmente. Adicionalmente se usaron 487 frutas repartidas en seis categorías según su calibre para obtener el rendimiento de la máquina y estimar este parámetro trabajando con lotes de fruta.

La fruta se inspeccionó seis veces con el sistema automático, tomando como valor medido el obtenido en la primera inspección y usando las otras cinco para conocer el grado de repetibilidad y robustez de estas medidas.

3.4.4.1 Estimación del calibre y peso

Tres expertos midieron manualmente todas las frutas utilizando un calibre digital, realizando esta operación tres veces cada uno y estableciendo como calibre de la fruta la media de las nueve medidas. Estos datos se compararon con los calibres obtenidos por el programa de inspección en línea y se extrajo el coeficiente de correlación entre ambos análisis con el objetivo de conocer el grado de precisión con el que el sistema automático puede reproducir la medida manual. Además, se pesó la fruta con la idea de intentar obtener una correlación entre los datos de calibre y peso.

Por otra parte, la fruta se clasificó en tres categorías de calibre que corresponden con una categoría de fruta pequeña y no comercializable y dos categorías de frutas comercializables:

- Categoría 1: [calibre < 65 mm]
- Categoría 2: [65 mm < calibre < 80 mm]
- Categoría 3: [80 mm < calibre]

Adicionalmente, para obtener el rendimiento de la máquina trabajando con lotes más elevados de fruta, se midió el calibre de las 487 frutas de forma manual y se agruparon en grupos según su calibre. Estos grupos se inspeccionaron de forma independiente por la máquina con el objetivo de conocer con qué precisión el sistema automático era capaz de reproducir la clasificación manual.

3.4.4.2 Detección de defectos

Las frutas se evaluaron de forma visual por tres expertos, categorizando la presencia de daños entre 0 (fruta sin defectos de ningún tipo) y 5 (fruta con numerosos defectos). Para realizar la comparación, puesto que el sistema está limitado a clasificar en tres categorías, se agruparon las frutas clasificadas manualmente en las siguientes tres categorías:

- Categoría I: valores entre 0 y 1 para las frutas con pocos o ningún defecto.
- Categoría II: valores entre 2 y 4 para frutas con un número moderado de defectos.
- Categoría destrío: valores 5 para frutas cuyo nivel de daños puede impedir su comercialización.

Esta clasificación se realizó pensando en que el objetivo de detectar defectos en esta plataforma sería, en primer lugar, detectar y eliminar aquellas frutas que no deben llegar al almacén de confección por su elevado nivel de daño, ahorrando de este modo el transporte, lavado, inspección, tratamiento y almacenamiento de estas frutas. Y En segundo lugar es importante identificar aquellas frutas con un nivel de defecto muy bajo para evitar nuevas inspecciones y manipulaciones en el almacén.

Estos datos se compararon con los obtenidos de forma automática por el sistema de visión estableciendo las siguientes categorías de forma arbitraria basada en la experiencia del grupo investigador.

- Categoría I: porcentaje de área con defectos entre el 0 % y el 5 %.
- Categoría II: porcentaje de área con defectos entre el 5 % y el 15 %.
- Categoría destrío: porcentaje de área con defectos superior al 15 %.

3.4.4.3 Estimación del color

Al igual que en los casos anteriores, el color de la fruta se midió de forma manual empleando un colorímetro (Minolta C400) en cuatro puntos diferentes de la fruta (próximo al cáliz, próximo al pedúnculo y dos en la zona ecuatorial). Las mediciones se realizaron tres veces por tres operarios diferentes, decidiendo que el color de la fruta era el promedio de las 36 medidas (cuatro medidas por tres usuarios y por tres repeticiones).

La estimación del índice de color se realizó de forma automática siguiendo los dos métodos descritos: a partir del ICC de cada píxel y del RGB medio del conjunto de píxeles pertenecientes a la clase fruta.

Para comparar ambos sistemas se obtuvo la correlación entre las medidas manuales y automáticas, y se clasificó la fruta en tres categorías atendiendo a las fijadas para establecer los tratamientos de desverdización (DOGV, 2006; Martínez-Jávega et al., 2007) y que fueron:

- Categoría 1: [ICC < 3]
- Categoría 2: [3 < ICC < 7]
- Categoría 3: [7 < ICC]

Se consideró una tolerancia de $\pm 0,5$ debido a que, en la práctica, una diferencia así resulta imperceptible y es irrelevante a la hora de determinar el tratamiento adecuado para desverdizar la fruta (comunicación personal del Centro de Poscosecha del IVIA). Usando como referencia las medidas manuales, se obtuvo la ratio de éxito del sistema desarrollado.

3.4.5 Ensayos empleando el *Sistema Inteligente*

Estos ensayos se realizaron empleando la cámara con capacidad de procesamiento de imágenes. Se utilizó un conjunto de 105 naranjas del cultivar ‘Valencia’ y otro de 120 naranjas del cultivar ‘Navelina’ con diferentes colores y tamaños para estimar el rendimiento de la máquina en términos de clasificación de la fruta. Las frutas se seleccionaron aleatoriamente a partir de fruta recién recolectada con diferentes tamaños y diferentes colores, desde el verde intenso hasta el típico color naranja. En todos los casos, cada fruta se etiquetó y se inspeccionó seis veces por el sistema automático, la primera para obtener los datos de calibre y el resto para comprobar la repetibilidad del sistema.

3.4.5.1 Estimación del calibre

Al igual que en el ensayo anterior, todas las frutas se midieron manualmente utilizando un calibre digital, realizando tres medidas por tres expertos distintos y calculando su media. Estos datos se compararon con los obtenidos por los programas de inspección que estiman el calibre a partir del área de la fruta y se obtuvo el índice de correlación R^2 . Además, se pesó la fruta con la idea de intentar obtener una correlación entre el calibre y el peso.

3.4.5.2 Estimación del color

Al igual que en el ensayo anterior, todas las frutas se midieron manualmente utilizando un colorímetro, realizando tres medidas por tres expertos distintos en cuatro zonas de la fruta y concluyendo que el color de la fruta se corresponde con la media de las 36 mediciones. Estos datos se compararon con los obtenidos por los programas de inspección que estiman el color a partir del ICC de cada píxel de la fruta y del RGB medio del conjunto de píxeles de la misma. Se obtuvo el índice de correlación R^2 entre ambas medidas para comprobar el éxito del sistema.

3.5 Resultados

3.5.1 Ensayos realizados usando el *Sistema PC*

3.5.1.1 Estimación del calibre

Para la estimación del calibre se ha realizado una regresión de un modelo lineal y un modelo cuadrático, a partir de los diámetros medidos utilizando un pie de rey (en mm) y los diámetros calculados por el software de análisis de imágenes (en píxeles y convertidos a mm). El R^2 del modelo cuadrático muestra un valor del 99,7 %. La Ecuación 3.5 muestra el modelo de ajuste.

$$\text{Calibre} = 7,738 + 0,868 * \text{Diámetro}_{\text{máquina}} + 0,001 * \text{Diámetro}_{\text{máquina}}^2 \quad (3.5)$$

El *p-valor* del modelo es cero, lo que indica que éste es válido. Los *p-valor* observados mostrados en la Tabla 3.4 nos indican que el segundo término de la ecuación estimada ($\text{Diámetro}_{\text{máquina}}^2$) no es significativo, debido a que el *p-valor* es mayor de 0,05, por lo cual comprobaremos si existe un mayor ajuste con una regresión lineal.

El coeficiente de correlación para el modelo lineal muestra un valor de 0,998 y un R^2 del 99,7 %. La Ecuación 3.6 muestra el modelo de ajuste de la regresión lineal.

$$\text{Calibre} = 5,805 + 0,919 * \text{Diámetro}_{\text{máquina}} \quad (3.6)$$

Según se observa en la Tabla 3.5, los *p-valor* de la *Ordenada* y la *Pendiente* son estadísticamente significativos para el modelo. Además el R^2 expresa el 99,7 % de la variabilidad de los datos, por lo que se obtiene una relación relativamente fuerte entre

las variables. Es por ello que para simplificar los cálculos se utilizará el modelo lineal, aunque, ambos modelos expresan un R^2 del 99,7 %.

Tabla 3.4. Análisis de regresión polinomial (Calibre-Diámetro máquina *Sistema PC*)

	Error estimación	Estadístico estándar	T	P-Valor
Constante	7,738	2,638	2,932	0,004
Diámetro máquina	0,868	0,069	12,487	0,000
Diámetro máquina ²	0,001	0,001	0,740	0,460

Tabla 3.5. Análisis de regresión lineal (Calibre-Diámetro máquina *Sistema PC*)

	Error estimación	Estadístico estándar	T	P-Valor
Ordenada	5,805	0,399	14,533	0,000
Pendiente	0,919	0,005	172,660	0,000

En la Figura 3.24 se observa el ajuste al modelo polinomial (arriba) frente al modelo lineal (abajo).

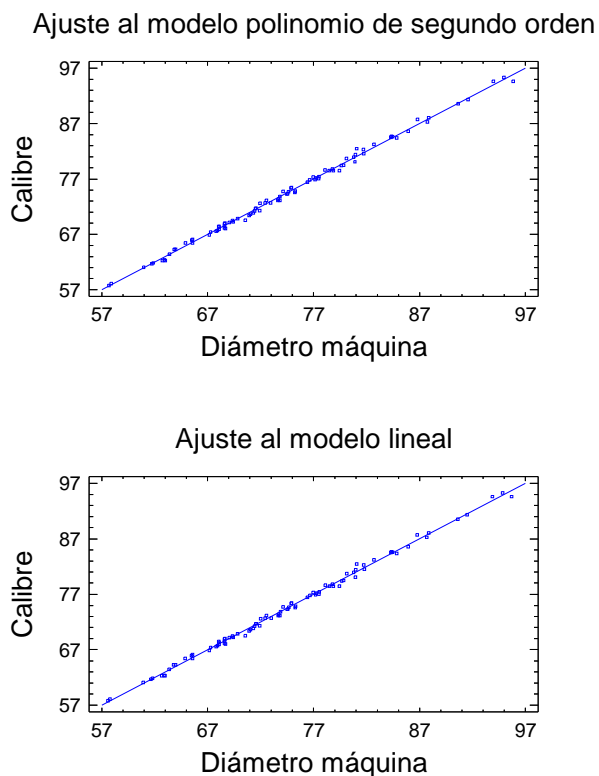


Figura 3.24. Representación de los modelos polinomial y lineal (Calibre-Diámetro máquina *Sistema PC*)

Los resultados de clasificación se muestran en la Tabla 3.6. El principal objetivo de la clasificación de la fruta por tamaño es eliminar aquellas piezas que son demasiado pequeñas para ser comercializadas. Por lo tanto, el hecho de que la fruta muy pequeña se detectara en un 100 % de los casos resulta un resultado muy destacable.

Tabla 3.6. Matriz de confusión de la clasificación automática de la fruta según la característica de tamaño (Sistema PC)

	Categoría 1 (%)	Categoría 2 (%)	Categoría 3 (%)
Categoría 1 (calibre < 65)	100,0	0,0	0,0
Categoría 2 (calibre [65-80])	3,4	91,5	5,1
Categoría 3 (calibre > 80)	0,0	0,0	100,0

3.5.1.2 Estimación del peso

Para intentar predecir el peso de la fruta a partir del análisis de las imágenes, se intenta correlacionar el peso real de la fruta (en gramos) con los diámetros calculados por el software de análisis de imágenes (en mm). Para ello se ha realizado una regresión lineal y otra cuadrática. El R^2 del modelo cuadrático muestra un valor del 98,2 %. La Ecuación 3.7 muestra el modelo de ajuste.

$$\text{Peso} = 72,116 - 3,520 * \text{Diámetro}_{\text{máquina}} + 0,068 * \text{Diámetro}_{\text{máquina}}^2 \quad (3.7)$$

El p -valor del modelo es cero y, como se observa en la Tabla 3.7, el p -valor de la constante del modelo podría suprimirse ya que no es significativa. Basándonos en los resultados obtenidos en el apartado anterior, donde es más sencillo un modelo lineal, se intentará comprobar si ocurre de la misma manera con un modelo lineal.

Tabla 3.7. Análisis de regresión polinomial (Peso–Diámetro máquina Sistema PC)

	Error estimación	Estadístico estándar	T	P-Valor
Constante	72,116	49,503	1,456	0,148
Diámetro máquina	-3,520	1,304	-2,699	0,008
Diámetro máquina ²	0,068	0,008	8,046	0,000

El coeficiente de correlación para el modelo lineal muestra un valor de 0,984 y un R^2 del 96,9 %. La Ecuación 3.8 muestra el modelo de ajuste de la regresión lineal.

$$\text{Peso} = -321,577 + 6,942 * \text{Diámetro}_{\text{máquina}} \quad (3.8)$$

En este caso, el p -valor del modelo lineal también es cero. Según se observa en la

Tabla 3.8, los p -valor son estadísticamente significativos, por lo tanto ambos modelos pueden ser válidos ya que ofrecen unos R^2 muy elevados, lo que confirma una relación fuerte entre las variables. Sin embargo el modelo cuadrático ofrece un R^2 mayor.

Tabla 3.8. Análisis de regresión lineal (Peso–Diámetro máquina *Sistema PC*)

	Error estimación	Estadístico estándar	T	P-Valor
Ordenada	-321,577	9,866	-32,593	0,000
Pendiente	6,942	0,131	52,780	0,000

En la Figura 3.25 se observa el ajuste al modelo polinomial (arriba) frente al modelo lineal (abajo).




Figura 3.25. Representación de los modelos polinomial y lineal (Peso – Diámetro máquina *Sistema PC*)

3.5.1.3 Estimación del color

En el caso de la estimación del color, se correlaciona el ICC de la fruta medido con el colorímetro con el ICC calculado por el software de análisis de imágenes. Como en los casos anteriores se realiza una regresión lineal y otra cuadrática. El R^2 del modelo cuadrático muestra un valor del 98,9 %. La Ecuación 3.9 muestra el modelo de ajuste.

$$ICC_{colorímetro} = 0,218 + 0,532 * ICC_{máquina} + 0,005 * ICC_{máquina}^2 \quad (3.9)$$

El *p-valor* del modelo es cero y, como se observa en la Tabla 3.9, todos los *p-valor* son significativos. Veamos que ocurre con el modelo lineal.

Tabla 3.9. Análisis de regresión polinomial (ICC colorímetro-máquina Sistema PC)

	Error estimación	Estadístico estándar	T	P-Valor
Constante	0,218	0,079	2,752	0,006
ICC máquina	0,532	0,004	119,988	0,000
ICC máquina ²	0,005	0,001	15,116	0,000

El coeficiente de correlación para el modelo lineal muestra un valor de 0,986 y un R² del 97,4 %. La Ecuación 3.10 muestra el modelo de ajuste de la regresión lineal.

$$ICC_{colorímetro} = 1,062 + 0,532 * ICC_{máquina} \quad (3.10)$$

En este caso, el *p-valor* del modelo lineal también es cero. En la Tabla 3.10 se observa que los *p-valor* son estadísticamente significativos, por lo tanto ambos modelos pueden ser válidos ya que ofrecen R² muy elevados. En este caso el modelo cuadrático también ofrece un R² mayor que el modelo lineal.

Tabla 3.10. Análisis de regresión lineal (ICC colorímetro-máquina Sistema PC)

	Error estimación	Estadístico estándar	T	P-Valor
Ordenada	1,062	0,088	12,023	0,000
Pendiente	0,532	0,006	76,792	0,000

En la Figura 3.26 se observa el ajuste al modelo polinomial (arriba) frente al modelo lineal (abajo).

El objetivo del sistema de visión es el de clasificar la fruta en tres categorías, que se corresponden con las posibilidades mecánicas de la máquina. Los resultados de la clasificación utilizando la característica de color se muestran en la Tabla 3.11. La categoría 1 se compone de frutas que presentan un color naranja claro con manchas de color verde. La categoría 2 se compone de frutas con un color naranja claro, pero con algunas zonas de color verde claro. La categoría 3 se compone de frutas con el color naranja típico y que se encuentran listas para su comercialización. Los peores resultados se han obtenido en la clasificación de la categoría 3 (fruta lista para su comercialización). Sin embargo, estos errores fueron dados en frutas con cifras cercanas al umbral entre la segunda y tercera categorías, siendo el valor del ICC cercano a este umbral en todos los casos.

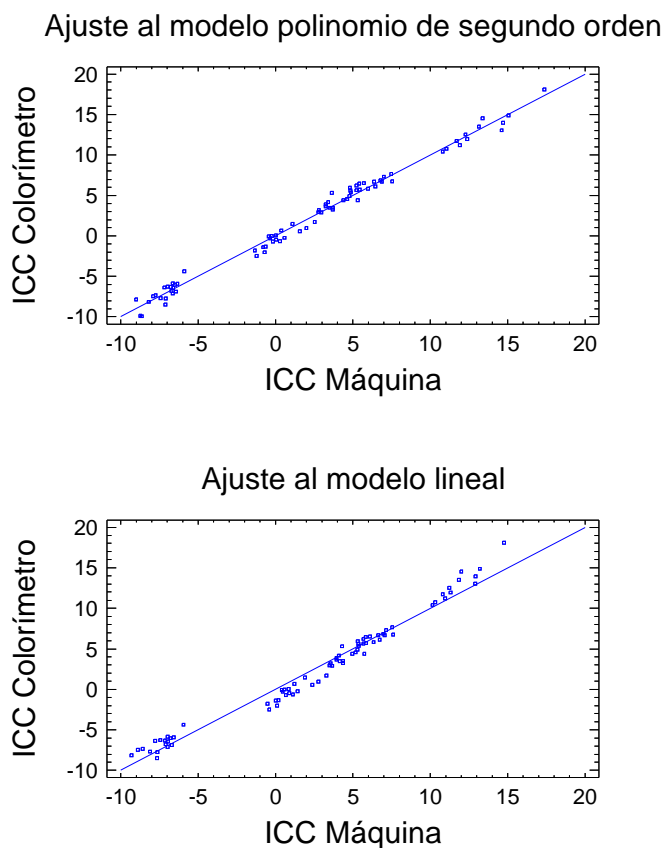


Figura 3.26. Representación de los modelos polinomial y lineal (ICC colorímetro-máquina *Sistema PC*)

Tabla 3.11. Matriz de confusión de la clasificación automática de la fruta según la característica del color (*Sistema PC*)

	Categoría 1 (%)	Categoría 2 (%)	Categoría 3 (%)
Categoría 1 (ICC < 3)	93,8	6,2	0,0
Categoría 2 (3 < ICC < 7)	9,5	86,0	4,5
Categoría 3 (ICC > 7)	0,0	17,6	83,4

3.5.1.4 Detección de defectos

Los resultados obtenidos en la detección de defectos apenas alcanzaron un 55 % de éxito. Esto se debió a diversas causas. La más probable fue la heterogeneidad de la fruta, con gran variedad de colores y daños de muy diversa consideración. Algunas frutas contenían zonas con un color verde muy intenso que presentaban cierta

similitud con los colores también oscuros de daños encontrados en otras frutas, lo que confundía al sistema a la hora de diferenciar las zonas pertenecientes a daños de otras con colores verdes muy oscuros. Otro de los problemas que perjudicaron a la detección de los defectos fue la iluminación. A pesar de los buenos resultados obtenidos en estimación del color, se observó que la iluminación era insuficiente para la detección de los defectos. Se mejoró la iluminación, para lo cual se rediseñó la placa electrónica de alimentación de los LED, ya que era necesario aumentar su voltaje de funcionamiento por encima de su valor nominal (12 V) en modo pulsado. Esta mejora del sistema de iluminación se implementó en los ensayos realizados con el *Sistema Inteligente*, aunque ya no fue posible realizar la detección de los defectos debido a los problemas de coste computacional asociados con esta configuración.

3.5.1.5 Estimación del tiempo de procesamiento

En la Tabla 3.12 se muestra el tiempo total requerido para procesar una imagen. Para minimizar los errores de precisión que presenta el reloj interno del ordenador, el tiempo consumido fue estimado realizando un bucle de 1000 iteraciones de cada operación de forma independiente, para posteriormente dividir el tiempo total empleado entre 1000 para obtener la cantidad de tiempo consumido por una sola operación. Esto se ha repetido para un total de 10 imágenes diferentes con ocho de las frutas de mayor calibre, que presentaban diferentes colores y la presencia de varios defectos. El tiempo requerido para la adquisición de la imagen y el envío de los resultados al autómata no se incluyen en la tabla, ya que se superponen con otras operaciones, como ya se comentó anteriormente. Los tiempos mostrados en la tabla son los máximos obtenidos para cualquiera de las diez imágenes que se utilizaron.

Tabla 3.12. Tiempos máximos obtenidos para cada operación de procesamiento con el *Sistema PC*

Operación	Tiempo consumido (ms)
Segmentación	25
Filtrado	15
Extracción y análisis de contornos	5
Extracción de características	3
Total	48

3.5.2 Ensayos empleando el *Sistema Inteligente*

3.5.2.1 Estimación del calibre

Como ya se comentó anteriormente, con el *Sistema Inteligente* no ha sido posible realizar la búsqueda de objetos, por lo que únicamente se tiene información del área de la fruta para estimar su calibre. Partiendo de esto, se ha estimado el calibre a partir del área según la Ecuación 3.4 y se ha realizado una regresión de un modelo lineal y un modelo cuadrático, utilizando las calibres calculados a partir del diámetro medio de la fruta (en mm²) medido con un pie de rey y los calibres calculados por el software de

análisis de imágenes (en píxeles y convertidos a mm²). El R² del modelo cuadrático muestra un valor del 99,9 %. La Ecuación 3.11 muestra el modelo de ajuste.

$$\begin{aligned} \text{Calibre}_{real} = & 4,775 + 0,858 * \text{Diámetro}_{máquina} \\ & + 0,001 * \text{Diámetro}_{máquina}^2 \end{aligned} \quad (3.11)$$

El *p-valor* del modelo es cero. Los *p-valor* observados en la Tabla 3.13 nos indican que todos los términos de la ecuación son significativos. También se ha comprobado el ajuste con una regresión lineal.

Tabla 3.13. Análisis de regresión polinomial (Área real-máquina *Sistema Inteligente*)

	Error estimación	Estadístico estándar	T	P-Valor
Constante	4,775	2,007	2,378	0,019
Diámetro máquina	0,858	0,054	15,749	0,000
Diámetro máquina ²	0,001	0,001	2,841	0,005

El coeficiente de correlación para el modelo lineal muestra un valor de 0,999 y un R² muy elevado del 99,9 %. La Ecuación 3.12 muestra el modelo de ajuste de la regresión lineal.

$$\text{Calibre}_{real} = -0,907 + 1,013 * \text{Diámetro}_{máquina} \quad (3.12)$$

Como indica la Tabla 3.14, los *p-valor* de la *Ordenada* y la *Pendiente* son estadísticamente significativos para el modelo. Aunque ambos modelos tienen el mismo R², se elige el modelo lineal ya que es menos costoso de calcular.

Tabla 3.14. Análisis de regresión lineal (Calibre real-máquina *Sistema Inteligente*)

	Error estimación	Estadístico estándar	T	P-Valor
Ordenada	-0,907	0,179	-5,065	0,000
Pendiente	1,013	0,002	414,305	0,000

En la Figura 3.27 se observa el ajuste al modelo polinomial (arriba) frente al modelo lineal (abajo).

Los resultados de estimación del calibre a partir del área fueron muy buenos, alcanzando el 100 % de éxito para todas las categorías, como se observa en la Tabla 3.15.




Figura 3.27. Representación de los modelos polinomial y lineal (Área real-máquina *Sistema Inteligente*)

Tabla 3.15. Matriz de confusión de la clasificación automática de la fruta según la característica de tamaño (*Sistema Inteligente*)

	Categoría 1 (%)	Categoría 2 (%)	Categoría 3 (%)
Categoría 1 (calibre < 65)	100,0	0,0	0,0
Categoría 2 (calibre [65-80])	0,0	100,0	0,0
Categoría 3 (calibre > 80)	0,0	0,0	100,0

3.5.2.2 Estimación del peso

Para intentar predecir el peso de la fruta a partir del análisis de las imágenes, se intenta correlacionar el peso real (en gramos) con las áreas estimadas en el análisis de imágenes (en mm²). Para ello se ha realizado una regresión lineal y otra cuadrática. El

R^2 del modelo cuadrático muestra un valor del 33,3 %. La Ecuación 3.13 muestra el modelo de ajuste.

$$Peso = 75,323 + 0,015 * \text{Área}_{máquina} + 0,001 * \text{Área}_{máquina}^2 \quad (3.13)$$

El p -valor del modelo es cero. Se observa en la Tabla 3.16 que los p -valor de los términos no son significativos. Por lo cual hay que comprobar que ocurre con el modelo lineal.

Tabla 3.16. Análisis de regresión polinomial (Peso-Área máquina Sistema Inteligente)

	Error estimación	Estadístico estándar	T	P-Valor
Constante	75,323	83,878	0,898	0,371
Área máquina	0,015	0,038	0,401	0,688
Área máquina ²	0,001	0,001	0,274	0,783

El coeficiente de correlación para el modelo lineal muestra un valor de 0,631 y un R^2 del 39,8 %. La Ecuación 3.14 muestra el modelo de ajuste de la regresión lineal.

$$Peso = 39,685 + 0,003 * \text{Área}_{máquina} \quad (3.14)$$

En este caso, el p -valor del modelo lineal también es cero. Según se observa en la Tabla 3.17, los p -valor son estadísticamente significativos, por lo tanto el modelo que más expresa esta relación es el lineal, aunque su R^2 es muy bajo.

Tabla 3.17. Análisis de regresión lineal (Peso-Área máquina Sistema Inteligente)

	Error estimación	Estadístico estándar	T	P-Valor
Ordenada	39,685	14,104	2,813	0,005
Pendiente	0,003	0,001	8,831	0,000

En la Figura 3.28 se observa el ajuste al modelo polinomial (arriba) frente al modelo lineal (abajo).

3.5.2.3 Estimación del color

En el caso de la estimación del color, se correlaciona el ICC de la fruta medido con el colorímetro con el ICC calculado por el software de análisis de imágenes. Como en los casos anteriores se realiza una regresión lineal y otra cuadrática. El R^2 del modelo cuadrático muestra un valor del 90,1 %. La Ecuación 3.15 muestra el modelo de ajuste.

$$ICC_{colorímetro} = 7,736 + 0,374 * ICC_{máquina} + 0,002 * ICC_{máquina}^2 \quad (3.15)$$

El *p-valor* del modelo es cero y, como se observa en la Tabla 3.18, todos los *p-valor* son significativos. Veamos que ocurre con el modelo lineal.

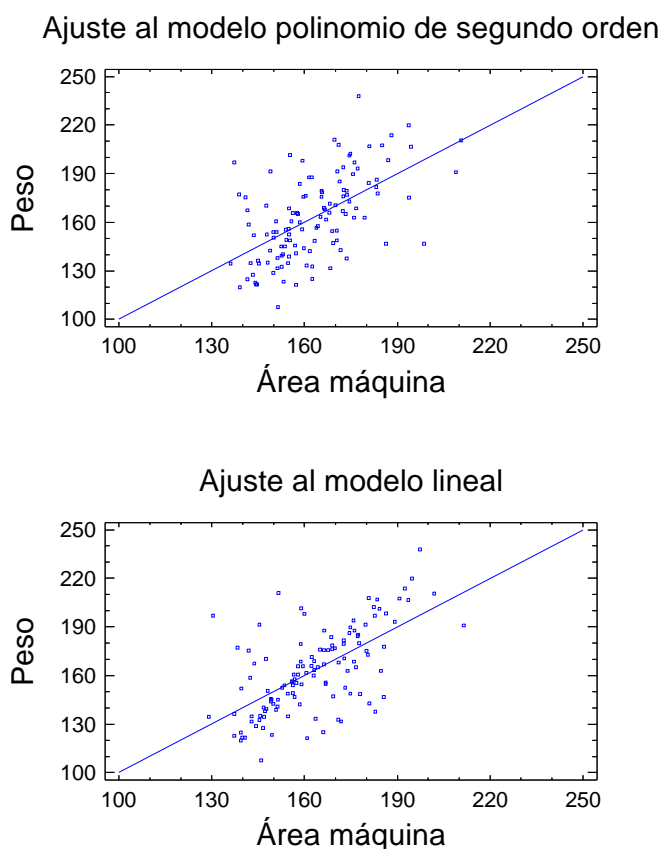


Figura 3.28. Representación de los modelos polinomial y lineal (Peso–Área máquina *Sistema Inteligente*)

Tabla 3.18. Análisis de regresión polinomial (ICC colorímetro-máquina *Sistema Inteligente*)

	Error estimación	Estadístico estándar	T	P-Valor
Constante	7,736	0,141	54,745	0,000
ICC máquina	0,374	0,008	43,321	0,000
ICC máquina ²	0,002	0,001	6,059	0,000

El coeficiente de correlación para el modelo lineal muestra un valor de 0,941 y un R^2 del 88,5 %. La Ecuación 3.16 muestra el modelo de ajuste de la regresión lineal.

$$ICC_{colorimetro} = 8,222 + 0,381 * ICC_{máquina} \quad (3.16)$$

En este caso, el *p-valor* del modelo lineal también es cero. En la Tabla 3.19 se observa que todos los *p-valor* son estadísticamente significativos, por lo tanto ambos modelos pueden ser válidos ya que ofrecen R^2 elevados. En este caso el modelo cuadrático también ofrece un R^2 mayor que el modelo lineal.

Tabla 3.19. Análisis de regresión lineal (ICC colorímetro-máquina *Sistema Inteligente*)

	Error estimación	Estadístico estándar	T	P-Valor
Ordenada	8,222	0,125	65,554	0,000
Pendiente	0,381	0,009	41,480	0,000

En la Figura 3.29 se observa el ajuste al modelo polinomial (arriba) frente al modelo lineal (abajo).




Figura 3.29. Representación de los modelos polinomial y lineal (ICC colorímetro-máquina *Sistema Inteligente*)

La matriz de confusión obtenida con ambos sistemas se muestra en la Tabla 3.20. Los mejores resultados se obtienen en el caso del grupo intermedio, ya que a este grupo pertenecen las frutas con un color más heterogéneo, siendo fundamentalmente naranja con grandes áreas amarillas y verdes. Por el contrario, el color de la fruta perteneciente al grupo 1 es de un verde más homogéneo y el del grupo 3 de un naranja más homogéneo. En todos los casos se obtuvo una clasificación superior al 84 %, siendo el acierto medio del 92 % y del 95 % respectivamente.

Tabla 3.20. Matriz de confusión obtenida para la clasificación de fruta por la plataforma móvil

	Categoría 1 (%)	Categoría 2 (%)	Categoría 3 (%)
Categoría 1 (ICC < 3)	84,0	16,0	0,0
Categoría 2 (3 < ICC < 7)	0,0	90,7	9,3
Categoría 3 (ICC > 7)	0,0	1,9	98,1

3.5.2.4 Estimación del tiempo de procesamiento

El tiempo de procesamiento de las imágenes con esta configuración se presenta en la Tabla 3.21. En ella se muestra el tiempo requerido por el primer algoritmo de estimación de color, que estima el ICC para cada píxel de la imagen, empleando la LUT y sin emplearla (realizando el conjunto de operaciones de conversión para cada píxel). La última fila corresponde al tiempo requerido por el segundo algoritmo que calcula el ICC a partir del RGB medio.

Tabla 3.21. Estimación de tiempos empleando la configuración de Sistema Inteligente.

Operación	Tiempo consumido (ms)
Calculando el ICC de cada píxel sin LUT	1171
Calculando el ICC de cada píxel con LUT	189
Calculando el RGB medio	125

A modo de comparación, la Tabla 3.22 muestra los tiempos obtenidos por configuración basada en la cámara inteligente ejecutando los algoritmos iniciales programados para la configuración cámara y ordenador. Como se puede apreciar, estos son notablemente más elevados que los obtenidos para el caso anterior e inviábiles para el problema de inspección.

Tabla 3.22. Estimación de tiempos empleando la cámara inteligente y los algoritmos inicialmente implementados para una configuración de cámara y ordenador personal.

Operación	Tiempo consumido (ms)
Segmentación	104
Filtrado	270
Extracción y análisis de contornos	145
Extracción de características	175
Total	694

3.6 Discusión

Se han desarrollado y montado dos sistemas de visión por computador en tiempo real sobre una plataforma móvil de recolección que permite la preclasificación de la fruta en el campo, que cumple con los objetivos y especificaciones requeridas.

Se han diseñado y construido las estructuras necesarias para ubicar las cámaras y el sistema de inspección, teniendo en cuenta la necesidad de que debe ser completamente ajustable en todas sus posiciones, y ser lo más reducida posible a la vez que permita un rápido montaje y desmontaje. La configuración ideada para la disposición de la cámara ha permitido construir una campana de inspección que sólo aumenta la altura de la máquina en 230 mm. El empleo de un espejo que refleja la imagen se ha demostrado como una solución igualmente válida frente a situar las cámaras con la tradicional disposición cenital.

Después de valorar diferentes tipos de iluminación, se ha optado por desarrollar un sistema basado en LED debido a su bajo consumo y elevada duración, lo que minimiza las tareas de mantenimiento. Para eliminar la aparición de brillos en la imagen se han empleado filtros polarizadores entre la iluminación y la cámara. El empleo de un mecanismo estroboscópico ha permitido reducir la energía consumida por los LED en un 93 % y ha reducido la disipación de calor, lo que ha permitido instalar los filtros polarizadores directamente en la carcasa de protección de las lámparas evitando así la instalación de nuevos sistemas de soporte.

Los primeros ensayos se realizaron empleando una cámara de video conectada a un PC que gobierna todo el sistema de visión y que se alimenta mediante un inversor de potencia conectado a la batería de la plataforma. Esta configuración presentaba un consumo energético relativamente elevado y se experimentó con una configuración menos potente basada en una cámara con capacidad de procesamiento propio, lo que ha permitido alimentar todo el sistema a 12 V de corriente continua, logrando una gran eficiencia energética.

Se han implementado algoritmos de análisis de imagen para estimar el calibre, color y presencia de manchas en las frutas, aunque esto último sólo se ha conseguido realizar con cierta eficacia con la configuración inicial de cámara y ordenador. La fruta pasa por debajo de la cámara a elevada velocidad mientras rota sobre sí misma. Durante ese trayecto se adquieren diferentes imágenes que el sistema procesa de forma secuencial. El procesamiento de cada imagen comienza con una segmentación basada en una tabla de consulta almacenada en memoria para optimizar el tiempo de proceso. Posteriormente se realiza una extracción y un seguimiento del contorno de cada objeto para decidir si es fruta, mancha o simplemente ruido. Si el objeto se considera fruta se obtiene su calibre, relación entre color verde y color naranja y porcentaje de superficie manchada. Al finalizar el análisis de la última imagen de cada fruta, la información se envía al autómatas de control para que tome la decisión adecuada respecto de su calidad y la desvíe por la salida correspondiente. El tiempo promedio que el *Sistema PC* tarda en analizar una imagen es de 48 ms, mientras que el *Sistema Inteligente*

precisaría 694 ms para analizar una imagen utilizando los mismos algoritmos. En estos tiempos se realizan además las tareas de adquisición de la imagen siguiente ya que los tiempos se solapan con el análisis, optimizando los tiempos completos de procesamiento. Esto da una idea de la diferencia en la capacidad de cálculo de ambos sistemas, aunque se ha optimizado el análisis de las imágenes en el *Sistema Inteligente* para que sea capaz de funcionar en tiempo real reduciendo la complejidad de los algoritmos a costa de un menor rendimiento. Se han conseguido correlaciones muy elevadas para la determinación del tamaño en ambos sistemas, (R^2 del 99 %) y del color (R^2 entre el 90 % y el 97 %), siendo éstas las características más importantes desde el punto de vista de su aplicación práctica. Sin embargo, la presencia de manchas no se ha conseguido detectar correctamente debido a una deficiente iluminación. El peso ha sido estimado con una correlación alta en el caso del *Sistema PC* (R^2 del 97 %), aunque no así para el *Sistema Inteligente* (R^2 del 40 %). Sin embargo esto no se considera un factor importante ya que la máquina cuenta con un sistema electrónico de pesaje mucho más exacto que una estimación por análisis de imágenes.

Se han desarrollado para las dos aplicaciones, entrenamiento e inspección, interfaces amigables que permiten entrenar de forma intuitiva el sistema y observar el desarrollo del análisis para ajustar su funcionamiento a lo esperado.

Ya que los ensayos realizados muestran buenos resultados, se recomienda la configuración compuesta por la cámara inteligente que, como ya se ha descrito ampliamente, simplifica el sistema de inspección. No obstante hay que destacar el hecho que la detección de defectos es un aspecto muy importante en la estimación de la calidad de los cítricos y debe ser mejorado en un futuro, incidiendo en la iluminación, optimizando los algoritmos y si es posible utilizando un hardware con mayor capacidad de procesamiento.

En definitiva, es posible inspeccionar cítricos sobre una plataforma móvil especialmente concebida para trabajar en campo para estimar el color y el calibre empleando un sistema basado en visión por computador instalado sobre una plataforma móvil de asistencia a la recolección.

4. Nuevas tecnologías para la selección automática de arilos de granada (*Punica granatum L*) basadas en visión por computador

Resumen

La granada es una fruta con excelentes propiedades organolépticas y nutricionales, pero el hecho de que sea difícil de pelar afecta a su comercialización y disminuye su consumo potencial. Una solución a este problema es el mercado de arilos de granada en un formato listo para consumir, para lo que es necesario pelar la fruta en la industria. Sin embargo, durante un proceso de pelado automático, además de arilos, otros materiales no deseados tales como membranas internas o arilos defectuosos se extraen junto con los arilos buenos y se deben eliminar de la línea de envasado, ya que la presencia de este material reduce el periodo de vida del producto y deteriora su apariencia frente al consumidor. Realizar esta clasificación de forma manual resulta inviable debido a la enorme cantidad de producto y la dificultad de su manejo. Sin embargo, no existen máquinas comerciales para realizar esta tarea, ya que la fruta mínimamente procesada ha sido hasta ahora un mercado minoritario en comparación con la fruta fresca, por lo que se hace necesario el desarrollo de equipos específicos. Este trabajo describe el diseño y creación de un nuevo prototipo basado en visión por computador para inspeccionar los objetos procedentes del proceso de extracción, detectar y eliminar el material no deseado y clasificar los arilos en cuatro categorías según su color o tamaño. El prototipo se compone de unidades para individualizar, transportar, inspeccionar y clasificar los objetos. La unidad de inspección se basa en un sistema de visión por computador para la que se han desarrollado algoritmos de análisis de imagen y sincronización con el resto de sistemas. Los algoritmos de análisis de imagen se han probado empleando dos métodos de segmentación de imágenes: el primero utilizando un umbral con la relación R/G y el segundo con un enfoque más complejo basado en un Análisis Discriminante Lineal Bayesiano (LDA) en el espacio RGB. Ambos métodos ofrecieron una tasa de éxito promedio del 90 % en el conjunto de validación, siendo la primera opción más intuitiva para los operadores, así como más rápida y fácil de implementar a nivel práctico. Posteriormente, el prototipo desarrollado se probó en la industria, trabajando en condiciones reales a lo largo de toda una temporada de granadas, durante la que se clasificaron automáticamente más de 9 toneladas de arilos.

Palabras clave: Tiempo real, inspección automática, análisis en línea, arilos de granada, control de calidad

4.1 Introducción

España produce alrededor de 20.000 toneladas de granadas (*Punica granatum L.*) por año durante la campaña comprendida entre octubre y enero. Esta fruta se ve afectada en el campo por particulares desórdenes fisiológicos, tales como quemaduras provocadas por el sol o el rajado de la fruta madura (Melgarejo et al., 2004) que no influyen en su calidad o sus propiedades internas, pero degradan su aspecto exterior y evitan que los frutos afectados se puedan comercializar. Además, el hecho de que sea tan complicado y engorroso para el consumidor pelar esta fruta da lugar a un cierto grado de rechazo en favor de otras frutas que son más fáciles de comer. Sin embargo, es una fruta con grandes propiedades nutricionales y anti-cancerígenas (Schubert et al., 1999; Gil et al., 2000; Malik et al., 2005; Lansky y Newman, 2007). Otro aspecto importante es el hecho de que los granados no necesitan agua u otros productos agrícolas (fertilizantes, productos fitosanitarios y otros) en grandes cantidades, y esto hace que cada vez se desarrollen con más facilidad en climas áridos y semiáridos. Por todo ello, se están realizando grandes esfuerzos, desde los productores hasta las administraciones, para aumentar el consumo de esta fruta. Una forma de conseguirlo es la venta de arilos listos para el consumo, que contienen un alto valor añadido en una sociedad cada vez más concienciada por la salud.

En el mercado ya se encuentran disponibles algunos tipos de máquina para la extracción de los arilos. Uno de sus principales problemas, sin embargo, es que durante el proceso de extracción se liberan fragmentos de membranas internas o de pieles, así como producto que se debe eliminar como arilos defectuosos (rotos, de forma anormal o con diferentes desórdenes fisiológicos) junto con arilos válidos de diferentes colores que varían desde el blanco hasta el rojo. Los arilos defectuosos pueden acortar el periodo de vida del producto, sobre todo si presentan algún tipo de infección, mientras que los arilos con diferentes colores en un mismo envase pueden reducir la atracción del consumidor y, por lo tanto, su precio. Siendo la inspección manual demasiado cara y subjetiva, es muy importante para los productores de arilos de granada listos para consumir la posibilidad de encontrar soluciones automáticas para inspeccionar y clasificar el producto.

En las líneas de producción actual, la inspección de los arilos tiene tres objetivos principales: 1) eliminar los restos de membranas internas y pieles; 2) eliminar arilos no deseados tales como aquellos que son demasiado pequeños, están rotos o tienen un color pardeado; y 3) ordenar los arilos de calidad por color con el fin de conseguir que el aspecto del producto sea uniforme en un mismo lote. Como ya se comentó en la introducción, la visión por computador, muy empleada en otros sistemas de inspección, abre la posibilidad de construir sistemas de clasificación automática adaptados a este producto.

Los sistemas de visión por computador montados en las máquinas de clasificación requieren de dispositivos auxiliares para que los objetos entren y salgan del campo de visión de las cámaras. Por lo general, trabajan en combinación con otros dispositivos

que individualizan el producto, lo transportan y separan la producción en diferentes categorías en función de su cualidad o características deseadas por el productor. Los frutos grandes son relativamente fáciles de manejar y separar por medios mecánicos, lo que permite que los sistemas de visión por computador inspeccionen cada objeto de forma individual fácilmente. El caso se complica cuando se trata de fruta pequeña, como tomate cherry, aceitunas, cerezas, etc. ya que son productos frágiles, en ocasiones van mojados y su producción (el número de frutos a inspeccionar por unidad de tiempo) es muy elevada. Por ello, con la excepción de los siguientes, hay muy poca información disponible sobre el desarrollo de sistemas de visión por computador en el ámbito de frutas pequeñas: aceitunas (Díaz et al., 2004), dátiles (Lee et al., 2008), pasas (Huxoll et al., 1995) o melocotones en conserva (Vizmanos et al., 1997). Esta tesis supone el primer intento de automatizar la inspección de un producto de las características de los arilos de granada, pues no se ha encontrado en la literatura científica ningún trabajo que haya bordado antes este problema. Los arilos de granada son objetos particularmente difíciles de manejar debido a su pequeño tamaño, y porque se trata de un producto húmedo y pegajoso que es muy difícil de separar. Además, los arilos son mucho más frágiles que la fruta fresca, lo que complica la forma en la que se manipulan por lo que es necesario investigar en novedosas soluciones de ingeniería para crear un prototipo de clasificación específico para este tipo de productos.

Desde el punto de vista de la adquisición y análisis de las imágenes, existen otras dificultades adicionales tales como la gama de posibles colores de los arilos (desde el blanco al rojo oscuro o marrón), la alta velocidad de las cintas transportadoras y los brillos producidos por el agua en la piel de los arilos, que complican todavía más la estimación del color. Existen técnicas de segmentación supervisadas basadas en estadísticas, como son los métodos bayesianos, que pueden facilitar el análisis de imágenes (Marchant y Onyango, 2003), a pesar de que requieren la participación de un experto para entrenar el sistema correctamente. Otras técnicas más simples, como por ejemplo la umbralización, proporcionan una segmentación de imágenes más rápida, pero sólo funcionan adecuadamente cuando los objetos pertenecientes a las diferentes clases presentan colores distintos y bien definidos (Gunasekaran, 1987; Zion et al., 1995) y además dependen de un experto para determinar el umbral adecuado.

En esta tesis se ha colaborado, durante dos campañas, con el productor de granadas Frutas Mira Hermanos, S.L., con el fin de diseñar y desarrollar un prototipo basado en visión por computador capaz de inspeccionar y clasificar automáticamente arilos de granada en función de su calidad comercial. Esta tesis analiza los retos tecnológicos involucrados y desarrolla las soluciones de ingeniería aplicadas en el desarrollo del nuevo prototipo.

4.2 Objetivos

El objetivo es el desarrollo de sistemas para la clasificación automática de arilos de granada. Esta tarea incluye:

- El diseño de mecanismos para la individualización, transporte y separación de los arilos.
- El desarrollo de un sistema de inspección que incluya el diseño de la campana de inspección, el sistema de iluminación y la decisión sobre el número de cámaras a utilizar.
- El desarrollo de algoritmos de visión por computador para la inspección y clasificación de los arilos en tiempo real.
- El desarrollo de algoritmos y dispositivos para la sincronización de la unidad de inspección con el sistema de clasificación.
- La creación de un prototipo que permita probar todos los sistemas ideados.
- El desarrollo de procedimientos de comunicación y control para supervisar todo el prototipo, incluyendo una interfaz gráfica amigable con el usuario.

La solución propuesta debe permitir que el prototipo clasifique todos los objetos que salen de la máquina de extracción en hasta cuatro categorías, al tiempo que garantice una producción mínima de 250 kg de arilos/hora, lo que equivale al análisis de unos 140 arilos/s, ya que cada arilo tiene un peso aproximado de 0,5 gramos.

Los algoritmos de visión por computador deben evaluar el color de cada objeto individualmente y ser capaces de discriminar entre los arilos y otros materiales no deseados, principalmente los compuestos por trozos de pieles y membranas internas. Los algoritmos de control deben sincronizar la adquisición de imágenes de las cámaras, analizar las imágenes y controlar el desplazamiento de los objetos sobre las cintas transportadoras hasta activar el sistema de clasificación. El procesamiento de imágenes en tiempo real es esencial para lograr el rendimiento requerido. Es necesario comparar técnicas de clasificación intuitivas y rápidas, con el fin de decidir cuáles se implementan en el prototipo. La solución óptima debe consumir pocos recursos de cálculo y ser fácil de utilizar por un usuario sin experiencia. Por otra parte, la solución propuesta debe ser realizable para la empresa y fácil de mantener y limpiar debido a las exigencias de los estándares de calidad de las empresas agroalimentarias.

4.3 Materiales y métodos

El prototipo ideado consiste básicamente en tres elementos principales que corresponden con las unidades de recepción e individualización, inspección y separación (Figura 4.1).




Figura 4.1. Esquema del prototipo

4.3.1 Unidad de alimentación: separación y transporte de los objetos

Los objetos procedentes de la máquina de extracción viajan sobre una única cinta transportadora de 250 mm de ancho y el objetivo es conseguir que el producto se reparta horizontalmente sobre un número reducido de estrechas cintas transportadoras. Para ello se ha pensado en un sistema compuesto por una bandeja vibradora con una inclinación determinada. La inclinación de la bandeja y su movimiento de vibración hacen que los objetos se deslicen hacia adelante, siendo el reparto facilitado por unas cuñas situadas en esta bandeja (Figura 4.2). Al final, los objetos se dividen en seis cintas transportadoras de 30 mm de ancho que se desplazan a una velocidad relativamente alta (0,75 – 1,25) m/s, lo que en teoría facilita una separación individual de los distintos objetos que componen los objetos de entrada. Este paso es crucial, ya que permite al sistema utilizar técnicas de análisis de imágenes más sencillas y además expulsar cada objeto en su salida correspondiente. La pequeña anchura de las cintas evita grandes acumulaciones de material y facilita la separación de los objetos.

El color de las cintas transportadoras es muy importante, ya que va a representar el fondo de las imágenes, por ello se han realizado algunos experimentos encaminados a determinar el color que produce el mejor contraste entre las cintas y los arilos, de ese modo se facilita la segmentación de las imágenes. Se probaron cintas de diferentes colores antes de ser instaladas en el prototipo, tal y como se detallará posteriormente. Estas pruebas consistieron en la adquisición y segmentación de imágenes de arilos y membranas internas colocadas sobre muestras de cintas de color blanco, azul, verde, naranja y gris para posteriormente medir las diferencias de color entre fondo y arilo, así como el éxito de la clasificación.

Para establecer esta diferencia se utilizó el espacio de coordenadas de color CIELAB, ya que las relaciones entre sus coordenadas están ideas para simular la respuesta no lineal del ojo humano, de forma que los cambios en las componentes en el sistema se

corresponden con cambios en la percepción del color percibido, haciendo este espacio de color particularmente interesante para comparaciones (Jain, 1989). El contraste se ha medido como la distancia Euclídea del color medio de cada una de las clases y el fondo según la Ecuación 4.1.

$$\Delta E_{ab,i}^* = \sqrt{(L_f^* - L_i^*)^2 + (a_f^* - a_i^*)^2 + (b_f^* - b_i^*)^2} \quad (4.1)$$

Donde $\Delta E_{ab,i}^*$ es la distancia de color entre el fondo y la clase i , L_f^*, a_f^*, b_f^* son las coordenadas del color medio del fondo en espacio de color CIELAB y L_i^*, a_i^*, b_i^* son las coordenadas del color medio de la clase i .



Figura 4.2. Sistema de recepción e individualización

4.3.2 Unidad de inspección y sistema de visión por computador

Para abarcar el total de cintas transportadoras manteniendo una resolución adecuada para la inspección de un producto de tamaño tan pequeño se han utilizado dos cámaras color de escaneo progresivo (modelo JAI CV-M77, la misma que se utilizó en el capítulo anterior), con las que se han adquirido imágenes de 512 x 384 píxeles en formato RGB, con una resolución de 0,70 mm/píxel. Ambas cámaras se conectan a un ordenador, llamado *ordenador de inspección* (equipo con procesador Pentium 4 a 3,0 GHz y 1Gb de memoria RAM), por medio de una única tarjeta de adquisición de imágenes (CORECO PC-RGB utilizada también en el trabajo de campo) que las digitaliza y transfiere a la memoria del ordenador.

Cada cámara inspeccionará tres de las seis cintas transportadoras por lo que el tamaño de la escena viene condicionado por la separación de las mismas. Dado el factor de 4:3 (largo:ancho) de las cámaras, se ha considerado como más conveniente situarlas con orientación longitudinal para que el largo de la imagen adquirida corresponda a la dirección de avance de los objetos para maximizar el número de granos en las imágenes y minimizar la adquisición de las mismas. De este modo el ancho de la imagen deberá ser un poco mayor que el ancho de las tres cintas. Este valor se ha establecido en 270 mm, por lo que en cada imagen se inspeccionará 360 mm de cintas transportadoras.

Por lo tanto, según los cálculos anteriores, la escena capturada por cada cámara tiene una longitud de aproximadamente 360 mm a lo largo de la dirección del movimiento de los objetos y un ancho de 270 mm correspondientes a 3 cintas transportadoras. Siguiendo los datos mencionados comparativos de ópticas de la Tabla 3.2, en cada una de las cámaras se ha montado una óptica de 12 mm, por lo que las cámaras se sitúan a unos 900 mm de la escena. Se han utilizado estas ópticas en lugar de otras con menor distancia focal como las estándar de 8 mm porque al situarse la cámara a mayor distancia hace que los objetos en los laterales de las cintas no sean obstaculizados por los elementos de iluminación. A mayor distancia focal, el ángulo de visión disminuye (29° frente a los 35° de las ópticas de 8 mm) y la escena mantiene el mismo tamaño que si se situara la cámara a 600 mm con una óptica de 8 mm. Además no hay ninguna restricción en las dimensiones de la campana de inspección que impidiera que su altura sea más de un metro.

Respecto de la iluminación, se valoró la utilización de varios sistemas de iluminación como los descritos en el capítulo anterior, aunque únicamente se consideraron viables para esta aplicación los tubos fluorescentes y las tiras de LED, principalmente por la uniformidad de la luz que aportan a toda la escena.

Como ya se comentó, los tubos fluorescentes presentan grandes ventajas como son la uniformidad, buena distribución y alta luminosidad, aunque como inconvenientes aparecen el alto consumo, la complejidad del cableado y la alta disipación de calor. Todos estos inconvenientes son menos importantes en una máquina de selección que trabaja de forma estática en una empresa, mientras que las ventajas son muy a tener en cuenta. Incluso, gracias a que la luz que proporcionan es omnidireccional, se puede situar un tubo entre dos carriles para iluminar ambos, optimizando enormemente el sistema. Otro hándicap a mencionar de los tubos fluorescentes es su peligrosidad en caso de rotura, por lo que deberían estar convenientemente protegidos. Sin embargo los LED presentaban ciertos inconvenientes para su implementación. La primera y más importante, dado que el prototipo posee una zona de inspección mucho mayor que en el trabajo de campo y 6 carriles de inspección, es necesario un muy elevado número de elementos para conseguir una iluminación uniforme. Incluso, al proporcionar una iluminación direccional, se debería situar a ambos lados de cada carril, por lo que el número de elementos a instalar hace excesivamente costoso y complicado su montaje.

4. Selección automática de arilos de granada

Por lo tanto se decidió implementar un sistema de iluminación consistente en dos tubos fluorescentes compactos (Osram Dulux L 840/40 W) situados a ambos lados de cada cinta transportadora, lo que hace un total de 14 tubos. Como se trató en el capítulo anterior, las lámparas fluorescentes alimentadas con balastos estándar no aportan una luz continua, sino que muestran un parpadeo que depende de la frecuencia de la corriente alterna aplicada (en España, 50 Hz). Para evitar este efecto, los tubos se han alimentado con balastos electrónicos de alta frecuencia (Osram, Quicktronic professional QTP). Esta iluminación es suficientemente potente y uniforme y no produce sombras. La influencia de brillos en la escena causados por la reflexión de la luz directa sobre superficies húmedas puede alterar la percepción del color por parte del sistema de inspección. Por ello, al igual que en el capítulo anterior, se ha minimizado mediante el uso de filtros de polarización cruzada colocados entre las lámparas y las lentes de las cámaras.

Todo el sistema se aloja en una campana de acero inoxidable alimentario para protegerlo del entorno de trabajo. Además los tubos están protegidos por carcasas de plástico transparente que los protegen y que permiten incorporar los filtros polarizadores junto a ellos. Los ordenadores se situaron en un armario con el objetivo de protegerlos de alta humedad presente en el ambiente de trabajo.

En la Figura 4.3 se observa el interior de la campana de inspección con los elementos de iluminación a los lados de las cintas transportadoras.




Figura 4.3. Zona de inspección

4.3.2.1 Adquisición y análisis de imágenes en línea

Todo el software de análisis de imagen y de control del prototipo se ha programado específicamente para esta aplicación en lenguaje C++, utilizando el entorno de programación Ms. Visual Studio 6.0 y sin el uso de ninguna librería comercial con el fin de garantizar el control total de las operaciones y las respuestas en tiempo real. Uno de los principales logros del software desarrollado es la estrategia seguida para trabajar con las dos cámaras al mismo tiempo, ya que la adquisición de las imágenes es un proceso muy costoso temporalmente (40 ms por imagen). El software se ha diseñado para procesar una imagen obtenida con una cámara en paralelo con la adquisición de la imagen con la otra cámara. El resultado es que el procesamiento de una imagen y la adquisición de la siguiente se solapan en el tiempo, ahorrando así tiempo de procesamiento y optimizando la operación.

La adquisición de las imágenes se ha sincronizado utilizando los pulsos recibidos por un codificador óptico acoplado al eje del rodillo de arrastre y conectado al puerto serie del otro equipo, llamado *ordenador de control*. Se ha optado por un ordenador en lugar de un PLC como en el capítulo anterior debido a que este desarrollo se trataba más de un prototipo de investigación que una máquina industrial, como era el caso anterior, y el ordenador permitía mayor flexibilidad. Este equipo (similar al de inspección, con procesador Pentium 4 a 3,0 GHz y 1Gb de memoria RAM) utiliza una tarjeta PCI de entradas y salidas digitales (ADDI-DATA APCI-2032) tanto para enviar la señal de disparo de las cámaras como para activar las salidas del producto. El disparo de las cámaras se produce cada 350 mm de avance de la cinta, aunque se va alternando entre una cámara y otra para lograr el solapamiento entre adquisición y procesamiento antes comentado. Este diseño hace que la adquisición de las imágenes sea independiente de la velocidad de las cintas, y por lo tanto asegura que nunca haya superposición o pérdida de información entre imágenes consecutivas.

Para la segmentación de las imágenes se ha optado por un algoritmo orientado a píxel, ya que estos algoritmos son normalmente más rápidos que otras técnicas (por ejemplo, algoritmos orientados a regiones, análisis de texturas, etc.). Este algoritmo se ha hecho en base al color azul de las cintas transportadoras. El color de los arilos de granada varía entre el blanco y el rojo, que presentan una alta componente de rojo. De igual forma, las membranas internas son en su mayoría blancas, y por lo tanto también tienen una alta componente roja (además de verde y azul). Por otra parte, las cintas presentan un elevado componente azul y un bajo nivel de rojo. En consecuencia, para el algoritmo de segmentación se ha utilizado un umbral predefinido en la banda de rojo. Los píxeles con coordenadas de rojo por debajo de este umbral se han considerado que pertenecen al fondo. La Figura 4.4 ilustra este principio mostrando el histograma de la banda de rojo de un arilo típico rodeado por el fondo azul. El pico de la izquierda corresponde a los píxeles de fondo (valores bajos de rojo), mientras que el pico de la derecha representa los píxeles del arilo. Si bien se podía haber encontrado un método para hallar el mínimo entre ambos picos, dada la gran y constante

diferencia no se ha considerado necesario. El valor de este umbral entre los dos picos fue seleccionado manualmente por un experto.

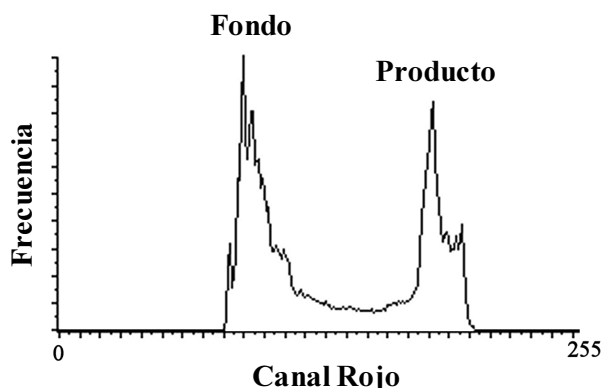


Figura 4.4. Histograma de la imagen en la banda roja

Una vez que el fondo se hubo eliminado de la imagen, cada región conexas fue etiquetada como un posible objeto de interés (bajo circunstancias normales, debería ser un arilo o algún otro objeto). Para cada región, el programa calcula el tamaño como la suma de sus píxeles, el centro de gravedad como la media aritmética de las coordenadas espaciales de sus píxeles y el color como la media aritmética de las coordenadas de color RGB de cada píxel. El tamaño de los arilos con los que se realizaron los experimentos sigue una distribución normal, con una media (μ) de 85,5 (en píxeles) y una desviación típica (σ) de 35,7. Aquellos objetos cuyo tamaño no estuvieron en intervalo $[\mu \pm 2\sigma]$ se consideraron como objetos extraños y clasificados como material no deseado.

Para el resto de objetos se utilizó la media aritmética de las coordenadas de color para clasificar el objeto en una de las cuatro categorías predefinidas. El procedimiento para determinar las clases se describe posteriormente. Después de procesar cada imagen, el *ordenador de inspección* envía la categoría, número de cinta transportadora y posición de cada uno de los objetos encontrados al *ordenador de control*, que se encarga de controlar el movimiento del objeto hasta que llega a la zona donde se clasifica.

Para medir la velocidad de procesamiento de las imágenes, se conectó un osciloscopio (Hameg, HM205-3) al puerto paralelo del *ordenador de inspección* de tal manera que al comienzo del análisis de la imagen, el equipo de visión mandaba una señal al osciloscopio para marcar el inicio del contador de tiempo. Al final del procesamiento de imágenes, una nueva señal marcaba el fin del periodo a contar. Esto se realizó con diferentes imágenes en las que todas ellas contenían, al menos 100 objetos, lo que representa aproximadamente el triple de los objetos teóricos para cada imagen y el máximo de objetos que se pueden analizar en cada imagen debido a necesidades de velocidad y computación. De esta forma se ha podido medir el tiempo transcurrido

entre las dos señales y determinar con precisión si el sistema alcanzó los requisitos de tiempo real.

4.3.2.2 Selección de la forma de representar el color de los objetos

Durante las pruebas se utilizaron granadas del cv. ‘Mollar de Elche’. El color de sus arilos varía desde el blanco-rosa (predominante al comienzo de la temporada) al rojo oscuro-marrón (más frecuente al final de la temporada) como se observa en la Figura 4.5.




Figura 4.5. Distintos tipos de arilos y pieles

Se crearon dos conjuntos de objetos (arilos y pieles) para el entrenamiento y validación a partir de muestras obtenidas de la máquina de pelado. Expertos de la empresa productora clasificaron los objetos de estos conjuntos en cinco categorías, siguiendo los estándares de calidad de la empresa. Estas categorías se nombraron de la siguiente manera: arilo blanco, arilo rosa, arilo rojo, arilo marrón (podrido) y desecho. En esta última categoría se colocaron principalmente trozos de piel y membranas internas, que eran en su mayoría blancas y más grandes que los arilos. El conjunto de entrenamiento se compuso de 100 arilos de cada categoría de color y 50 membranas (un total de 450 objetos). El conjunto de validación consistió en muestras independientes de 400 arilos de cada categoría y 100 membranas (1700 objetos). Las imágenes de todos estos objetos se adquirieron utilizando el prototipo en modo de operación normal, esto es, viajando los objetos sobre las cintas transportadoras.

Para estimar el color de los objetos se usaron las coordenadas RGB. Ahora bien, debido a la evolución natural de la fruta y su maduración durante la campaña, es habitual que durante el uso de máquinas automáticas de clasificación en la industria, se requieran frecuentes entrenamientos del sistema de visión por computador. Sin embargo, estas máquinas son generalmente manejadas por trabajadores sin ningún conocimiento de visión por computador o sin experiencia en estadística y que necesitan una forma rápida para adaptar el software de inspección a la evolución del

color del producto. Una técnica intuitiva y fácil de implementar en un panel de control son los umbrales de color utilizando interruptores virtuales en la interfaz gráfica de usuario. Por este motivo, para clasificar los objetos se usaron dos métodos: el primero, más sencillo e intuitivo, está basado en umbralizaciones de la imagen en los canales R, G, B y según la relación R/G; el segundo es más complejo desde el punto de vista estadístico y se ha utilizado para comparar el sistema basado en umbrales con otro teóricamente más robusto basado en análisis discriminante. La idea de usar la ratio R/G surge del análisis de las estadísticas básicas de la imagen, donde se comprueba que las bandas R y G presentan más variación que la B, y por ser una ratio encontrada en la literatura científica (Tijskens et al., 2005; Aynalem et al., 2006; Xiang et al., 2011).

Para el primer método, se establecieron umbrales para cada una de las clases de objetos a partir de los percentiles P_{10} y P_{90} de cada uno de los descriptores de color de cada clase. Para obtener una continuidad, cuando estos valores muestran distancias o solapamientos entre clases consecutivas, se utiliza el valor medio de la distancia o solape para definir los límites de cada clase. La Tabla 4.1 muestra, como ejemplo, las estadísticas básicas de la relación R/G para las diferentes categorías y los umbrales seleccionados. Los percentiles P_{10} y P_{90} se superponen sólo para las categorías de color rojo y marrón, lo que podría causar confusión entre ellas.

Tabla 4.1. Estadísticas básicas de las diferentes clases para la ratio R/G

	Media	Desv. típica	P_{10}	P_{90}	Umbrales
Rechazo	97,8	1,3	96,1	99,5	0-107
Arilo blanco	125,1	8,2	115,0	133,3	108-133
Arilo rosa	139,7	7,2	134,6	144,7	134-144
Arilo marrón	155,2	8,1	145,8	166,7	145-165
Arilo rojo	183,1	14,4	164,8	202,0	166-255

Sin embargo, esta es una técnica que, aunque muy útil desde un punto de vista práctico, es relativamente sencilla y puede no representar la solución óptima al problema al tratarse de un método manual y subjetivo, por lo que se decidió compararla con los resultados obtenidos utilizando un método estadístico completamente objetivo como es el LDA de forma similar al entrenamiento realizado para la preclasificación automática de la fruta en campo. El LDA se puede considerar como un análisis de regresión donde la variable dependiente es categórica y tiene como categorías la etiqueta de cada una de las clases, y las variables independientes son continuas y determinan a qué grupos pertenecen los objetos. Se basa en el teorema de Bayes (Bayes, 1783) (4.2):

$$P(w_i|x) = \frac{p(x|w_i)P(w_i)}{\sum_{j=1}^m p(x|w_j)P(w_j)} \quad (4.2)$$

donde x es el vector observado (en nuestro caso, los valores RGB de un objeto), w_i ($i = 1..m$) es una de las m clases diferentes, m es el número de clases (5 en nuestro caso), $P(w_i)$ es la probabilidad a priori de que un objeto pertenezca a la clase w_i (esta probabilidad se consideró la misma para cada clase) y $p(x|w_i)$ es la función de densidad condicional de los valores RGB en la clase w_i (suponemos que todas estas funciones de densidad son Gaussianas con igual matriz de covarianza). Lo que esta función nos da es la probabilidad $P(w_i|x)$ de que una observación x pertenezca a la clase w_i , por lo que el modelo genera una función discriminante para cada una de las clases.

Los umbrales y las funciones de clasificación obtenidas con el LDA se obtuvieron empleando el conjunto de entrenamiento. La evaluación de los dos métodos de clasificación se realizó implementando todas las funciones discriminantes en el software de análisis de imágenes y clasificando automáticamente todos los objetos del conjunto de validación. Estos resultados se compararon con la clasificación realizada por personal experto, a fin de construir la matriz de confusión para cada método. Las pruebas se realizaron al inicio y al final de la campaña de la granada para observar si existen o no cambios en el rendimiento de los algoritmos de clasificación.

4.3.3 El sistema de clasificación

La zona de clasificación va a continuación de la campana de inspección (Figura 4.6). De común acuerdo con la empresa productora, se decidió crear un prototipo con cuatro salidas de producto diferentes ya que satisface sus necesidades y las de este tipo de productos en general. Éstas se colocaron tras la zona de inspección y consisten en unos huecos dispuestos en uno de los lados de cada cinta transportadora. Frente a cada salida, en el otro lado de la cinta transportadora, se colocaron de manera precisa eyectores de aire para expulsar el producto.

El *ordenador de control* es el encargado de monitorizar el movimiento de los arilos por las cintas a partir de los datos de posición enviados desde el *ordenador de inspección*, y activar los eyectores de aire cuando es necesario. Para ello usa una tarjeta con 32 salidas digitales que activa mediante señales eléctricas las electroválvulas que gobiernan a los eyectores de aire. El movimiento de las cintas transportadoras, y con ello la monitorización de la posición de los arilos, se realiza mediante la lectura de las señales producidas por el codificador óptico acoplado al eje del rodillo de arrastre.

El codificador óptico que se ha utilizado (Wachendorff WDG 40S-1500-ABN-G05-K1) envía 1500 señales o pulsos por cada vuelta de su eje, lo que proporciona aproximadamente 3 pulsos por cada mm de avance de las cintas.

Para realizar el calibrado de este sistema, se situó una pieza de color negro en una posición muy concreta del prototipo y a una distancia conocida de los eyectores. Se capturó una imagen de esta pieza y se obtuvieron sus coordenadas (x , y) en la imagen (en píxeles). Conociendo la resolución de la imagen en píxeles/mm fue posible

calcular con precisión la distancia desde el origen de coordenadas de la imagen hasta cada uno de los eyectores en mm. Conociendo entonces la ratio de conversión mm/pulsos del codificador (en este caso 0,3 mm/pulso), fue posible determinar la distancia en pulsos de codificador entre una posición concreta de la imagen y los eyectores.



Figura 4.6. Zona de separación y clasificación de arilos

El *ordenador de inspección* calcula para cada objeto la posición (x, y) en la imagen, y se la envía al *ordenador de control*, junto con la clase a la que pertenece el objeto encontrado, a través del protocolo de comunicaciones TCP/IP. Esta comunicación se llevó a cabo utilizando el protocolo TCP/IP, tarjetas de red Ethernet en ambos ordenadores y un cable de red cruzado que permite una comunicación directa entre ambos equipos sin la necesidad de utilizar un concentrador. Se valoró el uso de otro tipo de buses de comunicaciones industriales como puede ser RS-485, CAN, etc., pero se descartaron porque utilizando las tarjetas de red de los equipos era suficiente y no era necesario adquirir ningún hardware específico. En las pruebas previas a la instalación del prototipo en la empresa se comprobó que de este modo la aplicación funcionaba perfectamente incluso a la máxima velocidad del prototipo, ya que desde que se analizan las imágenes y se envían los resultados hasta que los objetos se expulsan hay tiempo más que suficiente para recibir los datos y preparar la expulsión.

Como primer paso al iniciar las aplicaciones en ambos equipos, se crean *sockets* o mecanismos de comunicación de paquetes de datos que contienen las direcciones IP local (*ordenador de inspección*) y remota (*ordenador de control*), un protocolo de transporte de datos (protocolo IP) y dos puertos de comunicaciones, uno local en el *ordenador de inspección* y otro remoto en el *ordenador de control*. Antes de iniciar la inspección se comprueba que los dos equipos están correctamente comunicados, en caso contrario se muestra un error en pantalla.

En el momento que comienza la adquisición de la primera imagen, se envía un mensaje de sincronización para que ambos equipos puedan llevar el control del número de imágenes capturadas. Al finalizar el análisis de cada imagen, el *ordenador de inspección* envía al *ordenador de control* dos mensajes; uno que contiene el número de datos a enviar y un segundo que contiene esos datos. Cada dato incluye la información sobre la clase y posición de cada objeto encontrado en la imagen y que se debe expulsar de las cintas. Los objetos que pertenecen a la primera categoría (arilos rojos) no se expulsan sino que continúan hasta el final de las cintas, por lo que su existencia no se comunica al *ordenador de control*. Por lo tanto, tras el análisis de una imagen se envían $n+1$ mensajes correspondientes a los n objetos que se deben expulsar.

Al finalizar la inspección, se envía un mensaje de parada para indicar que ya no se deben realizar nuevas fotos, ni esperar más mensajes.

Cada mensaje consta de 24 bits (3 bytes) que pueden incluir información de sincronización con el *ordenador de control* o datos para la expulsión de los objetos. Se ha intentado reducir al máximo la información a enviar entre el *ordenador de control* y el de visión pero siempre teniendo en cuenta posibles ampliaciones futuras, como un mayor número de carriles o de zonas de salida.

La estructura de un mensaje es la siguiente:

1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
CODIGO				ZONA_SALIDA				CINTA				DATOS										

Donde cada campo puede tener los siguientes datos:

- **CODIGO:**

1 → INICIO: Se utiliza para indicar al *ordenador de control* que ya se han ajustado las referencias en la imagen y que debe comenzar la adquisición y análisis de las imágenes.

2 → RESET: Se inicializan a cero los contadores de imágenes para asegurar que coinciden el número de fotos solicitadas por el *ordenador de control* con el de realizadas.

3 → DATO: El mensaje contiene un dato en el campo DATOS que deberá leerse.

4 → PARADA: Indica al *ordenador de control* que se ha ordenado una parada en la inspección.

5 → ERROR: Indica al *ordenador de control* que se ha producido un error. El número de mensaje de error se indicará en el campo DATOS.

6..15 → Disponibles para añadir nuevos mensajes de control.

- **ZONA_SALIDA:**

1 → Zona de salida 1, que corresponde a la categoría de mayor calidad. En esta categoría no se expulsan los objetos, por lo que no se utiliza.

2, 3, 4 → Zonas de salida 2, 3 y 4 configurables por el usuario para eliminar los objetos de las cintas según la categoría seleccionada.

5..15 → Zonas de salida disponibles para posibles futuras ampliaciones.

- **CINTA:**

1..6 → Cintas numeradas del 1 al 6, siendo el primero el de la izquierda en el sentido de avance de las cintas.

7..15 → Cintas disponibles para posibles futuras ampliaciones.

- **DATOS:**

Si el CODIGO enviado corresponde con un DATO y es el primer elemento del vector de mensajes, contendrá el número de objetos a expulsar correspondientes a la última imagen analizada (que es el número de mensajes que se envían a continuación). Para los siguientes mensajes del vector, correspondientes a cada uno de los objetos, este campo contiene el número de pulsos que tendrá que contar el *ordenador de control* hasta la activación de la electroválvula de expulsión correspondiente. La información sobre la CINTA y ZONA_SALIDA se utiliza para establecer qué eyector de aire de la cinta se tiene que utilizar para cada objeto. El *ordenador de control* cuenta el número de pulsos del codificador óptico necesarios para que el objeto alcance la posición del eyector, y va disminuyendo esta cuenta cada vez que recibe un nuevo pulso desde el codificador óptico. De este modo, cuando el contador llega a cero, en teoría el objeto debe pasar justo frente al eyector seleccionado, por lo que el ordenador activa la correspondiente electroválvula.

Si el CODIGO indica ERROR, este campo contendrá el código de error que se ha producido. En otros casos no se usa.

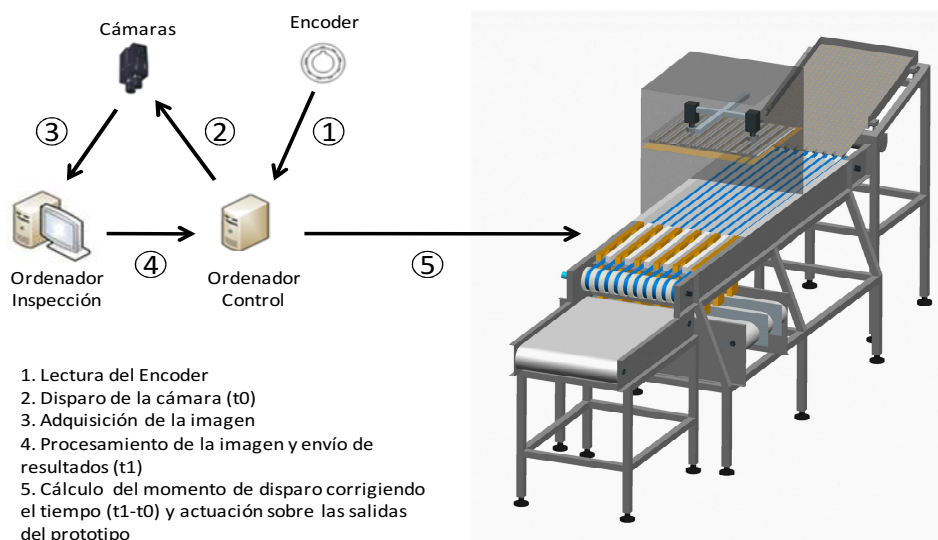


Figura 4.7. Esquema del mecanismo de sincronización

Hay que tener en cuenta que entre que se adquiere la imagen y el *ordenador de control* recibe los datos, pasa un tiempo durante el cual el objeto avanza sin el “conocimiento” del *ordenador de control*. Para paliar este problema el propio *ordenador de control* se encarga de solicitar la captura de la imagen y de esta forma conocer el número de pulsos transcurridos entre ese disparo y la recepción de la información correspondiente a esa imagen. Para ello, el *ordenador de control* mantiene un contador empleado para el disparo de la cámara de forma que por cada 350 mm de avance de la cinta (1166 pulsos), se adquiere una imagen. Cuando recibe la información de esa imagen, al contador de pulsos de cada objeto le descuenta los transcurridos entre la adquisición y la recepción de la información, obteniendo así una gran precisión que se adapta a cualquier velocidad de la cinta. Un esquema del mecanismo de sincronización se muestra en la Figura 4.7.

4.3.4 Pruebas del prototipo en condiciones comerciales. Evaluación global de su rendimiento

Tras diferentes pruebas preliminares de puesta a punto, una vez que el prototipo estuvo listo, se montó en las instalaciones de la empresa colaboradora para la realización de pruebas en entorno industrial y se configuró para realizar la separación de arillos y material no deseado como se describió anteriormente. El prototipo se probó en condiciones reales de trabajo durante un período de 6 meses, que equivale a una campaña completa de granada.

Durante las pruebas, el prototipo inspeccionó más de 9 toneladas de objetos. Fue inviable evaluar los resultados de la clasificación individual de cada objeto, ya que al

trabajar en condiciones comerciales resultó imposible detener la línea para poder comparar la clasificación de los objetos individuales realizada por el prototipo de la realizada por personal experto. Por esta razón, la evaluación se llevó a cabo a partir de los lotes producidos por el prototipo. Un equipo formado por tres expertos de la empresa analizó muestras aleatorias obtenidas de las diferentes zonas de salida del prototipo, dando cada uno de ellos una opinión global subjetiva del funcionamiento del sistema de inspección para cada categoría. Cada experto decidió si la clasificación automática era buena, regular o mala, y la decisión final del equipo fue considerada como aquella en la que dos o tres de ellos habían coincidido.

4.4 Resultados

Los principales resultados de este capítulo se integran en el capítulo principal que es la implementación de una solución automática basada en visión por computador para la clasificación de una fruta mínimamente procesada como es el arilo de granada. El diseño, desarrollo y prueba de este prototipo (ver Figura 4.8) constituye por sí mismo un importante logro para el que han sido necesarios los logros parciales que se describen a continuación.



Figura 4.8. Prototipo montando en la empresa colaboradora

4.4.1 Unidad de alimentación y transporte

La unidad de alimentación basada en una plataforma vibradora ha funcionado correctamente durante las pruebas. Para conseguir una correcta individualización del

producto, se consideraron otras soluciones, como por ejemplo la caída de la fruta en unos embudos asistidos por aire y que desembocaban en las cintas, que no funcionaron debido a que los arilos se adherían en las paredes provocando atoramientos.

Uno de los problemas encontrados con la solución propuesta es que, debido a la propia vibración de la plataforma y a la velocidad de las cintas transportadoras, algunos arilos entraban en la zona de inspección sin haberse estabilizado todavía sobre la cinta, esto es, literalmente rebotando sobre la misma. Este movimiento de los objetos sobre las cintas produjo errores en la sincronización entre la inspección y la unidad de clasificación y, en consecuencia, algunos objetos no llegaban a la salida adecuada. Sin embargo, se trata solamente de un problema mecánico, fácilmente solucionable alargando la zona comprendida entre la plataforma vibradora y la zona de inspección para dar espacio suficiente a esta estabilización, por lo que no se realizó ninguna acción correctora en este sentido.

En otras máquinas para la inspección de frutas pequeñas se han utilizado rodillos bicónicos con movimiento de rotación, como por ejemplo para aceitunas (Díaz et al., 2000). Estos dispositivos permiten al sistema inspeccionar prácticamente toda la superficie de los objetos mediante la adquisición de imágenes mientras rota el objeto. Además, proporcionan una forma de aislar los objetos individuales. Sin embargo, esto resulta inviable para un producto como éste dada su fragilidad y lo pegajoso que resulta por su alto contenido en azúcares. Además, en este caso, como el color se distribuye de igual forma por ambos lados, es suficiente con inspeccionar el producto únicamente por una cara y una única imagen proporciona toda la información necesaria para asignar el objeto a una determinada clase.

En cuanto a la decisión sobre el color de las cintas transportadoras, en la Figura 4.9 se puede observar los diferentes fondos probados para las cintas.

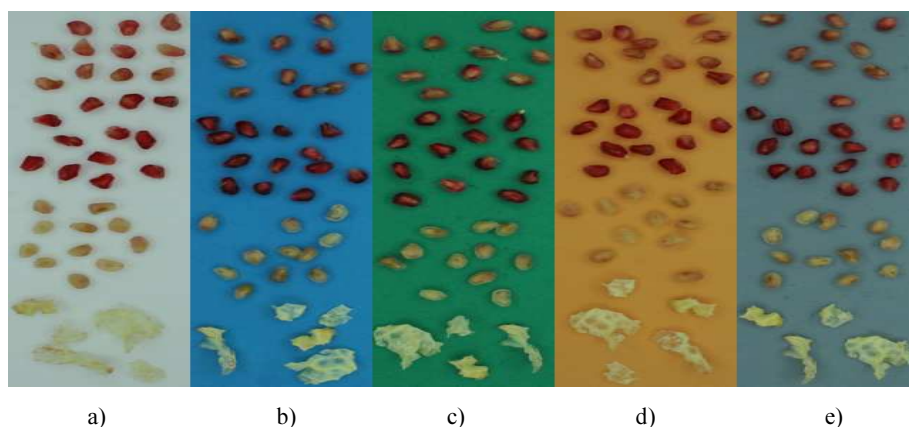


Figura 4.9. Ensayos para elegir el color de la cinta transportadora

La Tabla 4.2 muestra los valores medios del color de los distintos tipos de arilos y pieles (en valores RGB y CIELAB), situados sobre las diferentes cintas

4. Selección automática de arilos de granada

transportadoras probadas. Hay que tener en cuenta que los arilos son translúcidos, por lo que su color medio se ve afectado por el color del fondo y por eso presentan valores diferentes para cada cinta. La columna de la derecha muestra la distancia Euclídea del color de las distintas clases de interés en el espacio CIELAB, respecto del fondo (ΔE^*_{ab}). Al ser un espacio de color perceptual, estas distancias se pueden tomar como valores de contraste. Así, por ejemplo, se observa que para distinguir las pieles o los arilos blancos del fondo, es conveniente usar una cinta de fondo azul, mientras que para distinguir los arilos rojos y rosas es más apropiada una cinta blanca. Por el contrario, las pieles no se contrastan bien con una cinta blanca. En valores medios, el color del fondo blanco presenta una distancia métrica de 42,3 respecto a los colores del resto de clases, el fondo azul una distancia de 46,8, el fondo verde 36,5, el fondo naranja 24,7 y el fondo gris una distancia de 33,5. Por tanto, se decidió seleccionar una cinta transportadora de color azul.

Tabla 4.2. Colores promedio en los espacios de color RGB y CIELAB, y distancia entre el color del fondo y los diferentes tipos de objetos sobre las cintas transportadoras

AZUL	R	G	B	L*	a*	b*	ΔE^*_{ab}
Fondo	28	109	152	43,44	-7,86	-30,71	
Piel	120	154	122	60,35	-18,08	12,44	47,46
Blancos	99	107	83	43,93	-7,54	12,01	42,73
Rojos	64	28	31	15,59	17,97	5,86	52,73
Rosas	84	63	55	28,68	8,01	8,10	44,45
BLANCO	R	G	B	L*	a*	b*	ΔE^*_{ab}
Fondo	160	177	170	70,75	-6,97	0,84	
Piel	150	159	109	63,66	-11,44	24,53	25,14
Blancos	138	122	78	51,69	-0,13	25,88	32,20
Rojos	106	35	32	24,86	31,68	18,77	62,61
Rosas	124	70	52	35,82	21,42	20,46	49,10
GRIS	R	G	B	L*	a*	b*	ΔE^*_{ab}
Fondo	82	111	113	44,74	-9,76	-5,08	
Piel	135	153	106	60,66	-14,63	22,11	31,89
Blancos	116	110	72	46,09	-3,67	21,64	27,44
Rojos	83	36	33	20,87	21,75	12,15	43,12
Rosas	100	69	52	32,29	11,20	15,25	31,73
NARANJA	R	G	B	L*	a*	b*	ΔE^*_{ab}
Fondo	165	121	50	53,93	10,12	43,93	
Piel	160	149	87	61,36	-4,62	33,61	19,47
Blancos	145	108	51	48,24	8,53	36,55	9,44
Rojos	107	31	18	24,16	33,23	26,85	41,37
Rosas	125	62	32	33,79	25,03	29,95	28,69
VERDE	R	G	B	L*	a*	b*	ΔE^*_{ab}
Fondo	18	112	76	41,59	-35,07	12,36	
Piel	123	155	101	60,42	-21,04	24,27	26,32
Blancos	101	114	65	45,88	-13,36	25,12	25,54
Rojos	70	38	29	19,13	14,13	12,20	54,08
Rosas	90	73	48	32,15	3,53	17,34	40,04

En el cubo de color RGB de la Figura 4.10 se ve gráficamente que el fondo de color azul es el que mayor separación presenta, también en este espacio de color, es el que más se separa de las muestras de pieles y de toda la variedad de arilos de granada que podemos encontrarlos.




Figura 4.10. Separación de los colores de las cintas transportadoras probadas y del producto en el cubo RGB

4.4.2 Unidad de inspección y sistema de visión por computador

4.4.2.1 Optimización del análisis mediante umbrales. Comparación con LDA

Analizando imágenes almacenadas durante toda la campaña, se pudo comprobar que el color de los granos evoluciona con el tiempo, tal y como muestra la Figura 4.11. Al principio de la campaña presentan valores relativamente bajos que van aumentando a lo largo del tiempo, por lo que se realizaron pruebas al principio y al final de la campaña.

La Tabla 4.3 muestra la tasa media de éxito obtenido sobre el conjunto de validación cuando se utilizan los umbrales definidos únicamente en R, G y B y según la relación R/G, para distinguir arilos blancos, rosas, rojos y marrones, así como material no deseado. El éxito global es bajo (52 %) cuando se utilizan sólo los valores del canal R. Esto se debe a que todas las categorías tienen valores de componente roja relativamente altos, lo que hace aumentar la confusión entre las categorías tal y como se esperaba a partir de la observación de las estadísticas básicas antes de la realización de los experimentos. Se obtuvo también un éxito global bajo cuando se utilizaron sólo las bandas R y G, alcanzando valores de 61 % y 67 % respectivamente. A pesar de que

4. Selección automática de arilos de granada

las cinco categorías promediaron diferentes valores G y B, la alta variabilidad de los arilos dentro de las diferentes categorías impidió que se pudieran separar correctamente utilizando este método. Sin embargo, el uso de la relación R/G mejoró considerablemente los resultados, obteniendo un 90 % de éxito.

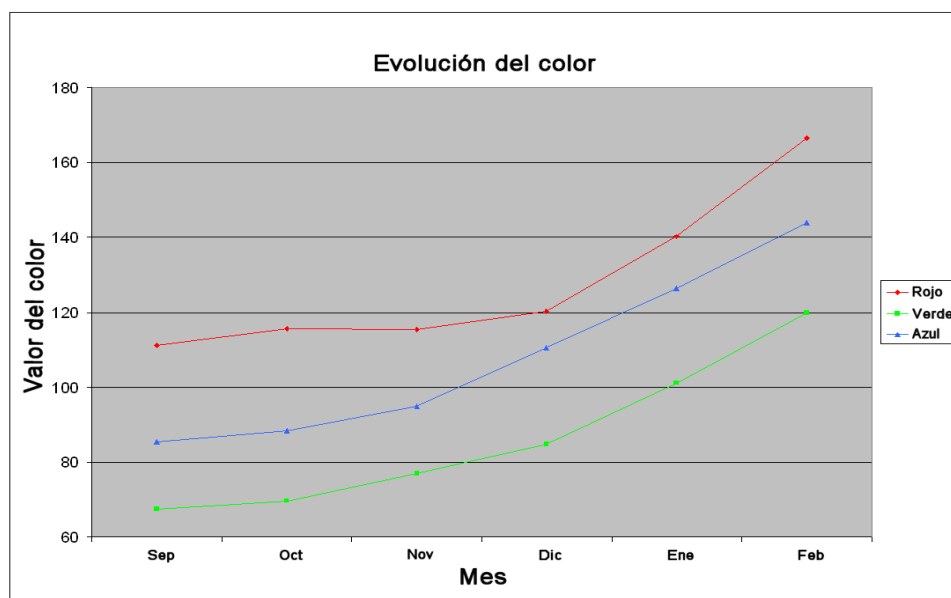


Figura 4.11. Evolución del color de los granos en granadas de la variedad 'Mollar de Elche' a lo largo de una campaña

Tabla 4.3. Porcentajes de éxito en la clasificación sobre el conjunto de validación empleando umbrales en las coordenadas de color (valores en tanto por ciento)

Categoría	R	G	B	R/G
Arilo blanco	48,6	68,1	69,9	92,0
Arilo rosa	41,8	54,7	64,8	91,4
Arilo rojo	58,1	73,1	62,6	89,2
Arilo marrón	49,6	61,1	58,0	89,0
Rechazo	88,9	100	83,7	98,3
Promedio	52,4	67,2	61,2	92,1

Los resultados obtenidos empleando la relación R/G fueron aceptables tanto al comienzo como al final de la campaña. La Tabla 4.4 y Tabla 4.5 muestran la matriz de confusión entre la clasificación manual y automática para el conjunto de validación utilizando los umbrales definidos en la Tabla 4.1, al comienzo y final de la campaña respectivamente. Estas tablas también muestran que el material no deseado (rechazo) fue la clase que obtuvo una mayor tasa de acierto en la clasificación (98 %). Esto se

puede explicar por el hecho de que el color y el tamaño de los objetos que componen esta clase son muy diferentes a los de los arilos. Las clases más importantes desde el punto de vista de la producción son arilos rojos (excelentes) y arilos marrones (se deben rechazar), alcanzando un éxito en la clasificación del 89 % al comienzo de la temporada y alrededor del 85 % al final de la misma. La confusión entre estas dos clases fue mayor que en cualquier otro par de clases, probablemente debido a la superposición de sus valores de color, como se pone de manifiesto en la Tabla 4.1. Los mejores resultados se obtuvieron para las clases de arilos blancos y rosas. Hay que señalar que los arilos experimentan una evolución en su color conforme la granada madura a lo largo de la temporada, lo que podría explicar el aumento de la confusión entre las clases al final de la campaña.

Tabla 4.4. Matriz de confusión de la clasificación realizada al comienzo de la temporada utilizando valores de umbral basados en la ratio R/G. Resultados referidos al conjunto de validación (valores en tanto por ciento)

	Automático	Arilo blanco	Arilo rosa	Arilo rojo	Arilo marrón	Rechazo
Manual						
Arilo blanco		92,0	4,0	0,0	2,7	1,3
Arilo rosa		1,5	91,4	1,5	5,6	0,0
Arilo rojo		0,0	2,3	89,2	8,5	0,0
Arilo marrón		0,8	4,7	5,5	89,0	0,0
Rechazo		1,7	0,0	0,0	0,0	98,3

Tabla 4.5. Matriz de confusión de la clasificación realizada al final de la temporada utilizando valores de umbral basados en la ratio R/G. Resultados referidos al conjunto de validación

	Automático	Arilo blanco	Arilo rosa	Arilo rojo	Arilo marrón	Rechazo
Manual						
Arilo blanco		89,4	7,3	0,0	2,0	1,3
Arilo rosa		4,0	88,0	1,7	6,3	0,0
Arilo rojo		0,7	3,0	85,7	10,3	0,0
Arilo marrón		2,0	5,3	11,3	81,3	0,0
Rechazo		1,7	0,0	0,0	0,0	98,3

Los resultados de la clasificación obtenidos con el conjunto de validación al inicio de la temporada utilizando LDA se muestran en la Tabla 4.6. En general, todas las categorías se clasificaron relativamente bien, especialmente el material no deseado con una tasa de éxito del 100 %, aunque el 1 % de arilos blancos se clasificaron erróneamente en esta clase. En este caso, también se obtuvo una confusión en torno al 3 % entre las clases de arilos rojo y marrón. La tasa media de éxito de este método se situó cerca de un 92 % en todas las categorías al inicio de la temporada. Sin embargo, las pruebas realizadas al final de la temporada demostraron que decrecía el rendimiento del sistema en todas las categorías, especialmente en la categoría de arilos rojos, y sobre todo en la categoría de arilos marrones, en la que se redujo a un 83 % (Tabla 4.7). La confusión entre ambas clases aumentó a más del 10 %.

4. Selección automática de arilos de granada

Tabla 4.6. Matriz de confusión obtenida al inicio de la campaña usando LDA en el conjunto de validación (valores en tanto por ciento)

Automático	Arilo blanco	Arilo rosa	Arilo rojo	Arilo marrón	Rechazo
Manual					
Arilo blanco	93,3	3,3	0,0	2,3	1,0
Arilo rosa	2,0	91,7	4,3	2,0	0,0
Arilo rojo	0,0	5,3	91,3	3,3	0,0
Arilo marrón	1,0	2,7	3,0	91,3	0,0
Rechazo	0,0	0,0	0,0	0,0	100,0

Tabla 4.7. Matriz de confusión obtenida al final de la campaña usando LDA en el conjunto de validación (valores en tanto por ciento)

Automático	Arilo blanco	Arilo rosa	Arilo rojo	Arilo marrón	Rechazo
Manual					
Arilo blanco	91,3	6,3	0,0	1,3	1,0
Arilo rosa	3,0	90,0	1,7	5,3	0,0
Arilo rojo	0,3	2,0	86,7	9,0	0,0
Arilo marrón	1,3	4,7	10,7	83,3	0,0
Rechazo	0,7	0,3	0,0	0,0	99,0

Se pueden interpretar las magnitudes de los coeficientes como indicadores de la importancia relativa de las variables en cada función discriminante. Así, si un coeficiente es grande en valor absoluto, entonces hay una fuerte asociación entre su variable asociada y la clase a la que pertenece la función. Dado que el espacio de los valores R, G y B es el mismo, se puede considerar que cuanto mayor sea el coeficiente, mayor es la importancia de la variable para determinar la clase en la que estaría. Como se observa en la Tabla 4.8, las variables G y R demostraron tener un mayor peso mientras que la variable B demostró tener un peso relativamente bajo, lo que reforzó la idea de usar la relación R/G para representar el color de los arilos.

Tabla 4.8. Coeficientes de la función de clasificación obtenida utilizando LDA

Clase	Arilo blanco	Arilo rosa	Arilo rojo	Arilo marrón	Rechazo
Variable					
Verde	0,38	-0,07	-0,38	-0,76	1,80
Rojo	0,08	0,41	0,61	0,86	-0,81
Azul	-0,04	-0,05	-0,05	-0,02	-0,16
Constante	-34,0	-28,3	-27,7	33,6	-99,3

4.4.2.2 Velocidad de procesamiento

El tiempo que necesita el *ordenador de inspección* para procesar una imagen fue de unos 15 ms, lo que hace posible el análisis de hasta 65 imágenes/s. Sin embargo, el análisis está limitado por la frecuencia de adquisición de imagen de las cámaras empleadas (25 imágenes/s), que aun así se redujo a 12 imágenes/s debido a las limitaciones mecánicas del prototipo. Esto abre la posibilidad de incluir soluciones

más sofisticadas en el prototipo, como por ejemplo algoritmos de aprendizaje similares a los propuestos por Picus y Peleg (2000) para dátiles, con el fin de adaptar automáticamente los parámetros de la clasificación a la evolución en el color de los arilos.

4.4.3 Unidad de clasificación

A pesar de que el diseño permite una precisión en el seguimiento de la posición de las cintas de 0,3 mm, las pruebas mostraron que se requiere una separación mayor entre los objetos para clasificarlos con cierta precisión. Los chorros de aire producidos por las boquillas generan un flujo en forma de cono que arrastra a todos los objetos dentro de su volumen de influencia. Experimentos realizados fuera de línea demostraron que, para una velocidad de las cintas transportadoras de 1000 mm/s, se requiere una separación de 20 mm entre dos objetos consecutivos para que sean correctamente expulsados. Por otro lado, el actual diseño del software permite incorporar fácilmente a los algoritmos un mayor número de categorías, si bien el rendimiento de los clasificadores decrece conforme el número de clases aumenta (Duda et al., 2001). La Figura 4.12 muestra ejemplos de los arilos clasificados por las diferentes salidas.



Figura 4.12. Granos escogidos al azar de las diferentes salidas del prototipo

4.4.4 Ensayos intensivos bajo condiciones comerciales

Dado que las tasas medias de éxito de ambos métodos (umbrales y LDA) fueron similares (tan sólo difieren en un 1 % en cada categoría), se decidió utilizar el más sencillo de implementar en un interfaz de usuario, que es el basado en umbrales. Éstos son más fáciles de ajustar por parte de los trabajadores si observan desviaciones en la clasificación debidas a la evolución del color o cualquier otra influencia externa o simplemente a posibles estrategias comerciales. Por ejemplo, si la producción de arilos de categoría excelente (rojos) es elevada, se puede ser más estricto. Si por el contrario hay una elevada presencia de granos rosas, la tolerancia a su clasificación como excelentes puede ser mayor. Además, este método es más rápido de ejecutar y permitió reducir el tiempo de procesamiento de las imágenes. La Figura 4.13 muestra

4. Selección automática de arilos de granada

la interfaz de usuario que permite realizar estos ajustes (izquierda) y la pantalla de visualización de la inspección (derecha).

La inspección automática de las categorías de rechazo, arilos blancos y arilos de color rosa se consideró como buena durante toda la campaña por el grupo de expertos. Sin embargo, la clasificación de los arilos de color rojo y marrón se consideró buena sólo durante los primeros cuatro meses. Al final de la temporada, el rendimiento de la clasificación disminuyó, debido a que la confusión entre los arilos rojos y marrones fue mayor. El rendimiento del prototipo durante las últimas pruebas realizadas en enero de 2009 fue de unos 220 kg de arilos por hora en condiciones de puesta a punto, posteriormente disminuía con el uso hasta unos 180 kg/h.




Figura 4.13. Pantallas de ajuste de parámetros y visualización de la inspección

Las particularidades de los arilos de granada hacen que sean muy difíciles de manipular y clasificar. Este prototipo es único y diferente a otras máquinas diseñadas para la clasificación de fruta pequeña que se pueden encontrar en el mercado, por ello el prototipo se ha patentado en colaboración con la empresa productora de arilos, ya que algunas de las soluciones presentadas se pueden adaptar y emplear para otros productos similares como se verá en el capítulo siguiente. Aunque se pueden encontrar fácilmente en la literatura científica técnicas de procesamiento de imágenes similares a la descrita en este documento, este trabajo no se centra únicamente en el desarrollo de un sistema de visión por computador, sino que además lo integra en nuevas soluciones de ingeniería para automatizar la clasificación de arilos de granada. Las soluciones tecnológicas adoptadas y los algoritmos presentados en esta tesis han demostrado ser relevantes en la aplicación de visión por computador con el fin de automatizar esta tarea, y han hecho que sea factible la propuesta de comercialización de arilos de granada listos para comer.



Figura 4.14. El prototipo durante los ensayos intensivos

Estas pruebas han permitido confeccionar un listado de mejoras posibles al prototipo que quedan como trabajo futuro. Entre estos problemas cabe destacar:

- Una excesiva cantidad de grano y una distribución poco uniforme puede llegar a atascar el vibrador con el paso del tiempo debido a que los arilos se pueden quedar pegados en algunas zonas, por lo que se aconseja un sistema más sencillo de regulación y el rediseño de algunas partes del vibrador.
- Los arilos puede llegar a caerse de las cintas antes de llegar al sistema de visión por lo que es conveniente encauzar bien las cintas.
- Los arilos se pegan en las cintas debido al alto contenido en azúcar. También se pegan a los sistemas laterales de protección de las cintas, por lo que se aconseja un sistema de autolimpieza de las cintas.
- Los arilos no van alineados en las cintas, a veces se golpean contra algunos laterales mal instalados y caen en la zona de expulsión. La acumulación provoca que se clasifiquen erróneamente por arrastre.

- Dificultad para extraer los arilos de las salidas inferiores. Se quedan pegados a los tubos de las salidas inferiores siendo un foco de suciedad. Se aconseja rediseñar las salidas para mejorar este problema.
- La parte de las cámaras es demasiado accesible. Al limpiar el prototipo es fácil modificar la configuración de las cámaras, lo que puede perjudicar a la inspección.
- El prototipo es difícil de limpiar debido a que las partes de transporte y expulsión son fijas y llenas de cavidades poco accesibles. Las salidas deberían ser desmontables.
- Si el prototipo se detiene, los arilos se acumulan en el vibrador. Todos los sistemas deberían estar conectados de forma que si uno para, lo hicieran todos.
- El prototipo no dispone de ruedas que faciliten su transporte y permita apartarla en caso de mantenimiento o avería.

Como se observa, muchos de estos problemas y consejos requieren de soluciones más propias de una empresa de fabricación de máquinas y no de una tesis doctoral, por lo que quedan como posibles mejoras de forma a la creación de una futura máquina de clasificación automática. La Figura 4.14 muestra una fotografía del prototipo durante los primeros ensayos intensivos.

4.5 Discusión

Este trabajo aporta una solución nueva para la clasificación automática de arilos de granada. Se ha desarrollado un prototipo preparado para la inspección y clasificación de este producto, que se ha puesto en funcionamiento y probado con éxito, pudiendo manejar un rendimiento de 180 kg/h. La unidad de alimentación, basada en una plataforma vibradora inclinada, que desemboca en cintas transportadoras estrechas, ha resultado un dispositivo eficaz para la separación de los objetos procedentes de la máquina de extracción. La unidad de inspección, compuesta por dos cámaras conectadas a un sistema de visión por computador y los algoritmos de análisis de imágenes específicamente implementados para este problema, tiene suficiente capacidad para lograr las especificaciones requeridas de tiempo real, así como la precisión suficiente para cumplir con los requisitos de calidad exigidos. El sistema de clasificación es capaz de clasificar el producto en cuatro categorías. La sincronización entre los dos últimos sistemas mediante un codificador óptico hace que el funcionamiento del prototipo sea independiente de la velocidad de las cintas transportadoras. Los intensos ensayos a los que se ha sometido el sistema en condiciones reales de funcionamiento han dado buenos resultados durante una campaña completa, si bien han aportado información sobre cómo mejorar el prototipo, el cual se ha patentado, teniendo como fecha de concesión de la patente el 30/09/2011 y número de patente ES 2352713 B1.

5. Nuevas tecnologías para la selección automática de gajos de satsuma (*Citrus unshiu*) basadas en visión por computador

Resumen

Aunque la mayor parte de las tareas del procesado de gajos de mandarina Satsuma (*Citrus unshiu*) en conserva están actualmente automatizadas, la inspección y control de calidad de cada gajo se sigue realizando a mano debido a la dificultad de la manipulación del producto y a la complejidad del software de inspección necesario para la clasificación de los gajos, ya que en la actualidad se siguen criterios subjetivos para establecer esta calidad. En este capítulo se presenta el desarrollo de maquinaria y algoritmos para desarrollar sistemas de visión capaces de automatizar esta tarea. Se ha desarrollado un sistema basado en visión por computador para clasificar los gajos que llegan a la línea de inspección hasta en cuatro categorías de calidad. Esto incluye el diseño, construcción y prueba de un prototipo similar al presentado en el capítulo anterior, pero adaptado para individualizar, inspeccionar y clasificar gajos de satsuma. Éstos se transportan sobre cintas semitransparentes que permiten iluminar la fruta desde la parte inferior con el objetivo de aumentar el contraste del contorno de los gajos sobre el fondo. El sistema adquiere imágenes de los gajos utilizando dos cámaras conectadas a un único ordenador y las procesa en menos de 50 ms. Mediante la extracción de las características morfológicas de los objetos, los algoritmos desarrollados identifican automáticamente los gajos en la imagen y distinguen los trozos de pieles u otros elementos extraños como hojas o pedúnculos. Además, separa los gajos enteros de los que están rotos mediante el empleo de un sistema de decisión basado en análisis discriminante, tomando como variables algunas características morfológicas; además, también es capaz de distinguir entre varios grados de rotura.

Palabras clave: Tiempo real, inspección automática, análisis en línea, gajos de Satsuma, control de calidad

5.1 Introducción

Como se ha comentado en el capítulo anterior, debido a las rutinas y exigencias de los tiempos actuales, los consumidores de frutas demandan cada vez más productos mínimamente procesados y listos para su consumo. Los gajos de mandarina, al igual que otras frutas como melocotones, pera o piña, es un producto que puede ser envasado y vendido en su jugo o en almíbar para su consumo instantáneo. En las industrias españolas dedicadas a la preparación de este producto, las mandarinas se pelan de forma mecánica y los gajos se separan utilizando maquinaria específica para ello. En una etapa posterior, mediante un proceso enzimático se elimina la piel de los gajos mientras viajan en una solución líquida. En todas estas tareas se utiliza un circuito de agua para transportar el producto de forma sencilla y evitar su deterioro. Antes de ser envasado, se realiza una inspección de calidad, en la que aquellos que presentan semillas y otro tipo de material extraño como pieles, pedúnculos u hojas se eliminan de la cadena de producción. Para el resto de gajos, se establecen tres categorías comerciales: enteros, rotos y mitades, que se separan por salidas diferentes. En una planta de envasado de este producto, todas las tareas están automatizadas excepto la inspección, que se realiza de forma manual en mesas de selección donde unos seis operarios por cada mesa inspeccionan visualmente toda la producción y la separa a mano.

En la etapa de inspección, los gajos son particularmente difíciles de manipular por ser un producto húmedo y pegajoso. En la actualidad, los operarios tienen que detectar los gajos rotos o los que contienen semillas mientras pasan frente a ellos sobre una cinta transportadora. Cuando identifican un gajo defectuoso, lo colocan manualmente en la salida correspondiente a su calidad estimada. No existen criterios objetivos para determinar cuando un gajo está roto. Puede ser que presente algún tipo de rotura o que le falte una esquina de mayor o menor tamaño, siendo este un umbral que queda a criterio del operario. Existen ciertos factores que disminuyen la calidad de la inspección y, en consecuencia, del producto final, como son la subjetividad y disparidad de criterios entre los operarios, que se ven agravados con la fatiga y el tedio de una operación manual repetitiva. Una alternativa más rápida, fiable y objetiva viene del uso de sistemas basados en visión por computador para realizar esta tarea.

Un sistema de visión capaz de analizar este producto se debe basar en un análisis morfológico de cada gajo. Es importante encontrar métodos que permitan determinar si el gajo está entero o roto a partir del análisis de su forma. El análisis de la forma de los objetos en la inspección en línea se ha abordado desde diferentes puntos de vista y se ha utilizado ampliamente para construir sistemas de visión por computador para la inspección de algunos productos agrícolas. Ciertos parámetros morfológicos tales como el área, el perímetro, la compacidad, la longitud, la anchura, la relación de aspecto o la redondez son algunas de las características más comunes que se usan para clasificar o identificar el producto según su forma. Sakai et al. (1996) distinguen con algunas de estas variables entre cuatro variedades diferentes de arroz y Shouche et al. (2001) las emplean para discriminar entre 15 variedades de trigo. También se ha

investigado su aplicación en frutas para estimar el volumen con el objetivo de clasificarlas en categorías. Por ejemplo Koc (2007) estima el volumen de sandías a través de un elipsoide creado a partir de los diámetros mayor y menor de la fruta. Samal y Iyengar (1993) utilizan la Transformada de Hough para detectar las formas de objetos naturales que son reconocidas utilizando el análisis de sus componentes principales.

La eficacia de los descriptores de forma basados en estas características puede verse afectada si los objetos tienden a presentar formas diferentes o no están previamente orientados, pues su correcta estimación puede depender de la escala, tamaño o la orientación de los objetos (Chen y Bui, 1999). Los descriptores basados en la transformada de Fourier se han utilizado ampliamente para la clasificación de formas (Osowski y Nghia, 2002), ya que resultan invariantes con el tamaño y la rotación y se han podido aplicar con éxito para describir la forma de productos agrícolas (Lootens et al., 2007). La Transformada Discreta de Fourier se ha usado ampliamente para analizar el espectro de señales en el dominio de la frecuencia y se puede usar, por ejemplo, para describir firmas de contornos de objetos. La Transformada Rápida de Fourier (FFT) es un algoritmo de computación de la transformada de Fourier que se puede aplicar sobre un conjunto de valores discretos. Dado un conjunto finito de puntos, por ejemplo, tomados de la firma del contorno de una forma concreta, la FFT expresa esos puntos en términos correspondientes a sus frecuencias fundamentales, que son particulares para cada tipo de forma (señal). El resultado de la FFT es una serie de números que representan las frecuencias fundamentales y sus coeficientes. En el análisis de formas, las firmas se usan como datos de entrada en el algoritmo de la FFT.

Mebatsion et al., (2012) investigaron la variación en la forma de granos de cereal (cebada, avena, centeno y trigo) usando PCA a partir de descriptores elípticos de Fourier. Extrajeron el contorno de cada grano y lo codificaron con un código de cadena, a partir del cual calcularon los 13 primeros coeficientes elípticos de Fourier. Los descriptores elípticos de Fourier también se emplearon por Neto et al. (2006) para identificar plantas de diversas especies mediante el análisis de la forma de las hojas. Obtuvieron funciones de clasificación mediante análisis discriminante a partir de los descriptores de Fourier del contorno de las hojas en plantas con dos o tres semanas después de la germinación. Lootens et al. (2007) compararon dos métodos para estimar la forma de las raíces de *Chicorium intybus* L: descriptores elípticos de Fourier y descriptores clásicos de forma, obteniendo mejores resultados con los primeros.

Una vez extraídas las características morfológicas del objeto, el siguiente paso es tomar una decisión sobre su clasificación. Técnicas estadísticas como el LDA o las ANN son métodos comúnmente empleados para la clasificación de objetos por su forma (Cho et al., 2002). Dubey et al. (2006) compararon las ANN con el análisis discriminante para clasificar objetos entre plantas y malas hierbas, utilizando como datos de entrada algunas características morfológicas. A pesar de que llegaron a la

conclusión que las ANN tenían más éxito, los resultados obtenidos con ambos métodos fueron similares (por encima del 90 %), siendo el LDA más rápido y fácil de implementar en un sistema en tiempo real como es el caso de una línea de inspección automática.

Como se ha comentado en el capítulo anterior, las líneas de inspección basadas en sistemas de visión por computador, además de contar con un procesamiento de análisis de imagen eficiente, también requieren tener dispositivos auxiliares para que los objetos entren y salgan del campo de visión de las cámaras, así como otros dispositivos que separan la producción físicamente en diferentes categorías. Para que un sistema de visión funcione de manera eficiente, el producto debe venir individualizado con el fin de facilitar tanto el análisis como la acción de los mecanismos de clasificación. Otras dificultades añadidas son la gran variedad de formas posibles de los gajos y su fragilidad, la alta velocidad de las cintas transportadoras y los brillos producidos por la luz que se refleja de los gajos mojados.

Este capítulo describe el desarrollo de un prototipo para la inspección y clasificación automática de gajos de mandarina. Por ser, conceptualmente similar al mostrado para el caso de los arilos de granada, el capítulo se centra en las diferencias entre ambos prototipos a nivel de soluciones de ingeniería y en los algoritmos de análisis de imagen desarrollados específicamente para el análisis de la forma en tiempo real de los gajos.

5.2 Objetivos

El objetivo de este trabajo es desarrollar una solución basada en visión por computador para la clasificación automática de gajos de satsuma, incluyendo para ello algoritmos de análisis de imagen capaces de estimar la calidad de gajos de mandarina en línea. Para lograrlo, los gajos se deberán detectar automáticamente sobre las cintas transportadoras y se deberá tener la capacidad para poder separar los gajos enteros de los que estén rotos, y al mismo tiempo discriminar entre gajos con diferentes grados de rotura. Los algoritmos deben identificar los gajos que contienen semillas y detectar la presencia de otros elementos extraños que puedan darse en las cintas transportadoras. Una dificultad añadida es el hecho que en cada imagen puede haber un número aleatorio de gajos mojados situados en posiciones también aleatorias.

Para conseguir este objetivo hay que diseñar mecanismos para individualizar y transportar los gajos, algoritmos de visión por computador en tiempo real para inspeccionar y clasificar el producto, algoritmos y dispositivos para la sincronización de la unidad de inspección con el sistema de clasificación, la construcción de un sistema para clasificar los gajos en distintas categorías y el diseño de procedimientos de comunicación y control para supervisar toda la operación.

El producto a inspeccionar, del que se expone una muestra en la Figura 5.1, se compone de:

- Gajos enteros.
- Gajos rotos: varían desde los que presentan una pequeña rotura en un extremo hasta las mitades de gajos o gajos rotos con formas extrañas.
- Gajos dobles: formados por dos o más gajos que están unidos debido a fallos en el proceso previo de desgajado.
- Gajos con semillas: contienen una o más semillas en su interior.
- Pieles: son pedazos de la piel de la mandarina o cualquier otro objeto no deseado, como hojas o ramas, que no se han eliminado en procesos anteriores.

Los algoritmos de visión por computador deben ser capaces de realizar esta inspección y además sincronizar la adquisición de imágenes de dos cámaras distintas, realizar el análisis de las imágenes, controlar el movimiento de los objetos sobre las cintas transportadoras y activar la unidad de clasificación.

En cuanto a la producción requerida, que determinará el tiempo máximo de proceso de cada imagen, es de 1 tonelada/hora. Estimando que en promedio cada gajo pesa 5 gramos, se deben inspeccionar unos 55 gajos por segundo.



Figura 5.1. Gajos pertenecientes a las clases entero (izquierda), roto (centro) y mitad (derecha).

5.3 Materiales y Métodos

La solución propuesta se lleva a cabo sobre un prototipo similar al desarrollado para la inspección de arilos de granada, si bien adaptado para la inspección de gajos. Las principales diferencias son:

- Un sistema de iluminación posterior. Los gajos se iluminan por debajo para obtener un mayor contraste entre el producto y el fondo, y facilitar de ese modo el análisis de su contorno.
- Cintas semitransparentes. Las cintas deben dejar pasar la luz que estará situada por debajo.
- Un menor número de cintas. Al ser un producto de mayor tamaño, la anchura de las cintas es mayor y, por tanto, el número de cintas en el prototipo menor.

- Parámetros de trabajo como la velocidad de las cintas transportadoras, el tiempo necesario para analizar de cada imagen, frecuencias e inclinaciones diferentes del individualizador, etc.
- Los algoritmos de análisis de imágenes. En el caso de los arilos de granada se trata de inspeccionar color y tamaño de un número de objetos muy elevado en cada imagen. En éste, se trata de analizar la forma y detectar la presencia de semillas, abarcando de ese modo un espectro más amplio de soluciones en la utilización de estos equipos.

Al igual que en el caso de los arilos, el prototipo consiste esencialmente en tres elementos principales: unidad de alimentación, unidad de inspección y unidad de clasificación. Éstos incluyen las cintas transportadoras, la iluminación, las cámaras, los eyectores de aire o las zonas de salida (Figura 5.3). Todos ellos se describen a continuación.

5.3.1 Unidad de alimentación: separación y transporte de los objetos

Los gajos de Satsuma entran en el prototipo de inspección desde una bandeja vibratoria que se extiende en todo su ancho (600 mm) y que los distribuye entre seis cintas transportadoras de 50 mm de ancho que se mueven a una velocidad relativamente alta, lo que facilita su individualización. La estrecha anchura de las cintas transportadoras evita la formación de grandes acumulaciones de material y facilita la posterior separación de los objetos. Teniendo en cuenta que el peso medio de un gajo típico es de unos 5 g, para cumplir los requisitos de 1000 kg por hora, se deben inspeccionar alrededor de siete gajos por segundo y cinta transportadora. Asumiendo una distancia de 50 mm entre gajos consecutivos, la velocidad de las cintas transportadoras se estableció en 600 mm/s para lograr este objetivo.

5.3.2 Unidad de inspección y sistema de visión por computador

El prototipo utiliza el sistema de adquisición de imágenes descrito para los arilos de granada, con similares equipos y las mismas cámaras y tarjeta digitalizadora de imágenes.

En este caso también se han utilizado dos cámaras para inspeccionar las seis cintas transportadoras. Se ha considerado más adecuada su orientación longitudinal, por lo que el ancho de la escena corresponderá al ancho de 3 cintas, concretamente 270 mm. De este modo la longitud de la imagen se establece en 360 mm. En cada una de las cámaras se ha montado una óptica de 12 mm, por lo que las cámaras se sitúan a unos 900 mm de la escena. Se han utilizado las mismas ópticas que en el caso anterior por los mismos motivos, para evitar que los objetos en los laterales de las cintas no sean obstaculizados por los elementos de iluminación y porque no hay ninguna restricción en las dimensiones de la campana de inspección que impida que ésta mida algo más de un metro de altura.

El sistema de iluminación consiste en dos pares de tubos fluorescentes compactos (Osram Dulux L 840/40 W) al igual que en el prototipo de inspección de arilos de

granada, situados en ambos lados de cada cinta y se ha añadido otro tubo situado justo debajo de cada cinta transportadora Figura 5.2. Como se explica en el Anexo II, situando la iluminación debajo de los objetos se pueden inspeccionar objetos translúcidos mejorando la detección de formas y contornos. Por lo tanto, para este trabajo se ha combinado el uso de iluminación direccional y por retroiluminación.

En este caso también se han utilizado balastos electrónicos de alta frecuencia (Osram, Quicktronic professional QTP) para evitar el parpadeo provocado por la frecuencia de la corriente y se han utilizado filtros polarizadores entre la iluminación y las cámaras para evitar los brillos provocados por los reflejos de la luz directa sobre los gajos que llegan muy mojados a la zona de inspección.




Figura 5.2. Cinta transportadora con la iluminación superior e inferior

Las cintas transportadoras están confeccionadas con un material translúcido, lo que permite que los gajos se vean a contraluz y facilita la detección de semillas y la segmentación de la forma de los gajos. Los tubos fluorescentes se utilizan en combinación con balastos electrónicos de alta frecuencia para evitar el efecto de parpadeo ya comentado anteriormente. Tanto los tubos fluorescentes como los filtros polarizadores están situados en unas carcasas de plástico transparente que los aíslan y protegen.

El sistema de inspección (cámaras e iluminación) se ha alojado en una campana de acero inoxidable que lo aísla de la luz exterior y lo protege del entorno.

El modelo del conjunto desarrollado se puede observar en la Figura 5.3.




Figura 5.3. Esquema de los principales elementos del prototipo

5.3.2.1 Adquisición de imágenes y análisis en línea

Todo el software de análisis de imágenes y de control del prototipo se ha programado en lenguaje C++ utilizando el entorno de programación Ms. Visual Studio 6.0. La adquisición de las imágenes se sincroniza utilizando los pulsos recibidos del codificador óptico acoplado al eje del rodillo de arrastre de las cintas, que está conectado al puerto serie del *ordenador de control*, al igual que en el trabajo de los arillos de granada. Se toma una imagen por cada 350 mm de avance de las cintas, aunque las imágenes de ambas cámaras están tomadas al tresbolillo, esto es, desplazadas una cámara de la otra para solapar los tiempos de adquisición de una con el análisis de las imágenes de la otra cámara. Este diseño hace que la adquisición de las imágenes sea independiente de la velocidad de las cintas, lo que garantiza que siempre haya un solapamiento de 30 mm entre dos imágenes consecutivas de cada cámara, que es aproximadamente la mitad de la longitud de un gajo típico (unos 50 mm de promedio).

La aplicación desarrollada para llevar a cabo las labores de adquisición y análisis de las imágenes se ejecuta en el *ordenador de inspección* y se describe en el Anexo VI. No se ha mostrado la aplicación ejecutada en el *ordenador de control* ya que no presenta ninguna opción al usuario ni visualiza ninguna información.

5.3.2.2 Discriminación de los objetos de interés

El primer paso del procesamiento de la imagen es la segmentación. Consiste en determinar qué píxeles de la imagen corresponden a fondo y cuales representan los objetos de interés. La configuración de la iluminación, con iluminación posterior, permite al sistema adquirir imágenes bien contrastadas, aunque el color también se ha

conservado gracias a la iluminación situada a los dos lados de cada cinta (Figura 5.4). De esta manera, en una imagen los gajos aparecen con un color anaranjado translucido, las semillas contenidas en los gajos aparecen como regiones puntuales oscuras, mientras que los elementos extraños se muestran como objetos irregulares con un color más opaco que varía desde el naranja al negro. Al igual que en los trabajos anteriores, se realizó un estudio de distintos tipos de iluminación, eligiendo como factibles los LED y los tubos. Sin embargo, como se comentó en el capítulo anterior, los LED presentan diversos problemas que hacen más sencilla la solución de los tubos fluorescentes. Por lo tanto se decidió situar un tubo fluorescente debajo de cada cinta transportadora para aportar luz posterior, unido a un tubo fluorescente a situado entre cada una de las cintas. Por lo tanto fueron necesarios seis tubos fluorescentes para la parte inferior y catorce para la superior. La Figura 5.5 muestra un ejemplo de una imagen procesada por el sistema en la que se aprecian gajos de diferentes categorías.

La Tabla 5.1 muestra el promedio y la desviación típica de los valores RGB de los gajos, el material no deseado (incluyendo semillas) y el fondo. Se aprecia que los valores RGB del fondo están completamente saturados (alcanzan su máximo posible), facilitando así su discriminación respecto del resto de los productos. La diferencia entre los gajos y el material no deseado, tales como semillas o pedazos de piel es también evidente, sobre todo en el canal rojo.

Tabla 5.1. Estadísticas básicas sobre el color del producto a inspeccionar

	Gajos			Material no deseado			Fondo		
	R	G	B	R	G	B	R	G	B
Media aritmética	204,2	97,2	43,6	78,0	48,7	45,4	255,0	250,5	255,0
Desviación típica	36,6	20,0	11,3	18,8	9,8	14,6	0,0	4,3	0,0



Figura 5.4. Gajos con iluminación direccional y posterior




Figura 5.5. Imagen de los gajos sobre las cintas transportadoras (izquierda) e imagen segmentada que muestra en gris claro las semillas, trozos de piel y gajos dobles (derecha)

Con el fin de obtener un procesamiento muy rápido de las imágenes, para realizar la segmentación se ha tenido que incorporar una sencilla pero eficaz técnica. Utilizando los valores mostrados en la Tabla 5.1, se ha realizado una doble segmentación. En una primera etapa se elimina el fondo del resto de la imagen y en un segundo paso se distinguen el resto de las regiones. Se observa en los objetos un valor de componente azul relativamente bajo respecto del fondo, lo que facilita la elección de un umbral en esta banda de color para eliminar el fondo. La gran diferencia entre el valor de azul del fondo (255) y el promedio del componente azul de los objetos (36) hace que prácticamente cualquier umbral sea válido para detectar los píxeles de fondo, así que se estableció en 150 durante los experimentos. Los objetos así segmentados incluyen gajos, semillas o trozos de piel. Para discriminarlos entre sí se llevó a cabo una segunda segmentación. Debido a que las semillas y los trozos de piel son más opacos que los gajos, mostraron valores más bajos en el componente rojo. En el caso de los gajos, para el 95 % de los casos los valores de la componente roja de los píxeles se encontraban en niveles comprendidos entre 160 y 255, mientras que para el caso de las semillas o pieles, en el 95 % de los casos, los valores de la componente roja de los píxeles se encontraban en niveles entre 45 y 112 (nivel rojo promedio de 204 frente a 78 respectivamente). En esta segunda etapa también se detectan los gajos dobles, cuyos valores de rojo oscilaron desde 127 hasta 154.

No se ha podido usar directamente el canal rojo para eliminar el fondo debido a posibles confusiones entre gajos y fondo, y no se ha podido usar el canal azul para diferenciar entre gajos y pieles por el mismo motivo, lo que justifica esta estrategia de la doble segmentación por umbrales. Este proceso es rápido y eficaz debido a las grandes diferencias en los niveles de color observados entre las diferentes categorías de objetos debidas, fundamentalmente, al acierto en la elección del sistema de iluminación.

Las pieles y los gajos con semillas son objetos que se deben eliminar de la producción y por lo tanto ambos se separan utilizando la misma salida del prototipo. Sin embargo, en este trabajo ambos tipos de objetos se etiquetaron de forma diferente a efectos estadísticos y para la confección de informes de éxito y de rendimiento. Las semillas son normalmente más pequeñas y regulares que los objetos compuestos por pieles, por lo que se pueden identificar empleando estas características. Por otro lado, los gajos dobles aparecen normalmente en la imagen como grandes objetos opacos y regulares (la parte central de los gajos dobles) dentro de un área con un color parecido al del resto de gajos (parte periférica de los gajos dobles). El área de cada objeto se estima contando el número de píxeles identificados como tal.

Visto esto, los objetos identificados como gajos con semillas, gajos dobles o pieles, se eliminan de la imagen, centrándose el posterior análisis de imagen en la clasificación del resto de objetos encontrados inicialmente. Estos objetos supuestamente son los gajos que hay que distinguir y clasificar entre enteros y diferentes grados de rotura, lo que se realiza mediante la estimación y análisis estadístico de diferentes características morfológicas.

5.3.2.3 Análisis de las imágenes. Parámetros morfológicos estudiados

La Figura 5.6 muestra el diagrama de flujo de todo el proceso de análisis de una imagen. El proceso comienza con la extracción del perímetro (P) del objeto, formado por los píxeles que pertenecen al objeto y que tienen algún vecino que pertenece al fondo. El centroide se calcula como el promedio de las coordenadas (x , y) de cada uno de los píxeles del perímetro. El área (A) se calcula como el número de píxeles que se encuentra en el interior del perímetro. Se calculan los momentos de inercia para obtener los ejes principales de inercia (Tanenbaum, 2004), a partir de los que se estima la longitud, la anchura y la orientación del objeto.

En el siguiente paso se calcula la elongación (E) como la relación entre la longitud (L) y la anchura (W) del objeto. El factor circularidad (FC) se calcula como una estimación de la forma relativa del objeto frente a una circunferencia con un perímetro igual al del objeto. El valor de este factor varía entre 0 y 1 y se calcula mediante la Ecuación 5.1 (Throop et al., 1995).

$$FC = 4\pi A/P^2 \quad (5.1)$$

La compacidad (C) se utiliza como una estimación de la presencia de concavidades y convexidades en el contorno, que probablemente estén causadas por roturas en los gajos. Se calcula utilizando la Ecuación 5.2 (González y Woods, 2002).

$$C = P^2/A \quad (5.2)$$

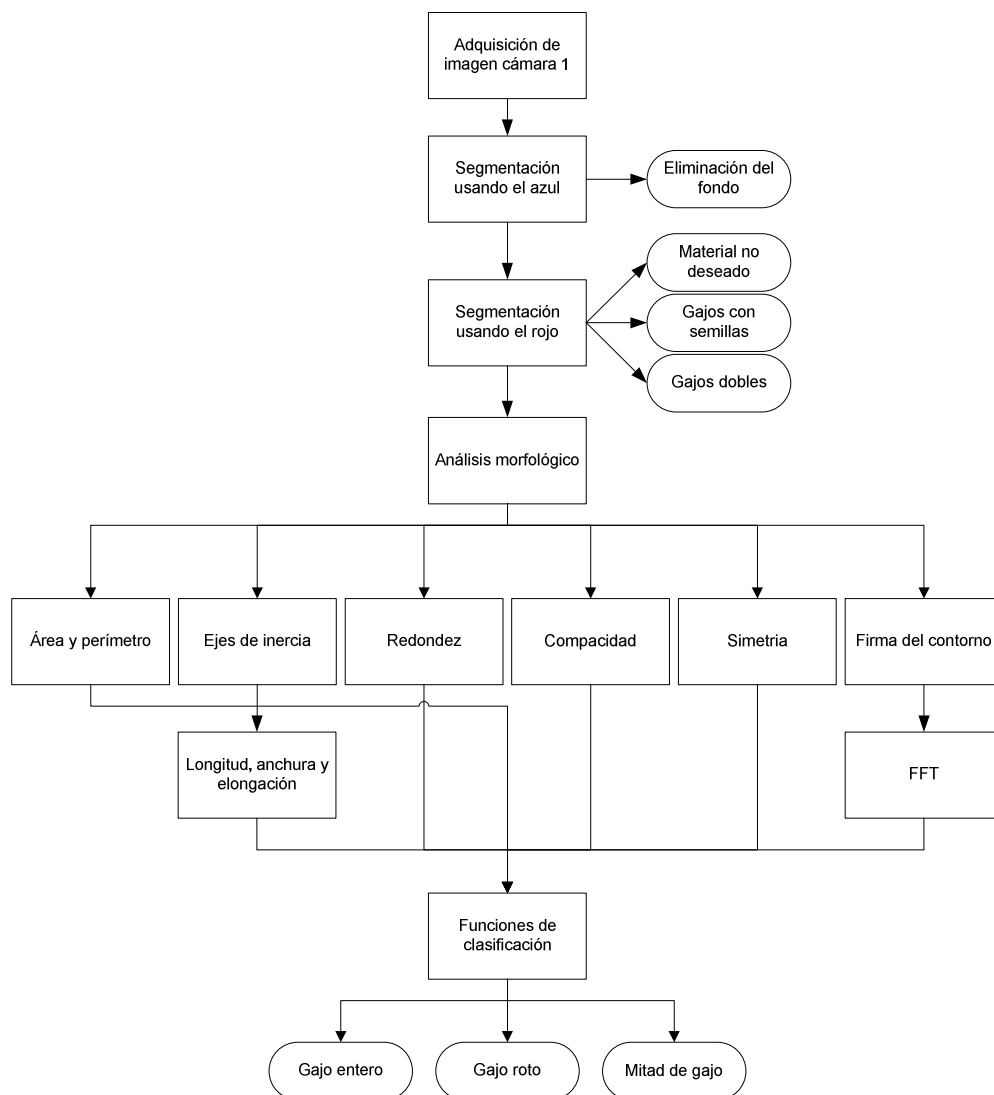


Figura 5.6. Diagrama de flujo del proceso de análisis de imágenes

Por su forma teórica, es de suponer que un gajo entero es más simétrico que uno roto. La estimación de la distribución de la masa a ambos lados del eje de inercia secundario se puede utilizar como una estimación de la simetría (S). Para obtenerla, se divide el gajo en dos mitades según el eje secundario y se calcula la relación entre el número de píxeles que tienen un píxel simétrico en el otro lado y el área total del gajo. La Figura 5.7 (izquierda) muestra un gajo donde el contorno de la parte derecha se ha proyectado sobre la parte izquierda para ilustrar la simetría visualmente. En gris se muestra el área coincidente en ambos lados. La Figura 5.7 (derecha) muestra la simetría de un gajo roto.




Figura 5.7. Representación de la simetría de los gajos mediante la proyección de la parte derecha del gajo sobre la izquierda. La imagen de la izquierda muestra la simetría de un gajo entero. La imagen de la derecha muestra la simetría de un gajo roto. En gris se resalta la zona de solapamiento

Finalmente, el contorno se codifica mediante la firma polar, que consiste en un vector unidimensional que contiene la distancia Euclídea entre el centroide del objeto y cada uno de los i puntos del contorno $t(i)$; $i = [0, P]$ (Figura 5.8). La unión de estas distancias conforma un vector que representa una señal unidimensional representativa del contorno. Al calcular la transformada rápida de Fourier (FFT) de esta firma, obtenemos información sobre su perfil que puede ser utilizada como una estimación de la forma de los objetos. Tao et al., (1995) demostraron que la información más relevante de la forma de patatas está contenida en los diez primeros armónicos de la FFT de la firma polar del contorno, por lo que en esta tesis se ha decidido incluir solamente esos diez primeros armónicos en el análisis estadístico.




Figura 5.8. Firma polar del contorno de los gajos

5.3.2.4 Análisis estadístico y evaluación de los datos

Tal y como se ha descrito anteriormente, los gajos con semillas, los gajos dobles y el material no deseado se identifican en un primer paso. La clasificación del resto de gajos se realiza mediante un modelo basado en análisis discriminante. Para generar este modelo, se eligió aleatoriamente un conjunto de entrenamiento compuesto por

620 gajos procedentes de la línea de producción, etiquetados de forma previa y manual como enteros, rotos o medios, y se pasaron por la línea de inspección. Para cada uno de estos gajos se calcularon los parámetros morfológicos descritos anteriormente (factor de forma, compacidad, elongación, longitud, área y simetría), además de los primeros 10 armónicos de la FFT de la firma polar (Tao et al., 1995). Tomando estos datos como variables de entrada, se utilizó un análisis discriminante Bayesiano no lineal para obtener las funciones de clasificación correspondientes a cada una de las clases. Este método se basa en el teorema de Bayes (4.1).

El resultado del análisis de cada imagen es la clasificación de cada uno de los objetos encontrados en alguna de las clases predefinidas, bien por la técnica de umbralización para el caso de los gajos dobles, los gajos con semillas y las pieles, o bien mediante el modelo creado a partir de un análisis discriminante para el caso de las clases de gajos enteros, gajos rotos o mitades de gajos.

5.3.3 El sistema de clasificación

Este sistema es muy similar al utilizado en el prototipo de inspección de arilos de granada (Figura 5.9). Cuenta con cuatro salidas de producto, una de ellas para la mejor categoría comercial en las que no se manipulan los objetos ya que llegan hasta el final de las cintas transportadoras mientras que las otras tres consisten en huecos dispuestos en uno de los lados de cada cinta transportadora y frente a ellos unos eyectores de aire que expulsan el producto a la parte inferior del prototipo. La principal diferencia respecto al anterior prototipo es el tipo de eyector de aire utilizado. En este caso se utilizan unas boquillas que expulsan el aire en abanico cubriendo un cono mayor (aproximadamente 3 cm) que para el caso de los arilos de granada, donde el cono es muy puntual (sobre 1 cm).

El *ordenador de control* monitoriza el movimiento de los objetos por las cintas a partir de los datos de posición enviados desde el *ordenador de inspección*, y activa los eyectores de aire cuando es necesario. Se utiliza una tarjeta con 32 salidas digitales que activa las electroválvulas que hacen pasar el aire a los eyectores. El movimiento de las cintas transportadoras y la monitorización de la posición de los gajos, se realiza mediante la lectura de las señales producidas por el codificador óptico acoplado al eje del rodillo de arrastre.

El codificador óptico que se ha utilizado envía 500 pulsos cada vez que su eje da una vuelta completa, lo que proporciona aproximadamente un pulso por cada mm de avance de las cintas. El calibrado del sistema de visión se realiza situando una pieza a modo de referencia en una posición conocida del prototipo y a una distancia conocida de los eyectores. Al iniciar la aplicación se captura una imagen en la que aparece la referencia y se calculan sus coordenadas (x, y) en la imagen (en píxeles). Sabiendo la resolución de la imagen en píxeles/mm se calcula la distancia desde el origen de coordenadas de la imagen hasta cada eyector en mm. Partiendo de la ratio de conversión mm/pulsos del codificador (en este caso 1 mm/pulso) se determina la

distancia en pulsos de codificador entre la referencia encontrada en la imagen y cada uno de los eyectores.

Al igual que en el prototipo de inspección de arilos de granada, el *ordenador de inspección* calcula la posición (x, y) de los objetos en la imagen, y se la envía al *ordenador de control*, junto con la salida a la que corresponde el objeto encontrado, utilizando el protocolo de comunicaciones TCP/IP y una conexión directa entre las tarjetas de red Ethernet de ambos ordenadores. En este caso también se valoró el uso de algún bus de comunicaciones industriales como RS-485, pero no se consideró necesario adquirir ningún hardware específico porque utilizando las tarjetas de red de los equipos era suficiente y el prototipo funcionó perfectamente incluso a la máxima velocidad del prototipo, ya que desde que se analizan las imágenes y se envían los resultados hasta que los objetos se expulsan hay tiempo más que suficiente para recibir los datos y preparar la expulsión.

Por lo tanto, una vez establecidos los *sockets* de comunicación de paquetes de datos que contienen las direcciones IP local (*ordenador de inspección*) y remota (*ordenador de control*), un protocolo de transporte de datos (protocolo IP) y los dos puertos de comunicaciones (uno local en el *ordenador de inspección* y otro remoto en el *ordenador de control*) y antes de iniciar la inspección, se comprueba que los dos equipos están correctamente comunicados, y en caso contrario se muestra un error en pantalla.

Cuando se adquiere la primera imagen, ambos equipos se sincronizan gracias al envío de mensajes de sincronización para que ambos equipos puedan llevar el control del número de imágenes capturadas. Al finalizar el análisis de cada imagen, el *ordenador de inspección* envía al *ordenador de control* dos mensajes; uno con el número de datos que se envían a continuación y un segundo con los datos referentes al análisis de los objetos encontrados en la imagen, que contiene la información sobre la posición de cada objeto y la zona por la que se debe expulsar de las cintas. Los objetos que pertenecen a la primera categoría no se expulsan sino que continúan hasta el final de las cintas, por lo que no se comunica ningún dato referente a los mismos al *ordenador de control*. Por lo tanto, después de analizar cada imagen se envían $n+1$ mensajes correspondientes a los n objetos que se deben expulsar.

La finalización de la inspección se produce enviando un mensaje de parada para indicar que ya no se deben ordenar nuevas fotos, ni esperar para recibir más mensajes.

El formato de los mensajes es igual que en el caso anterior, donde cada mensaje consta de 24 bits (3 bytes) que incluyen información bien de sincronización con el *ordenador de control* o de datos para la expulsión de los objetos.

La estructura de un mensaje, al igual que en el caso anterior es la siguiente:

1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
CODIGO				ZONA_SALIDA				CINTA				DATOS										

El *ordenador de control* se encuentra continuamente contando los pulsos que recibe del codificador óptico, con un contador que se utiliza para el disparo de las cámaras, recibiendo los mensajes de resultado del análisis y comprobando en todo momento si alguna electroválvula deberá ser activada en ese momento, teniendo en cuenta que desde que recibe la información de esa imagen, al contador de pulsos de cada objeto le descuenta los transcurridos entre la adquisición y la recepción de la información.



Figura 5.9. Zona de clasificación de los gajos de satsuma

5.3.4 Prueba del prototipo. Evaluación global de su rendimiento

Una vez que el prototipo estuvo preparado, se instaló en una empresa productora de gajos de satsuma, concretamente en Agriconsas, S.A. de Algemés (Valencia), para realizar pruebas industriales (Figura 5.10), y se configuró para separar gajos y material no deseado como se ha descrito. El prototipo se probó en condiciones comerciales entre octubre y diciembre de 2006, coincidiendo con la campaña de recolección en Valencia de mandarina ‘Satsuma’.

Con el fin de medir la velocidad de procesamiento de las imágenes, se conectó un osciloscopio (Hameg, HM205-3) al puerto paralelo del ordenador. Al comienzo del análisis de la imagen, el ordenador activó una señal del osciloscopio que inició un contador de tiempo. Al final del procesamiento de las imágenes, se envió una nueva señal para detener el contador. Esto se ha realizado para todas las imágenes correspondientes al conjunto de entrenamiento, lo que ha permitido medir el tiempo transcurrido (promedio y máximo) entre las dos señales y determinar con exactitud si el sistema alcanza los requisitos de tiempo real.



Figura 5.10. Imagen del prototipo para la adquisición y procesamiento de gajos de satsuma

Se llevaron a cabo dos pruebas; la primera consistió en el análisis en línea de 10 series de 3 kg de gajos (cerca de 6.000 gajos), que fueron elegidos aleatoriamente e inspeccionados por el sistema automático. Los objetos de estas imágenes se clasificaron utilizando el algoritmo descrito y la clasificación se comparó con la realizada por expertos humanos mediante la visualización de las imágenes para obtener el comportamiento del modelo estadístico. La segunda prueba consistió en la adquisición y análisis de 15.000 imágenes de los gajos, cada una con un número aleatorio de objetos, sumando un total aproximado de 135.000. Expertos del laboratorio de control de calidad de la empresa productora analizaron de forma visual los resultados de las salidas del prototipo, justo después de la inspección, para comprobar si se ajustaban a los estándares de la empresa y obtener así una estimación de su rendimiento. Estos análisis se realizaron de forma regular a lo largo de la campaña de producción. A modo descriptivo, comentar que según datos de la empresa (comunicación personal), alrededor del 78 % de la producción estaba compuesta de gajos enteros, los gajos rotos representaron el 18 %, mientras que los gajos dobles fueron el 3 % y los gajos con semillas el 1 %. No había datos previos sobre la cantidad de material no deseado que llegó a la inspección.

Tras la zona en la que se encuentra la campana de inspección se sitúa la zona de clasificación. En un lado de cada una de las cintas transportadoras se colocan tres zonas de salida y delante de cada una de ellas se colocan eyectores de aire controlados por el ordenador que se encargan de expulsar el producto. La sincronización entre la adquisición de las imágenes, el avance de las cintas y la expulsión del producto se realiza siguiendo el mismo mecanismo explicado para el caso de la inspección de arilos de granada.

5.4 Resultados

5.4.1 Unidad de inspección y sistema de visión por computador

La unidad de alimentación funcionó correctamente durante las pruebas en las instalaciones industriales, lo que indica ser una solución válida, aunque se observó que era necesario un preciso ajuste de la plataforma vibradora a fin de distribuir el producto de manera uniforme en las cintas transportadoras y evitar la sobrealimentación de alguna de ellas. Esto es muy importante debido a que cantidades excesivas de producto en una o varias cintas tienen una importante influencia negativa en el funcionamiento de todo el sistema, provocando acumulaciones de producto. En estos casos, ocurre que cuando gajos enteros viajan en las cintas transportadoras excesivamente cerca de otros objetos de categorías inferiores, pueden ser arrastrados por las salidas correspondientes a éstos, reduciendo el rendimiento del sistema.

El sistema clasificó los gajos de las imágenes utilizando el modelo basado en un análisis discriminante. Después, esta clasificación se comparó con la realizada previamente por los expertos con el fin de obtener la matriz de confusión y los ratios de éxito para cada categoría, como se muestra en la Tabla 5.2.

Tabla 5.2. Matriz de confusión de la clasificación obtenida por el sistema automático (valores en tanto por ciento)

Categoría	Enteros	Rotos	Mitades	Semillas	Pieles	Dobles
Enteros	93,2	5,8	0,3	0,7	0,0	0,0
Rotos	9,9	83,4	6,7	0,0	0,0	0,0
Mitades	1,1	4,7	94,2	0,0	0,0	0,0
Semillas	2,5	0,9	0,3	96,3	0,0	0,0
Pieles	1,1	1,5	1,2	0,0	96,2	0,0
Dobles	10,0	3,3	0,1	0,0	4,2	82,4

En cuanto al material que se debe eliminar de la producción, el sistema fue capaz de detectar correctamente el 96 % de los gajos que contienen semillas y los trozos de piel que viajaban sobre la cinta transportadora, lo que significa que todavía queda un 4 % de producto que debería ser rechazado que se clasifica como de categoría aceptable. La tasa de éxito de los algoritmos en la separación de los gajos enteros fue del 93 %, mientras que la detección de los rotos fue de sólo el 83 %, debido principalmente al hecho de que la mayoría de roturas en muchos de estos gajos corresponden a pequeños fragmentos en un extremo, que el sistema tiene dificultad para detectar. Es por tanto necesario, desarrollar algoritmos específicos que sean capaces de detectar eficientemente estas pequeñas roturas, así como afinar en la detección de pieles y gajos con semillas. Esto se podrá realizar cuando el avance en los sistemas de computación permita un procesamiento más rápido todavía de las imágenes y, por lo tanto, la implementación de algoritmos más complejos.

La mayor confusión para la clase de mitades de gajo se produce con los gajos rotos. Desde el punto de vista comercial, esta confusión no es tan crítica como la que ocurre

entre los gajos rotos y enteros ya que ambos tipos de objetos pertenecen a categorías secundarias. En el caso de la confusión de mitades de gajo con enteros se produce cuando éstos tienen un tamaño excesivamente pequeño, por lo que, desde un punto de vista práctico, puede llegar a ser incluso beneficiosa para aumentar la calidad de la selección. Los gajos con semillas en su interior y los trozos de piel también pertenecen a la misma categoría y son rechazados por la misma salida. Sin embargo, no hay ninguna confusión entre estas dos clases.

El promedio total de éxito alcanzado por el prototipo en la detección es de aproximadamente el 90 %. Los resultados fueron similares en ambas pruebas, ya que los expertos de la empresa constataron que, efectivamente, la clasificación realizada por el prototipo, era adecuada y se mantenía dentro de un nivel de tolerancia aceptable, si bien en caso de una producción a escala sería necesario colocar un operador para inspeccionar el resultado de la inspección automática y enmendar los errores, principalmente en el caso de las pieles o gajos con semillas no rechazados.

En cuanto a la capacidad de discriminación de las variables utilizadas en la clasificación, se realizó un ensayo a partir de las imágenes obtenidas en la prueba 1 que consistió en la clasificación de los gajos utilizando cada una de las variables de forma individual e independiente, dando como resultado que las más discriminantes fueron *A* y *P*, alcanzando un 66 % y un 69 % respectivamente de gajos clasificados correctamente. Los resultados de este ensayo se muestran en la Tabla 5.3.

Tabla 5.3. Valores medios del éxito en la clasificación obtenido utilizando cada variable (transformada rápida de Fourier, compacidad, perímetro, área, factor de circularidad, simetría, elongación)

Variable	FFT	CM	P	A	CS	SM	EL
Acierto	36 %	48 %	69 %	66 %	48 %	50 %	32 %

No se han podido comparar estos porcentajes de clasificación correcta con otros trabajos ya que no hay máquinas para la inspección de gajos de mandarina descritos en la literatura.

5.4.2 Velocidad de procesamiento

El tiempo empleado en el procesamiento de una imagen fue de unos 48 ms, lo que se traduce en una tasa de análisis potencial de cerca de 22 imágenes/s. Sin embargo, la velocidad del sistema se ajustó para cada cámara a 4 imágenes/s debido a limitaciones mecánicas y a la fragilidad del producto. Esto abre la posibilidad de incluir soluciones más sofisticadas en el prototipo. Por ejemplo, se podrían introducir algoritmos de aprendizaje para adaptar automáticamente los parámetros de la clasificación a los cambios en el color de los gajos, similares a los propuestos por Picus y Peleg (2000) para dátiles o, como se ha comentado, incluir algoritmos más sofisticados para la detección de semillas y pieles, así como para reducir la confusión entre gajos enteros y rotos.

5.4.3 Pruebas intensivas en condiciones comerciales

El prototipo alcanzó el objetivo de 1.000 kg de producto por hora, que fue considerado como aceptable para fines comerciales. Sin embargo, el rendimiento depende de una adecuada alimentación de producto que evite acumulaciones en las cintas transportadoras.

A pesar de que se pueden encontrar en la literatura técnicas de procesamiento de imágenes que son similares a las empleadas en esta tesis, este trabajo no se centra sólo en el desarrollo de un novedoso sistema de visión por computador adaptado a un problema concreto, sino que también aporta soluciones de ingeniería para hacer posible la automatización del proceso de clasificación de gajos de mandarina, cuyas especiales cualidades hacen que sea un producto muy difícil de manejar y ordenar. Las soluciones tecnológicas adoptadas y los algoritmos propuestos en esta tesis han demostrado ser relevantes en la aplicación de la visión por computador para automatizar esta tarea.

5.5 Discusión

Este capítulo muestra el desarrollo de una solución de ingeniería para la inspección automática de la calidad de un producto muy frágil como son los gajos de mandarina. Se ha creado y probado un prototipo para inspeccionarlos y clasificarlos, demostrando que es capaz de alcanzar un rendimiento comercial con la actual configuración.

La unidad de alimentación, basada en una placa inclinada y estrechas cintas de transporte, es un dispositivo eficaz para la separación de los gajos y su reparto sobre las cintas transportadoras.

La unidad de inspección, con dos cámaras conectadas a un único ordenador, posee la capacidad suficiente para alcanzar las especificaciones de tiempo real y la precisión suficiente para cumplir con los requisitos de producción. El sistema de iluminación posterior, combinado con otro superior, ha ofrecido un adecuado rendimiento que ha permitido desarrollar algoritmos de análisis de forma eficaces. El sistema de clasificación fue capaz de separar la producción en cuatro categorías. La sincronización entre estos dos últimos sistemas utilizando un codificador óptico ha hecho que el rendimiento del prototipo sea independiente de la velocidad de las cintas transportadoras.

Esta máquina es única y diferente de otras diseñadas para la clasificación de frutas pequeñas o pre-elaboradas que se pueden encontrar en el mercado o incluso en la literatura, y es por eso que el prototipo se ha patentado, teniendo como fecha de concesión de la patente el 28/02/2011 y número de patente ES 2338293-B1.

6. Contribuciones de la tesis

Esta tesis ha realizado numerosas contribuciones científicas y tecnológicas que se han traducido en publicaciones en revistas científicas con índice de impacto, revistas de divulgación profesional, comunicaciones a congresos y patentes. De cada uno de los capítulos que describen el trabajo realizado (capítulos 3, 4 y 5) se ha obtenido al menos una publicación científica (seis en total, de las que cuatro son en revistas con índice de impacto) y una patente. Cabe destacar, por ejemplo, que la revisión del estado del arte se ha publicado como un trabajo de revisión en una revista situada en el número 4 de 126 en su área de conocimiento. En estos momentos se está preparando una nueva publicación que se enviará a la revista *JCR Transactions of the ASABE* describiendo el trabajo realizado en el capítulo 3, poniendo especial atención a los logros relacionados con el diseño de la campana de inspección, sistema de iluminación e incorporación de la cámara inteligente, todos ellos con el objetivo de realizar un sistema muy robusto y muy eficiente desde el punto de vista energético. Asimismo, se está preparando la solicitud de la patente de la plataforma móvil de asistencia a la recolección, en la que esta tesis ha participado aportando todo el sistema de selección de fruta mediante visión por computador.

Esta tesis ha aportado sistemas de visión por computador en el ámbito de la ingeniería agrícola aplicados en entornos complicados como es el de la fruta procesada o el de inspección en campo para lo que se han tenido que realizar desarrollos específicos. Si bien, estos desarrollos no representan innovaciones en sí mismos dentro de determinadas áreas del conocimiento, como el análisis de imagen o la mecánica, su conjunción y aplicación práctica en estos entornos ha llevado aparejada un importante trabajo de investigación que hace que las aportaciones realizadas sí se puedan considerar contribuciones en el área de Agroingeniería. Los prototipos de inspección y selección de fruta, operativos y probados en entornos reales, se pueden resumir en sí mismos como las principales aportaciones, aunque en realidad lo son las soluciones específicas que incorporan, como sistemas de manipulación y clasificación de la fruta, sistemas de iluminación y computación eficientes, algoritmos de análisis de imágenes de fruta rápidos y eficaces, y que se han descrito con detalle en las discusiones de los capítulos 3, 4 y 5.

De manera cuantitativa, las contribuciones científico-técnicas se muestran a continuación en los siguientes apartados.

6.1 Revistas recogidas en el JCR

Cubero S, Aleixos N, Moltó E, Gómez-Sanchis J, Blasco J (2011) Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables. *Food and Bioprocess Technology* 4(4), 487-504. DOI: 10.1007/s11947-010-0411-8. N° orden en su área de interés: 4/126. IF (2010): 3,576. N° citas: 7

Blasco J, Aleixos N, Cubero S, Gómez-Sanchis J, Moltó E (2009) Automatic sorting of satsuma (*Citrus unshiu*) segments using morphological features. *Computers and Electronics in Agriculture* 66 (1), 1-8. DOI 10.1016/j.compag.2008.11.006. N° orden en su área de interés: 7/45. IF: 1,312. N° citas: 9

Blasco J, Cubero S, Gómez-Sanchis J, Mira P, Moltó E (2009) Development of a machine for the automatic sorting of pomegranate (*Punica granatum*) arils based on computer vision. *Journal of Food Engineering* 90(1), 27-34. DOI 10.1016/j.jfoodeng.2008.05.035. N° orden en su área de interés: 17/118. IF: 2,313. N° citas: 18

Blasco J, Cubero S, Alegre-Sosa S, Gómez-Sanchis J, López-Rubira V, Moltó E (2008) Short communication. Automatic inspection of the pomegranate (*Punica granatum* L.) arils quality by means of computer vision. *Spanish Journal of Agricultural Engineering* 6(1), 12-16. N° orden en su área de interés: 21/35. IF: 0,388. N° citas: 3

6.2 Artículos en otras revistas científicas internacionales

Cubero S, Moltó E, Gutiérrez A, Aleixos N, García-Navarrete OL, Juste F, Blasco J (2010) Real-time inspection of fruit on a mobile harvesting platform in field conditions using computer vision. *Progress in Agricultural Engineering Science* 6, 1-16. DOI: 10.1556/Progress.6.2010.1

Blasco J, Cubero S, Arias R, Gómez J, Juste F, Moltó E (2007) Development of a computer vision system for the automatic quality grading of mandarin segments. Martí et al. (Eds.): *IbPRIA 2007*, Gerona (España), Junio 2007, part II, Lecture Notes in Computer Science, 4478, 460-466.

6.3 Libros y capítulos de libros

Blasco J, Aleixos N, Cubero S, Lorente D (2011) Fruit, vegetable and nut quality evaluation and control using computer vision. Capítulo 16 en: *Computer vision technology in the food and beverage industry* Woodhead Publishing. Cambridge (Reino Unido). Da-Wen Sun (editor). En edición. ISBN: 978-0-85709 036-2.

Blasco J, Aleixos N, Cubero S, Albert F, Lorente D, Gómez-Sanchis J (2011) In-line sorting of processed fruit using computer vision. Application to the inspection of satsuma segments and pomegranate arils. En: *Intelligent Data Analysis for Real-Life Applications: Theory and Practice*. IGI Global. Hershey (EE.UU.). R. Magdalena, M. Martínez, J.M. Martínez, P. Escandell, J. Vila. (editores). En edición. ISBN 978-1-4666-1806-0

6.4 Publicaciones de divulgación

Blasco J, Cubero S (2011) Uso de la visión artificial en la estimación automática de la calidad de los arilos de Granada. *Agrícola Vergel* 344, 76-76. ISSN: 0211-2728.

Blasco J, Cubero S, Gómez-Sanchis J, Moltó E (2010) Avances en visión automática de productos hortofrutícolas. *Horticultura Global* 288, 48-51. ISSN: 1132-2950.

Blasco J, Gutiérrez A, Alegre S, Cubero S, Gómez-Sanchis J, Alegre V, Moltó E (2008) Sistemas de visión artificial para la inspección automática de fruta procesada. Aplicación a gajos de satsuma y arilos de granada. *Levante Agrícola* 391, 198-203. ISSN: 0457-6039.

6.5 Contribuciones en congresos

Cubero S, Gutiérrez A, Juste F, Moltó E, Blasco J (2011) Automatic sorting of citrus fruits on a mobile harvesting platform using computer vision. Aceptado. Annual International Meeting ASABE 2011. Louisville, Kentucky (EE.UU), Agosto 2011. Comunicación oral.

Blasco J, Cubero S (2010) Uso de la visión artificial en la estimación automática de la calidad de los arilos de granada. I Jornadas nacionales sobre el granado: producción, economía, industrialización, alimentación y salud. Elche (España), Octubre 2010. Conferencia invitada.

Gutiérrez A, Blasco J, Chueca P, Alegre S, López S, Cubero S, Moltó E (2010) A machine for harvesting and in-field sorting of citrus fruits. Proceedings of the International Conference on Agricultural Engineering, AgEng 2010, Artículo 256. Clermont Ferrand (Francia), Septiembre 2010. Comunicación oral.

Cubero S, Moltó E, Aleixos N, García-Navarrete OL, Gutiérrez A, Juste F, Blasco J (2010) Automatic sorting of citrus fruits on a mobile harvesting machine using computer vision. II International Workshop on Computer Image Analysis in Agriculture. Budapest (Hungría), Agosto 2010. Comunicación oral.

Blasco J, Aleixos N, Cubero S, Juste F, Gómez-Sanchis J, Alegre V, Moltó E (2009) Computer vision developments for the automatic inspection of fresh and processed fruits. I International Workshop on Computer Image Analysis in Agriculture. Image Analysis for Agricultural Products and Processes, pp.21-34. ISSN 0947-7314. Potsdam (Alemania), Agosto 2009. Comunicación oral.

Blasco J, Cubero S, Alegre S, Juste F, Moltó E (2008) Automatic inspection of satsuma segments using computer vision. Artículo N° PAP1430 en CD del 4th CIGR Section VI International Symposium on Food and Bioprocess Technology. Foz do Iguaçu (Brasil), Septiembre 2008. Póster.

Blasco J, Cubero S, Aleixos N, Alegre S, Gómez-Sanchis J, Juste F, Moltó E (2008) Development of a prototype for the automatic selection of mandarin segments. Actas en CD del XX Congreso Internacional de Ingeniería Gráfica. Valencia (España), Junio 2008. Comunicación oral.

Blasco J, Cubero S, Arias R, Gómez J, Juste F, Moltó E (2007) Development of a computer vision system for the automatic quality grading of mandarin segments. 3ª Iberian Conference on Pattern Recognition and Image Analysis. J. Martí et al. (Eds.): IbPRIA 2007, part II, LNCS 4478, pp. 460–466. Gerona (España), Junio 2007. Póster.

6.6 Patentes obtenidas

Título	Máquina para la inspección automática de arilos de granada mediante visión artificial
Inventores	Blasco J, Perán M, Cubero S, Alegre S, Mira JM, Gómez-Sanchis J, Aleixos N, Mira P, Moltó E
Solicitud	P200801189
Número de patente	ES 2352713-B1
Fecha de prioridad	24/04/2008
Fecha de concesión	30/09/2011
Entidad titular	Frutas Mira Hermanos, S.L.- Instituto Valenciano de Investigaciones Agrarias
Empresa que está explotando	Frutas Mira Hermanos, S.L.
Descripción	Máquina para la inspección y clasificación automática de la calidad de los granos de granada mediante visión artificial, desarrollada mediante un convenio de colaboración con la empresa explotadora

Título	Máquina para la clasificación de gajos de mandarina para conserva
Inventores	Blasco J, Cubero S, Alegre S, Gómez J, Juste F, Moltó E
Solicitud	P200703384
Número de patente	ES 2338293-B1
País de prioridad	España
Fecha de prioridad	20/12/2007
Fecha de concesión	28/02/2011
Entidad titular	Instituto Valenciano de Investigaciones Agrarias
Descripción	Máquina para la inspección y clasificación automática de la calidad de gajos de satsuma mediante visión artificial.

7. Conclusiones

Atendiendo a los objetivos planteados, se han desarrollado sistemas completos de visión por computador, diseñados y programados específicamente para la inspección y selección automática de fruta en entornos complejos como es el campo o la industria de la fruta procesada.

7.1 Sistema de inspección de fruta en campo

A lo largo de esta tesis se ha diseñado y construido la campana de inspección y el sistema de iluminación, se ha incorporado una cámara inteligente para el procesamiento de las imágenes, se ha instalado el cableado y se ha programado todo el software de análisis de imagen. Más detalladamente:

Se han diseñado dos configuraciones diferentes de la campana de inspección con el objetivo de disminuir en la medida de lo posible la altura de la máquina. En la primera de ellas la cámara se instala en la parte superior de la campana con una configuración tradicional. La segunda campana se diseñó de forma que la cámara estuviera instalada en el plano horizontal paralelo a la línea de avance de la fruta. La cámara adquiere la imagen de la fruta reflejada en un espejo. De esta forma, la distancia entre la fruta y la cámara se obtiene mediante una separación horizontal, reduciendo el alzado de la campana de algo más de un metro a 32 cm. La estructura del espejo y de la cámara permite todos los ajustes necesarios, en altura, anchura y distancia, pudiéndose desmontar y montar completamente sin modificar dichos ajustes simplificando las labores de mantenimiento.

Se han realizado pruebas con diversos sistemas de iluminación: tubos fluorescentes, lámparas halógenas y LED. Finalmente se ha optado por iluminar la fruta mediante cuatro tiras de 48 LED funcionando en modo estroboscópico. Las pruebas demostraron que se reducía la energía consumida por las lámparas en un 93 % a la vez que se reducía considerablemente la emisión de calor, permitiendo así instalar los filtros polarizadores dentro del plástico de protección de las propias lámparas, lo que ha simplificado el montaje y el mantenimiento.

Se han probado dos configuraciones para adquirir y analizar las imágenes, una basada en una cámara conectada a un ordenador y otra que usa una cámara con capacidad de procesamiento propio. La primera, *Sistema PC*, es más rápida pero presenta la dificultad de que es necesario conectar un inversor de corriente a la batería de la máquina, lo que hace el sistema bastante complejo y muy ineficiente desde el punto de vista energético y, por tanto limita su autonomía. La segunda configuración, *Sistema Inteligente* ofrece una solución más compacta y adecuada a este trabajo, simplificando el conjunto y optimizando el consumo eléctrico considerablemente.

Ambos sistemas permiten capturar simultáneamente cuatro frutas por cada línea en una imagen. Las pruebas realizadas concluyen que es posible cumplir con las especificaciones de capturar y procesar las imágenes a una velocidad de ocho frutas por segundo, capturando cuatro imágenes de cada fruta mientras ésta rota a su paso por la zona de inspección. Debido a la escasa potencia del procesador que incorpora la cámara inteligente usada, ha sido necesario optimizar los algoritmos para obtener la velocidad de procesamiento requerida, lo que ha llevado a la necesidad de establecer un compromiso entre la velocidad de procesamiento y la eficacia de la inspección que ha impedido una adecuada detección de los defectos de las frutas, considerándose suficiente para el logro de los objetivos del proyecto marco del trabajo la estimación del calibre y el color.

Se han diseñado e implementado los algoritmos de adquisición y procesamiento de las imágenes, capaces de analizar en tiempo real para cada fruta el diámetro, el color y la presencia de defectos externos. Los datos de cada fruta se estiman como el promedio obtenido en el total de las imágenes adquiridas de esa fruta y se envían a través del puerto de comunicaciones. Los resultados obtenidos en los ensayos realizados han demostrado que el sistema es capaz de estimar el calibre y el color con gran precisión, con correlaciones muy elevadas y próximas al 99 % de acierto en casi todos los casos y ofreciendo unos resultados en la clasificación muy elevados. Sin embargo es necesario seguir trabajando en la mejora de la iluminación y en la optimización de los algoritmos para detectar los defectos.

En definitiva, se ha creado un sistema para analizar frutas en tiempo real mediante visión por computador en condiciones de campo. Estas condiciones han impuesto restricciones en cuanto al tamaño de la campana de inspección y al consumo energético del sistema, que se han cumplido mediante la configuración de la campana con un espejo y el uso de una cámara inteligente junto con el sistema estroboscópico de iluminación, que ha resultado ser un sistema muy eficiente desde el punto de vista energético y ha permitido alimentar todo el sistema de inspección directamente con la batería de la plataforma móvil.

7.2 Sistema de inspección de fruta procesada

Se han desarrollado dos sistemas de inspección de fruta procesada mediante visión por computador, no habiendo encontrado hasta la fecha constancia de máquinas comerciales similares que realicen estas tareas. Ante el problema de la separación física de un producto tan delicado, los prototipos se han diseñado de forma que constan de un sistema de alimentación basado en una plataforma vibradora que conduce el producto hasta unas cintas transportadoras relativamente estrechas, que facilitan su individualización y posibilitan su separación en categorías. La elevada velocidad de las cintas (1 m/s) hace que las frutas se separen al caer sobre las mismas, transportándolas hasta la campana de inspección, que es donde se adquieren las imágenes, y después hasta la zona de expulsión, compuesta por una serie de salidas ubicadas a un lado de cada cinta transportadora. Al otro lado de las cintas se ubican

unas boquillas de expulsión de aire a presión que empujan al producto hacia las salidas cuando así lo decide el sistema de visión.

Ambos prototipos cuentan con dos cámaras de video. Las dos cámaras no adquieren las imágenes de manera simultánea sino que se diseñó una estrategia que permite capturar la imagen de una cámara al mismo tiempo que se analiza una imagen anteriormente capturada por la otra cámara. Con esta estrategia se consiguió una optimización considerable del tiempo de proceso. Se ha desarrollado todo el software de análisis de las imágenes específicamente para la inspección de fruta procesada. Se han realizado pruebas con gajos de mandarina y, granos de granada, existiendo empresas de estos sectores que se han interesado por los resultados del proyecto y que han firmado convenios de colaboración con el IVIA para su desarrollo y explotación.

En el caso de los gajos de mandarina se ha optado por una iluminación posterior debido a que se busca obtener el contorno de los gajos para calcular parámetros morfológicos. Al iluminar por debajo se maximiza el contraste del gajo con el fondo iluminado de la imagen así como el contraste entre el gajo y posibles semillas que pudiera contener. Para el resto se ha optado por una iluminación superior debido a que el objetivo es estimar el color y la presencia de daños externos.

Se han diseñado e implementado algoritmos específicos para analizar las características de estas frutas y clasificarlas en tiempo real. El software desarrollado incluye los algoritmos de segmentación de las imágenes y de extracción de características de las frutas que, en el caso de los gajos de mandarina son los siguientes: área, perímetro, elongación, factor de forma, compacidad, simetría bilateral y los descriptores de Fourier del contorno, y en el caso de los arilos son área y color. Se programaron rutinas que calculan todos estos parámetros y que clasifican los gajos como enteros, rotos, trozos o con semillas, y los arilos en distinta gama de color, atendiendo a las exigencias de las empresas que colaboraron en esta investigación, y además separando en ambos casos elementos no deseados.

La sincronización entre las cintas transportadoras, la captura de las imágenes, la posición del producto y la expulsión está controlada por un codificador de pulsos sujeto al rodillo de tracción de las cintas y conectado al *ordenador de control* del prototipo. La unión del sistema de visión y el prototipo se probó en el laboratorio para determinar el grado de precisión en la expulsión, que se estimó en 2 mm y la separación mínima entre piezas de fruta, que se estimó en 20 mm aproximadamente en ambos casos.

Por último, los prototipos se probaron en condiciones reales de trabajo en las empresas Agricons, S.A., productora de gajos de satsuma sita en Algemés (Valencia) y Santiago Mira, S.L., productora de granos de granada ubicada en Elche (Alicante). Ambas empresas tienen automatizados todos los procesos de manipulación del producto, excepto la inspección final que se continúa realizando manualmente. En ambos casos se ubicó el prototipo junto a las líneas de clasificación manual de forma que el producto llegara hasta el mismo de manera automática. Los resultados

7. Conclusiones

obtenidos en cuanto a rendimiento y discriminación en diferentes categorías permiten pensar en su aplicación práctica.

8. Referencias bibliográficas

Abdullah MZ, Mohamad-Saleh J, Fathinul-Syahir AS, Mohd-Azemi BMN (2006). Discrimination and classification of fresh-cut starfruits (*Averrhoa carambola L.*) using automated machine vision system. *Journal of Food Engineering*, 76, 506–523.

Aleixos N, Blasco J, Navarrón F, Moltó E (2002). Multispectral inspection of citrus in real-time using machine vision and digital signal processors. *Computers and Electronics in Agriculture*, 33(2), 121-137.

Al-Mallahi A, Kataoka T, Okamoto H, Shibata Y (2010). Detection of potato tubers using an ultraviolet imaging-based machine vision system. *Biosystems Engineering*, 105(2), 257-265.

Antonucci F, Costa C, Pallottino F, Paglia G, Rimatori V, De Giorgio D, Menesatti P (2010). Quantitative method for shape description of almond cultivars (*Prunus amygdalus* Batsch). *Food and Bioprocess Technology*, DOI: 10.1007/s11947-010-0389-2, in-press.

Ariana DP, Guyer DE, Shrestha B (2006a). Integrating multispectral reflectance and fluorescence imaging for defect detection on apples. *Computers and Electronics in Agriculture*, 50, 148–161.

Ariana DP, Lu R, Guyer DE (2006b). Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers. *Computers and Electronics in Agriculture*, 53, 60–70.

Aynalem HA, Righetti TL, Reed BM. (2006). Nondestructive evaluation of *in vitro*-stored plants: A comparison of visual and image analysis. In *Vitro Cellular and Developmental Biology-Plant*. 42, 562–567.

Baeten J, Donné K, Boedrij S, Beckers W, Claesen E (2008). Autonomous fruit picking machine: a robotic apple harvester. *Springer Tracks in Advanced Robotics* 42:531-539.

Barnes M, Duckett T, Cielniak G, Stroud G, Harper G (2010). Visual detection of blemishes in potatoes using minimalist boosted classifiers *Journal of Food Engineering*, 98(3), 339-346.

Bayes, Thomas (1763). An Essay towards solving a Problem in the Doctrine of Chances. *Philosophical Transactions of the Royal Society of London* 53, 370–418.

Bei L, Dennis GI, Miller HM, Spaine TW, Carnahan JW (2004). Acousto-optic tunable filters: fundamentals and applications as applied to chemical analysis techniques. *Progress in Quantum Electronics*, 28(2), 67-87.

- Bennedsen BS, Peterson DL (2005a). Performance of a system for apple surface defect identification in near-infrared images. *Biosystems Engineering*, 90(4), 419–431.
- Bennedsen BS, Peterson DL, Tabb A (2005b). Identifying defects in images of rotating apples. *Computers and Electronics in Agriculture*, 48, 92–102.
- Blasco J, Aleixos N, Moltó E (2003). Machine vision system for automatic quality grading of fruit. *Biosystems Engineering*, 85(4), 415-423.
- Blasco J, Aleixos N, Moltó E (2007a). Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. *Journal of Food Engineering*, 81(3), 535–543.
- Blasco J, Aleixos N, Gómez J, Moltó E (2007b). Citrus sorting by identification of the most common defects using multispectral computer vision. *Journal of Food Engineering*, 83(3), 384-393.
- Blasco J, Aleixos N, Cubero S, Gómez-Sanchis J, Moltó E (2009a). Automatic sorting of satsuma (*Citrus unshiu*) segments using computer vision and morphological features. *Computers and electronics in agriculture*, 66, 1-8.
- Blasco J, Aleixos N, Gómez-Sanchis J, Moltó E (2009b). Recognition and classification of external skin damage in citrus fruits using multispectral data and morphological features. *Biosystems Engineering*, 103, 137-145.
- Blasco J, Cubero S, Gómez-Sanchis J, Mira P, Moltó E (2009c). Development of a machine for the automatic sorting of pomegranate (*Punica granatum*) arils based on computer vision. *Journal of Food Engineering*, 90(1), 27–34.
- BOE (2010). Boletín Oficial del Estado Orden PRE/52/2010, de 21 de enero, por la que se modifican los anexos II, IX, XI, XII y XVIII del Reglamento General de Vehículos, aprobado por Real Decreto 2822/1998, de 23 de diciembre. 6711-6734. Disponible en: <http://www.boe.es/boe/dias/2010/01/23/pdfs/BOE-A-2010-1011.pdf>
- Bulanon DM, Burks TF, Alchanatis V (2009). Image fusion of visible and thermal images for fruit detection. *Biosystems Engineering*, 103(1), 12-22.
- Chen G, Bui TD (1999). Invariant Fourier-wavelet descriptor for pattern recognition. *Pattern Recognition* 32, 1083-1088.
- Cho SI, Lee DS, Jeong JY (2002). Plant discrimination by machine vision and artificial neural network. *Biosystems Engineering* 83(3), 275-280.
- Costa C, Menesatti P, Paglia G, Pallottino F, Aguzzi J, Rimatori V, Russo G, Recupero S, Recupero GR (2009). Quantitative evaluation of Tarocco sweet orange fruit shape using optoelectronic elliptic Fourier based analysis. *Postharvest Biology and Technology*, 54(1), 38-47.
- Cox A (1979). *Óptica fotográfica. Un enfoque moderno de la técnica de la definición*. Ediciones Omega, S.A., Barcelona (España). ISBN: 84-282-0559-0

- Díaz R, Faus G, Blasco M, Blasco J, Moltó E (2000). The application of a fast algorithm for the classification of olives by machine vision. *Food Research International*, 33, 305-309.
- Díaz R, Gil L, Serrano C, Blasco M, Moltó E, Blasco J (2004). Comparison of three algorithms in the classification of table olives by means of computer vision. *Journal of Food Engineering*, 61, 101–107.
- DOGV (2006). *Diari Oficial de la Comunitat Valenciana*, 5346, 30321-30328.
- Du C-J, Sun D-W (2006). Learning techniques used in computer vision for food quality evaluation: a review. *Journal of Food Engineering*, 72, 39–55
- Dubey BP, Bhagwat SG, Shoucheand SP, Sainis JK (2006). Potential of artificial neural networks in varietal identification using morphometry of wheat grains. *Biosystems Engineering* 95(1), 61-67.
- Duda RO, Hart PE, Stork DG (2001). *Pattern Classification*. John Wiley & Sons, Nueva York, EE.UU. ISBN: 0-471-05669-3
- Dunn GM, Martin SR (2004). Yield prediction from digital image analysis: A technique with potential for vineyard assessments prior to harvest. *Australian Journal of Grape and Wine Research* 10, 196-198.
- Edan Y, Rogozin D, Flash T, Miles GE (2000). Robotic melon harvesting. *IEEE Transactions on Robotics and Automation* 16(6):831-834.
- EIMasry G, Wang N, ElSayed A, Ngadi M (2007). Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry. *Journal of Food Engineering*, 81, 98–107.
- EIMasry G, Wang N, Vigneault C, Qiao J, ElSayed A (2008). Early detection of apple bruises on different background colors using hyperspectral imaging. *LWT* 41, 337–345.
- EIMasry G, Wang N, Vigneault C (2009). Detecting chilling injury in Red Delicious apple using hyperspectral imaging and neural networks. *Postharvest Biology and Technology*, 52, 1–8.
- Evans MD, Thai CN, Grant JC (1998). Development of a spectral imaging system based on a liquid crystal tunable filter. *Transactions of the ASAE*, 41(6), 1845-1852.
- Fathi M, Mohebbi M, Ali Razavi SM (2011). Application of image analysis and artificial neural network to predict mass transfer kinetics and color changes of osmotically dehydrated kiwifruit. *Food and Bioprocess Technology*, 4(8), 1357-1366.
- Fernández L, Castillero C, Aguilera JM (2005). An application of image analysis to dehydration of apple discs. *Journal of Food Engineering*, 67, 185–193.
- Foley J. Van Dam A, Feiner S, Hughes J (1996). *Computer Graphics. Principles and Practice*. Addison-Wesley Publishing Company, 2nd edition.

- Freeman H (1961). On the encoding of arbitrary geometric configurations. IEEE Trans. Elect. Computers. EC-10:260-268
- Gardner JL (2007). Comparison of calibration methods for tristimulus colorimeters. Journal of Research of the National Institute of Standards and Technology, 112, 129-138.
- Gil MI, Tomás-Barberán FA, Hess-Pierce B, Holcroft DM, Kader AA (2000). Antioxidant activity of pomegranate juice and its relationship with phenolic composition and processing. J. Agric. Food Chem., 48, 4581-4589
- Gómez-Sanchis J, Gómez-Chova L, Aleixos N, Camps-Valls G, Montesinos-Herrero C, Moltó E, Blasco J (2008a). Hyperspectral system for early detection of rottenness caused by *Penicillium digitatum* in mandarins. Journal of Food Engineering, 89(1), 80-86.
- Gómez-Sanchis J, Moltó E, Camps-Valls G, Gómez-Chova L, Aleixos N, Blasco J (2008b). Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. Journal of Food Engineering, 85(2), 191-200.
- Gonzalez RC, Woods RE (2002). Digital image processing, Prentice Hall, NJ (USA).
- Gowen AA, Taghizadeh M, O'Donnell CP (2009). Identification of mushrooms subjected to freeze damage using hyperspectral imaging. Journal of Food Engineering, 93, 7-12.
- Gracia, C (1999). Estado actual y avances en la mecanización del cultivo de agrios. Vida rural 95: 68-74. ISSN 1133-8938.
- Gunasekaran S (1987). Image processing for stress cracks in corn kernels. Transactions of the ASAE, 30(1), 266-270.
- Hernández-Sánchez N, Hills B, Barreiro P, Marigheto N (2007). A NMR study on internal browning in pears. Postharvest Biology and Technology, 44, 260-270.
- Hetchts E (1998). Optics. Addison Wesley Longman, 3rd edition.
- Hoffman G (2010). CIE colour space. <http://www.fho-emden.de/~hoffmann/ciexyz29082000.pdf>. Accessed June 2010.
- HunterLab (2008). Application note: Hunter L,a,b versus CIE 1976 L*a*b*. Available at: http://www.hunterlab.com/appnotes/an02_01.pdf. Accessed June 2010.
- Hutchings, JB (ed) (1999). Food Color and Appearance. Aspen Publishers, Inc., Gaithersburg, MD
- Huxoll CC, Bolin HR, Mackey BE (1995). Near infrared analysis potential for grading raisin quality and moisture. Journal of Food Science, 60(1), 176-180.

- Intercitrus (2009). El sector de las naranjas y grupo mandarinas en España. Disponible en:
<http://www.intercitrus.org/NdSite/OnLineCache/FMS/30/42/58bc1592adedd8f2dd2c4e9b6dac7072/Sector%20narman211009def.pdf>. Último acceso Enero 2012.
- Jain AK (1989) Fundamentals of Digital Image Processing. New Jersey, United States of America: Prentice Hall. pp. 68, 71, 73. ISBN 0-13-336165-9.
- Jarimopas B, Jaisin N (2008). An experimental machine vision system for sorting sweet tamarind. *Journal of Food Engineering*, 89, 291–297.
- Jiménez-Cuesta M, Cuquerella J, Martínez-Jávega JM (1981). Determination of a color index for citrus fruit degreening. *Proceedings of the International Society of Citriculture* (2), 750-753.
- Juste F, Martín B, Fabado F, Moltó E (2000). Estudio sobre la reducción de los costes de producción de cítricos mediante la mecanización de las prácticas de cultivo. *Todo Citrus* 8, 29-36.
- Jutras PJ, Coppock GE (1958). Mechanization of citrus fruit picking. *Florida State Horticultural Society* 71:201,204
- Kang SP, East AR, Trujillo FJ (2008). Colour vision system evaluation of bicolour fruit: A case study with 'B74' mango. *Postharvest Biology and Technology*, 49, 77–85.
- Karimi Y, Maftoonazad N, Ramaswamy HS, Prasher SO, Marcotte M (2009). Application of hyperspectral technique for color classification avocados subjected to different treatments. *Food and Bioprocess Technology*, DOI: 10.1007/s11947-009-0292-x, in press.
- Kim MS, Chen YR, Mehl PM (2001). Hyperspectral reflectance and fluorescence imaging system for food quality and safety. *Transactions of the ASAE*, 44(3), 721-729.
- Koc AB (2007). Determination of Watermelon Volume Using Ellipsoid Approximation and Image Processing. *Postharvest Biology and Technology*, 45(3), 366-371.
- Kopparapu SK, Desai UB (2001). Bayesian Approach to Image Interpretation, Klurwer Academic Publishers, Norwell (MA), EE.UU. ISBN 978-0792373728.
- Lansky EP, Newman RA (2007). *Punica granatum* (pomegranate) and its potential for prevention and treatment of inflammation and cancer. *Journal of Ethnopharmacology*, 109(2), 177-206.
- Lee DJ, Schoenberger R, Archibald J, McCollum S (2008). Development of a machine vision system for automatic date grading using digital reflective near-infrared imaging. *Journal of Food Engineering*, 86(3), 388-398.

Leemans V, Destain MF (2004). A real-time grading method of apples based on features extracted from defects. *Journal of Food Engineering*, 61(1), 83-89.

Lefcote AM, Kim MS (2006a). Technique for normalizing intensity histograms of images when the approximate size of the target is known: detection of feces on apples using fluorescence imaging. *Computers and Electronics in Agriculture*, 50, 135–147.

Lefcote AM, Kim MS, Chen Y-R, Kang B (2006b). Systematic approach for using hyperspectral imaging data to develop multispectral imaging systems: Detection of feces on apples. *Computers and Electronics in Agriculture*, 54, 22–35.

León K, Domingo M, Pedreschi F, León J (2006). Color measurement in L*a*b* units from RGB digital images. *Food Research International*, 39, 1084–1091.

Liming X, Yanchao Z (2010). Automated strawberry grading system based on image processing. *Computers and Electronics in Agriculture*, 71(S1), S32-S39.

Lleó L, Barreiro P, Ruiz-Altisent M, Herrero A (2009). Multispectral images of peach related to firmness and maturity at harvest. *Journal of Food Engineering*, 93(2), 229-235.

Lorente D, Aleixos N, Gómez-Sanchis J, Cubero S, García-Navarrete OL, Blasco J (2012). Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment. *Food and Bioprocess Technology* (aceptado). DOI: 10.1007/s11947-011-0725-1.

Lootens P, Van Waes J, Carlier L (2007). Description of the morphology of roots of *Chicorium intybus* L. partim by means of image analysis: comparison of elliptic Fourier descriptors classical parameters. *Computers Electronics in Agriculture* 58(2), 164-173.

López-García F, Andreu-García A, Blasco J, Aleixos N, Valiente JM (2010). Automatic detection of skin defects in citrus fruits using a multivariate image analysis approach. *Computers and Electronics in Agriculture*, 71, 189–197.

Malik A, Afaq F, Sarfaraz S, Adhami VM, Syed DN, Mukhtar H (2005). Pomegranate fruit juice for chemoprevention and chemotherapy of prostate cancer. *PNAS*, 102(41), 14813 - 14818.

Marchant JA, Onyango CM (2003). Comparison of a Bayesian classifier with a multilayer feed-forward neural network using the example of plant/weed/soil discrimination. *Computers and Electronics in Agriculture*, 39(1), 3-22.

Martínez-Jávega JM, Salvador A, Navarro P (2007) Adecuación del tratamiento de desverdización para minimizar alteraciones fisiológicas durante la comercialización de mandarinas. En: V Congreso Iberoamericano de Tecnología Postcosecha y Agroexportaciones. Cartagena (Murcia), 29 de mayo al 5 de junio de 2007. Comunicación S3-O106.

- Mebatsion HK, Paliwal J, Jayas DS (2012) Evaluation of variations in the shape of grain types using principal components analysis of the elliptic Fourier descriptors. *Computers and Electronics in Agriculture* 80, 63–70.
- Melgarejo P, Martínez JJ, Hernández F, Martínez-Font R, Barrows P, Erez A (2004). Kaolin treatment to reduce pomegranate sunburn. *Scientia Horticulturae*, 100(1), 349-353.
- Mendoza F, Dejmek P, Aguilera JM (2006). Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, 41, 285–295.
- Menesatti P, Costa C, Paglia G, Pallottino F, D’Andrea S, Rimatori V, Aguzzi J (2008). Shape-based methodology for multivariate discrimination among Italian hazelnut cultivars *Biosystems Engineering*, 101, 417-424.
- Menesatti P, Zanella A, D’Andrea S, Costa C, Paglia G, Pallottino F (2009). Supervised multivariate analysis of hyper-spectral NIR images to evaluate the starch index of apples. *Food and Bioprocess Technology*, 2, 308-314.
- Milczarek RR, Saltveit ME, Garvey TC, McCarthy MJ (2009). Assessment of tomato pericarp mechanical damage using multivariate analysis of magnetic resonance images. *Postharvest Biology and Technology*, 52, 189–195
- Muscato G, Prestifilippo M, Abbate N, Rizzuto I (2005). A prototype of an orange picking robot: past history and experimental results. *Industrial Robot* 32(2):128-138.
- Neto JC, Meyer GE, Jones DD, Samal AK (2006). Plant species identification using Elliptic Fourier leaf shape analysis. *Computers Electronics in Agriculture* 50(2), 121-134.
- Nicolaï BM, Lötze E, Peirs A, Scheerlinck N, Theron KI (2006). Non-destructive measurement of bitter pit in apple fruit using NIR hyperspectral imaging. *Postharvest Biology and Technology*, 40, 1-6.
- Obenland D, Neipp P (2005). Chlorophyll fluorescence imaging allows early detection and localization of lemon rind injury following hot water treatment. *Hortscience*, 40(6), 1821-1823.
- Okamoto H, Lee WS (2009). Green citrus detection using hyperspectral imaging. *Computers and Electronics in Agriculture* 66(2), 201–208.
- Oowski S, Nghia DD (2002). Fourier wavelet descriptors fro shape recognition using neural networks – a comparative study. *Pattern Recognition* 35, 1949-1957.
- Paulus I, De Busscher R, Schrevens E (1997). Use of image analysis to investigate human quality classification of apples. *Journal Agricultural Engineering Research*, 68, 341-53.

Pedreschi F, León J, Mery D, Moyano P (2006). Development of a computer vision system to measure the color of potato chips. *Food Research International*, 39, 1092–1098.

Peterson C (2001). How it works: the charged-coupled device or CCD. *Journal of young investigators*. Available at:

<http://www.jyi.org/volumes/volume3/issue1/features/peterson.html>. Accessed June 2010.

Picus M, Peleg K (2000). Adaptive classification – A case study on sorting dates. *Journal of Agricultural and Engineering Research*, 76(4), 409-418.

Plá F, Juste F, Moltó E (1991). An approach to citrus vision systems in robotic harvesting. 1st. International Seminar of on machine vision systems for the Agriculture and Bio industries. G. Rabatel (editor), pp. 47-59.

Plá F, Juste F (1995). A thinning based algorithm to characterize fruit stems from profile images. *Computers and Electronics in Agriculture*, 13, 301-314.

Polder G, van der Heijden GWAM, Keizer LCP, Young IT (2003). Calibration and characterization of spectral imaging systems. *Journal Near Infrared Spectroscopy*, 11, 193-210. *Postharvest Biology and Technology*, 36(3), 281-290.

Poynton, C (ed) (1996). *A Technical Introduction to Digital Video*. John Wiley & Sons, New York, pp. 91-114

Pydipati R, Burks TF, Lee WS (2006). Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture*, 52, 49–59.

Qin J, Burks TF, Ritenour MA, Bonn WG (2009). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of Food Engineering*, 93, 183-191.

Quevedo R, Mendoza F, Aguilera JM, Chanona J, Gutiérrez-López G (2008). Determination of senescent spotting in banana (*Musa cavendish*) using fractal texture Fourier image. *Journal of Food Engineering*, 84, 509–515.

Reese D, Lefcourt AM, Kim MS, Lo YM (2010). Using parabolic mirrors for complete imaging of apple surfaces. *Bioresource Technology*, 100, 4499–4506.

Riquelme MT, Barreiro P, Ruiz-Altisent M, Valero C (2008). Olive classification according to external damage using image analysis. *Journal of Food Engineering*, 87, 371–379.

Ruiz LA, Moltó E, Juste F, Plá F, Valiente R (1996). Location and characterization of the stem-calyx area on oranges by computer vision. *Journal of Agricultural Engineering Research*, 64, 165-172.

- Ruiz-Altisent M, Ortiz-Cañavate J, Valero C (2007). Fruit and vegetables harvesting systems. In *Production practices and quality assessment of food crops*, Vol. 1: preharvest practice, ed. Ramdane Dris and Shri Mohan Jain, 261-285.
- Russ JC (2006). *The Image Processing Handbook*, Fifth Edition. CRC Press, Boca raton (FL) EE.UU. ISBN 978-0849372544.
- Sadriani H, Rajabipour A, Jafary A, Javadi A, Mostofi Y (2007). Classification and analysis of fruit shapes in long type watermelon using image processing. *International Journal of Agriculture and Biology*, 1, 68-70.
- Safren O, Alchanatis V, Ostrovsky V, Levi O (2007). Detection of green apples in hyperspectral images of apple-tree foliage using machine vision. *Transactions of the ASABE*, 50(6), 2303-2313.
- Sakai N, Yonekawa S, Matsuzaki A, Morishima H (1996). Two-dimensional image analysis of the shape of rice its application to separating varieties. *Journal of Food Engineering* 27(4), 397-407.
- Samal A, Iyengar PA (1993). Natural shape detection based on principal component analysis. *Journal of Electronic Imaging* 02(03), 253-263.
- Scarfe A, Flemmer R, Bakker H, Flemmer C (2009). Development of an autonomous kiwifruit picking robot. In *Proc. of the 4th International Conference on Autonomous Robots and Agents (ICARA 2009)*, 380-384. Wellington, USA.
- Schubert SY, Lansky EP, Neeman I (1999). Antioxidant and eicosanoid enzyme inhibition properties of pomegranate seed oil and fermented juice flavonoids. *J. Ethnopharmacol*, 66, 11-17.
- Shouche SP, Rastogi R, Bhagwat SG, Sainis JK (2001). Shape analysis of grains of Indian wheat varieties. *Computers Electronics in Agriculture* 33(1), 55-76.
- Shrivastava RJ, Gebelein JL (2007). Land cover classification and economic assessment of citrus groves using remote sensing. *ISPRS Journal of Photogrammetry & Remote Sensing* 61, 341-353.
- Slaughter DC, Obenland DM, Thompson JF, Arpaia ML, Margosan DA (2008). Non-destructive freeze damage detection in oranges using machine vision and ultraviolet fluorescence. *Postharvest Biology and Technology*, 48(3), 341-346.
- Stokes M, Anderson M, Chandrasekar S, Motta R (1996). A standard default color space for the internet: sRGB. <http://www.color.org/sRGB.xalter>. Accessed June 2010.
- Sun D-W (ed) (2007). *Computer vision technology for food quality evaluation*. Academic Press, Elsevier Science, London, UK.
- Sun D-W (ed) (2010). *Hyperspectral imaging for food quality analysis and control*. Academic Press, Elsevier Science, London, UK.

- Tao Y, Morrow CT, Heinemann PH, Sommer HJ (1995). Fourier-Based Separation Technique for Shape Grading of Potatoes Using Machine Vision. *Transactions of the ASAE*, 38(3), 949-957.
- Tenenbaum, RA (2004). *Fundamentals of Applied Dynamics*, Springer.
- Throop JA, Aneshansley DJ, Upchurch BL (1995). An image processing algorithm to find new old bruises. *Applied engineering in agriculture* 11(5), 751-757.
- Throop JA, Aneshansley DJ, Anger WC, Peterson DL (2005). Quality evaluation of apples based on surface defects: development of an automated inspection system. *Postharvest Biology and Technology* 36, 281–90.
- Tijskens LMM, Schouten RE, Lin WC (2005). Predicting harvest labour allocation in bell pepper production. *Acta Horticulturae*, 682, 1435–1442.
- Unay D, Gosselin B (2006). Automatic defect segmentation of 'Jonagold' apples on multi-spectral images: A comparative study. *Postharvest Biology and Technology*, 42(3), 271–279.
- Unay D, Gosselin B (2007). Stem and calyx recognition on 'Jonagold' apples by pattern recognition. *Journal of Food Engineering*, 78, 597–605.
- Vizmanos JG, Fuentes LM, Gutierrez JA (1997). Splinter detection in half-cut peaches. In *Proceedings of the SPIE*, 3208 pp. 277-286.
- Xiang R, Ying Y, Jiang H (2011). Research on image segmentation methods of tomato in natural conditions. En: *4th International Congress on Image and Signal Processing*, 3, pp.1268–1272.
- Xiaobo Z, Jiewen Z, Yanxiao L (2007). Apple color grading based on organization feature parameters. *Pattern Recognition Letters*, 28, 2046–2053.
- Xiaobo Z, Jie-wen Z, Yanxiao L, Holmes M (2010). In-line detection of apple defects using three color cameras system. *Computers and Electronics in Agriculture*, 70, 129–134.
- Xing J, Jancsó P, De Baerdemaeker J (2007). Stem-end/calyx identification on apples using contour analysis in multispectral images. *Biosystems Engineering*, 96(2), 231–237.
- Xul Q, Zou X, Zhao J (2009). On-Line Detection of Defects on Fruit by Machinevision Systems Based on Three-Color-Cameras Systems. *Computer and Computing Technologies in Agriculture II*, 295, 2231-2238.
- Ye X, Sakai K, Garciano LO, Asada S-I, Sasao A (2006). Estimation of citrus yield from airborne hyperspectral images using a neural network model. *Ecological modelling* 198, 426–432.

Ye X, Sakai K, Sasao A, Asada S-I (2008). Potential of airborne hyperspectral imagery to estimate fruit yield in citrus. *Chemometrics and Intelligent Laboratory Systems* 90, 132-144.

Zhao X, Burks TF, Qin J, Ritenour MA (2009). Digital microscopic imaging for citrus peel disease classification using color texture features. *Applied engineering in agriculture*, 25(5), 769-776.

Zion B, Chen P, McCarthy MJ (1995). Detection of bruises in magnetic resonance images of apples. *Computers and Electronics in Agriculture* 13, 289-299.

Zude M (ed) (2008). *Optical monitoring of fresh and processed agricultural crops*. CRC Press, Boca Raton, USA.

Anexo I. Descripción de la plataforma móvil de recolección

Esta máquina consta, en su parte frontal, de un tapiz plegable de 6 m de largo con tres brazos giratorios a cada lateral, adaptables manualmente a las características del marco de plantación (Figura I.1). Todos los brazos tienen unas cintas de transporte sobre las que los recolectores depositan la fruta y las llevan hasta el tapiz central de elevación que, a su vez, desemboca en una rampa unificadora.



Figura I.1. Plataforma móvil de recolección con el sistema de visión instalado en la parte superior

En esta rampa se procede a la individualización de la fruta para depositarla, ya en la parte superior de la máquina, en una zona de rodillos de color negro formando dos carriles. Al comienzo de la zona de rodillos se encuentran unos separadores motorizados que evitan tanto que la fruta se deposite en el centro de ambos carriles, como que se sitúen dos frutas en el mismo rodillo. En esta zona de aproximadamente un metro de longitud es donde se debe ubicar el sistema de visión. Allí, la fruta entra procedente de la rampa elevadora y cada unidad se debe posicionar exactamente entre dos rodillos. Cualquier anomalía en esta fase confunde al sistema y puede afectar al resultado del análisis por lo que se ha prestado especial atención a la forma de los rodillos y a la manera en la que la fruta se individualiza y ubica en los mismos.

Los rodillos sobre los que se ubica cada fruta se desplazan a lo largo de la zona de inspección mientras rotan sobre su eje, haciendo que la fruta gire sobre sí misma, lo que permite exponer una gran parte de superficie de la fruta a la cámara mientras se capturan diferentes imágenes. El sistema de visión se ha tenido que ubicar en esta

zona con los requisitos de, entre otros, ocupar el menor espacio y ser lo más ligero y bajo posible, como se detallará posteriormente. A ambos lados de esta zona de rodillos se encuentran unos soportes planos que servirán para sujetar la campana de inspección.

Una vez que la fruta se inspecciona, se deposita en unas cazoletas sincronizadas con los rodillos y que, en su camino hacia una de las tres posibles salidas atendiendo a su clasificación, permite realizar un pesaje electrónico de la fruta mediante células de carga. Esta parte de pesaje de la fruta ha sido realizada por el Laboratorio de Sensores y Calidad del Centro de Agroingeniería y queda fuera del ámbito de investigación de esta tesis. La información obtenida de los sistemas de visión y pesaje se combina para decidir a cuál de las tres salidas se envía la fruta. Estas salidas van a parar a los palots, cada uno de los cuales se va llenando con fruta de categoría diferente. Para que la fruta no se dañe, existen unos brazos extensibles que la depositan en el palot desde poca altura, regulándose la misma a medida que se llena el palot. Además, la máquina cuenta con un remolque que permite alimentar de palots vacíos la máquina mientras que extrae de la misma los que están llenos para dejarlos en el campo. Mientras se realiza el cambio de palots, la máquina puede seguir clasificando gracias a los compartimentos de las salidas que permiten almacenar de forma temporal cierta cantidad de fruta.

La máquina tiene una longitud de 7300 mm (con el tapiz y los brazos plegados y sin contar el remolque de alimentación de palots), una altura de 3200 mm y una anchura de 1950 mm, como se observa en la Figura I.2.




Figura I.2. Dimensiones de la máquina

El control de los sistemas electrónicos y de visión se realiza mediante un autómata programable (PLC) modelo Siemens Simatic 224XP que controla el movimiento de avance de la fruta mediante un codificador óptico de pulsos acoplado al eje de transporte de los rodillos. Este PLC debe enviar las señales de disparo de la cámara para adquirir las imágenes y de pesaje a las células de carga, recoger la información obtenida por estos sistemas y combinarla con los parámetros de usuario para tomar la

decisión sobre la calidad de la fruta para activar la salida correspondiente a su categoría. Esta parte se ha desarrollado en el Laboratorio de Sensores y Calidad del Centro de Agroingeniería.

Todos los procesos de la máquina, sensores y actuadores, son gestionados directamente por el PLC que, además, recibe señales procedentes de múltiples sensores que detectan posibles acumulaciones de fruta para actuar sobre los motores de transporte de la fruta, modificando sus velocidades e incluso deteniéndolos, detecta cuando los palots se están llenando para ir bajándolos poco a poco y sobre todo coordina las labores de inspección por visión y pesaje electrónico para, dependiendo de la información recibida por ellos, actuar sobre los pistones que sirven de selectores para que la fruta se desvíe por una salida u otra. En la Figura I.3 se muestra el cuadro de control que contiene, entre otros elementos, el autómeta y el módulo de pesaje desarrollado. Las labores que realiza el autómeta son las siguientes:

- Sincroniza los procesos de inspección y pesaje (adquisición de datos, almacenamiento y clasificación final) a través de la gestión de la señal enviada por el codificador de pulsos.
- Envía las señales de disparo a la cámara de inspección y de comienzo de pesado al módulo de pesaje.
- Recibe las tramas con los mensajes que contienen el resultado del análisis de las frutas.
- Gestiona el proceso de clasificación con el fin de actuar sobre los pistones neumáticos correspondientes una vez asignada la categoría basándose en color, presencia o ausencia de manchas y peso de cada fruta.
- Supervisa los sistemas de inspección y pesaje con el fin de avisar al usuario de cualquier anomalía detectada utilizando balizas luminosas.

El control operativo se efectúa mediante un interfaz amigable a través de una pantalla táctil con el fin de que el usuario pueda gestionar y configurar el funcionamiento de la máquina, permitiendo ajustar los parámetros de configuración y establecer las categorías de selección. Además permite visualizar en tiempo real el estado de la inspección y el pesaje, así como supervisar los mensajes de aviso o alarmas que puedan ocurrir. También es posible obtener informes de todo el proceso.

Además es posible variar la velocidad a la que se procesará la fruta modificando la velocidad de las cintas transportadoras y los rodillos. En uno de los menús del interfaz, el usuario puede elegir entre tres velocidades de funcionamiento que permiten adaptar la inspección y pesaje a la cantidad de fruta recolectada. Las velocidades establecidas fueron de 4, 6 y 8 frutas por segundo, siendo esta última la velocidad estimada que permite procesar toda la fruta que llega a la máquina durante una recolección manual típica.




Figura I.3. Cuadro de control


Anexo II. Técnicas de iluminación

Este anexo describe las técnicas para iluminar la escena más comúnmente utilizadas en visión por computador. Para esta tesis se han empleado la iluminación lateral difusa, la iluminación frontal y la iluminación por contraste o retroiluminación.


- **Iluminación direccional:** es una de las más comunes y consiste en colocar la cámara mirando al objeto e iluminándolo en la misma dirección, con un bajo ángulo de incidencia. De este modo la cámara recibe la mayor parte de la luz reflejada por el objeto. Su principal inconveniente es la generación de sombras en objetos poco planos y deslumbramientos que llegan directamente a la cámara en objetos brillantes.




- **Iluminación lateral:** se sitúa la cámara mirando al objeto y se ilumina lateralmente con un gran ángulo de incidencia. Se emplea para resaltar detalles laterales de los objetos o para resaltar aspectos de su superficie. Su gran inconveniente es la generación de grandes sombras.




- **Iluminación difusa:** es probablemente una de las más difíciles de implementar pero con la que mejores resultados se obtienen. Consiste en colocar la cámara mirando al objeto e iluminándolo desde todas las direcciones para lograr uniformidad en la luz. Suelen utilizarse también pantallas difusoras de luz para lograr el mismo efecto con menor número de fuentes de luz. La cámara recibe la mayor parte de la luz reflejada por el objeto pero apenas recibe reflejos. Sirve para prácticamente todo tipo de objetos tanto brillantes como no, aunque es difícil de montar sobre todo en espacios reducidos.




- **Iluminación coaxial:** es similar a la luz direccional o frontal, aunque con la diferencia que la luz se sitúa de forma difusa y uniforme en la misma dirección que la cámara, ya sea formando anillos alrededor de la óptica, o utilizando divisores de haz para reflejar la luz hacia el objeto con un espejo situado entre la cámara y el objeto. Sirve para prácticamente todo tipo de objetos, brillantes o mates, con excelentes resultados, aunque su montaje es complejo y presenta un excesivo coste.




- **Iluminación por campo oscuro o *darkfield*:** Se utiliza para inspeccionar objetos transparentes o traslúcidos. La cámara se sitúa sobre el objeto y la luz se recibe en dirección perpendicular, ya que se sitúa la fuente de luz a la altura del objeto, dispuesta alrededor de él y con la luz completamente dirigida al mismo. El fondo de la escena deberá ser oscuro, aunque también se puede utilizar un sistema de iluminación posterior sobre fondo traslúcido. Se emplea sobre todo para detectar los contornos de los objetos y así identificar sus formas y posibles defectos. Su ámbito de uso es muy limitado a ciertas aplicaciones.



- **Iluminación por contraste o retroiluminación:** Se utiliza principalmente para inspeccionar objetos opacos o traslúcidos. La cámara se sitúa sobre el objeto y la luz se dispone justo a la otra parte del objeto. El fondo de la escena deberá ser traslúcido para que atraviese la luz. Se emplea sobre todo para medición dimensional y detección de formas y defectos en el contorno. Su ámbito de uso es, como en el caso anterior, limitado a ciertas aplicaciones, ya que no es posible detectar el color ni recoger información de la superficie del objeto.



- **Iluminación estructurada** o láser: Como ya se ha comentado anteriormente, se utiliza principalmente para obtener detalles sobre la topología de las superficies. Tanto la cámara como la luz se disponen en ángulos conocidos, de forma que la cámara sea capaz de captar en todo momento las variaciones de la luz al reflejarse en la superficie del objeto.



Anexo III. Software de entrenamiento

Para poder entrenar el sistema, o lo que es lo mismo, crear el mapa de color que se utilizará para segmentar las imágenes, partiremos de una o varias imágenes de muestra. Sobre cada una de estas imágenes de prueba se van acotando zonas con colores similares y se asocian a una clase determinada. Una vez se han acotado todas las clases que se necesitan, ya se puede crear el mapa de color.

El programa crea un fichero que contiene la LUT en formato binario, utilizado por los programas de análisis en línea, y otro que contiene la LUT en formato de texto, simplemente informativo, ideal para una fácil comprensión de su contenido.

Para comprender mejor este fichero, podemos pensar en una tabla con cuatro columnas (Rojo, Verde, Azul y Clase) y una fila para cada combinación de color RGB de la imagen (o una reducción del número de colores). Además se guarda en ambos ficheros información adicional de cada clase como su nombre y el color asociado para su representación.

La pantalla principal del programa está dividida en cinco partes (Figura III.1):

- Ventana de entrenamiento, donde se visualiza la imagen de muestra, y sobre la que se realizará la selección de píxeles.
- Ventana imagen original, donde se visualiza en todo momento la imagen de muestra original.
- Ventana imagen resultado del entrenamiento, donde se visualiza el resultado del entrenamiento completo, el de un solo paso, o el de una clase completa.
- Ventana de visualización de pasos de entrenamiento, donde se muestran los pasos de entrenamiento y la clase correspondiente a cada paso.
- Botoneras para cargar/guardar las imágenes, LUT, las clases, modificación del nombre y color de clase, borrado de pasos y clases, ...

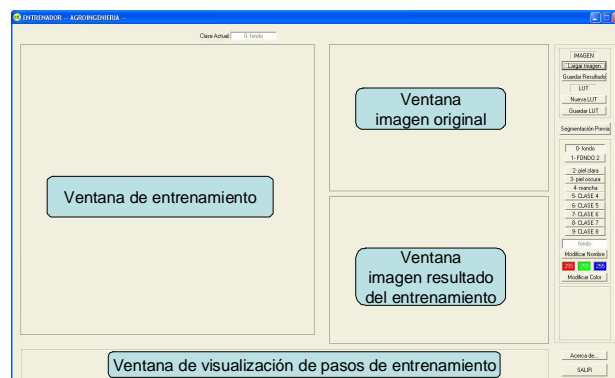


Figura III.1. Pantalla principal del programa

El primer paso a realizar es cargar una imagen válida (JPG, BMP o TIF), que será mostrada en la ventana de entrenamiento y en la ventana de imagen original. Las imágenes que normalmente se utilizan tienen una profundidad de color de 24 bits (3 x 8 bits) que corresponden a más de 16 millones de colores (256 x 256 x 256). Dicha resolución hace que la LUT sea muy grande, ocupe mucho espacio en memoria y aumenten los tiempos de acceso a la misma, con lo cual el tiempo de computación se ve aumentado en el análisis de cada imagen. En ciertos casos es conveniente reducir esa profundidad de color para disminuir el tamaño de la tabla. En este caso, cada vez que creamos una selección de colores (paso de entrenamiento), realizamos una conversión interna con tal de reducir la profundidad de color.

Posteriormente elegiremos la clase a la que pertenecerá la siguiente selección que haremos (inicialmente está seleccionada la clase 0 que corresponde al fondo). Esto se hace pulsando sobre la botonera de la parte derecha del programa donde se encuentran las 10 clases permitidas (las dos primeras de fondo y las siguientes para objetos). El nombre y color asociado de la clase seleccionada, aparecerá en una pequeña ventana en la parte superior de la ventana de entrenamiento.

Para realizar un paso de entrenamiento crearemos una ventana de selección pulsando con el botón izquierdo del ratón y arrastrando sin soltar el botón hasta que completemos la ventana de selección. Una vez completada la selección, soltaremos el botón. En ese momento se creará un paso de entrenamiento que se visualizará en la parte inferior, mostrando el color promedio de la ventana seleccionada y el color de la clase a la que pertenece dicha selección. Cada paso creado además se enumerará por P_x y la clase a la que pertenece por C_x . Realizando estos pasos sucesivamente se creará el entrenamiento completo. Es posible realizar hasta un máximo de 255 pasos de entrenamiento.

En la Figura III.2 se puede observar el entrenamiento de una imagen.

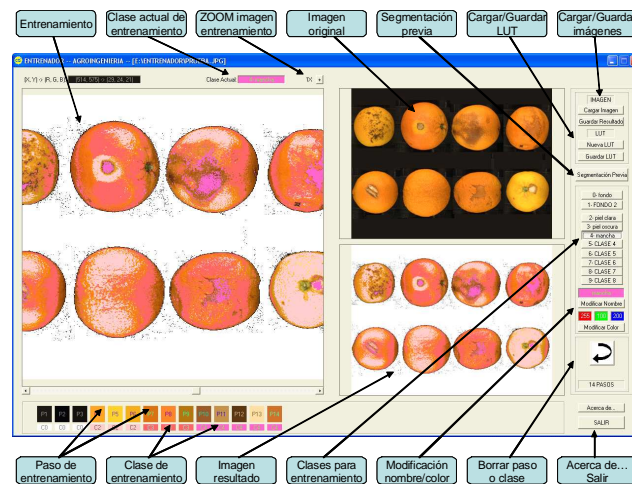


Figura III.2. Ejemplo de entrenamiento

En esta captura se pueden identificar todas las partes del programa ya comentadas y otras que lo serán posteriormente. Haciendo doble clic sobre un paso de entrenamiento se muestra en la ventana de la imagen resultado únicamente el paso seleccionado. Igualmente haciendo doble clic sobre una clase se muestran en la ventana de la imagen resultado todos los pasos seleccionados que corresponden a dicha clase (Figura III.3). En la parte superior de la ventana de entrenamiento también aparece la información del paso o clase seleccionada. Un doble clic en dicha ventana vuelve a mostrar el resultado del entrenamiento completo.

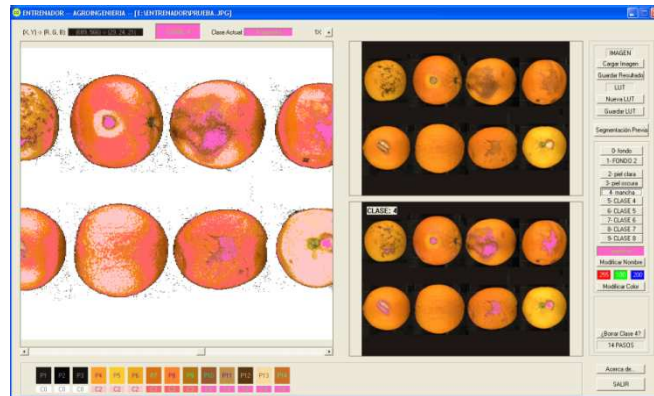


Figura III.3. Vista previa de la clase 4 (mancha)

Cuando se muestra un paso o clase, se permite además eliminar ese paso o todos los asociados a la clase seleccionada de la lista de pasos de entrenamiento. Las opciones aparecen en la parte derecha, como se observa en la Figura III.3 donde aparece la posibilidad de borrar los pasos asociados a la clase 4. Para una óptima realización de la selección, es posible aumentar el tamaño de la imagen de entrenamiento pulsando sobre los botones de zoom en la parte superior de la imagen.

Cada una de las clases tiene asociados un número fijo, así como un nombre y color que pueden ser modificados. Al seleccionar una de las clases aparece el nombre y color en unas pequeñas ventanas. Es posible modificar dichos valores simplemente cambiándolos y pulsando el botón modificar. Estos valores se guardarán como nuevos valores por defecto para la próxima vez que se utilice el programa.

Todos los valores RGB del entrenamiento, el paso en el que han sido creados, y su clase asociada, son almacenados en una lista que se utilizará tanto para comprobar que valores ya han sido clasificados para su visualización, como para tener un control de los pasos de entrenamiento creados, con el fin de poder eliminar en cualquier momento un paso de entrenamiento erróneo.

Una vez ha sido creado correctamente el entrenamiento, ya se está en disposición de generar y guardar la LUT. Para conseguirlo se ordena la lista creada en el entrenamiento y se pasa como entrada a un clasificador bayesiano, que como se comentó anteriormente, consiste en un clasificador probabilístico basado en la

aplicación de la regla de decisión de Bayes (Kopparapu y Desai, 2001). Dicho clasificador crea la LUT completa con todas las combinaciones RGB posibles y asocia cada una de ellas a una de las clases presentes en el entrenamiento. Esta LUT podrá ser utilizada para el análisis de imágenes que contengan las mismas clases de objetos que las utilizadas en el entrenamiento y adquiridas en las mismas condiciones.

Para comprobar si el entrenamiento que hemos realizado y la LUT generada nos satisfacen, podemos visualizar los resultados en una nueva ventana pulsando el botón Segmentación Previa. Dicha segmentación previa consta de los siguientes pasos:

- Segmentación de la imagen utilizando la LUT previamente generada. Esta segmentación consiste en etiquetar cada píxel de la imagen con su clase en la LUT. Para poder visualizar el resultado de la segmentación se crea una nueva imagen en la que cada clase se representa con un color diferente.
- Filtrado de la imagen utilizando un filtro de moda. Este filtro suaviza la imagen y elimina píxeles aislados. Su funcionamiento consiste en que cada píxel se etiqueta atendiendo a cuál es el más repetido entre sus 8-vecinos.
- Búsqueda de objetos en la imagen partiendo de los contornos encontrados. Se recorre la imagen hasta que se encuentra un píxel de alguna clase. Cuando aparece uno, se comprueba si el siguiente también pertenece a la misma clase. Si es así se continúa el proceso y en caso contrario se cambia la dirección de búsqueda. Existen 8 direcciones de búsqueda que corresponden a los 8-vecinos de cada píxel y siguen el sentido de las agujas del reloj empezando por el píxel de la derecha.
- Extracción de características de los objetos encontrados. Siguiendo los contornos de los objetos ya creados es posible extraer ciertos datos morfológicos que serán de interés, como son el centro, área, perímetro, longitud, anchura, ...

El resultado de estos pasos puede ser visualizado pulsando con el botón derecho del ratón sobre la ventana inferior y seleccionando cualquier combinación de entre las siguientes y eligiendo si se desea aplicar o no el filtrado de las imágenes.

- Muestra los contornos de los objetos encontrados en la imagen después de la segmentación y el filtrado (Figura III.1)
- Muestra los contornos de los objetos encontrados en la imagen sobre el resultado de la segmentación y el filtrado (Figura III.1)
- Muestra la imagen original y los contornos de los objetos encontrados en la imagen después de la segmentación y el filtrado (Figura III.1)

El número de objetos encontrados, así como ciertas características asociadas a cada uno de ellos, se pueden comprobar en un fichero de texto, donde se muestra, para cada objeto, las coordenadas X e Y del centro, la clase a la que pertenece, el área, perímetro, longitud y anchura y nos sirve para comprobar si el entrenamiento es válido y se puede aplicar a todas las imágenes.

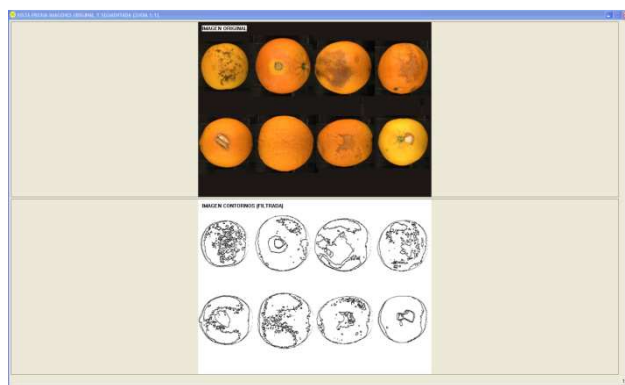


Figura III.4. Muestra de los contornos encontrados

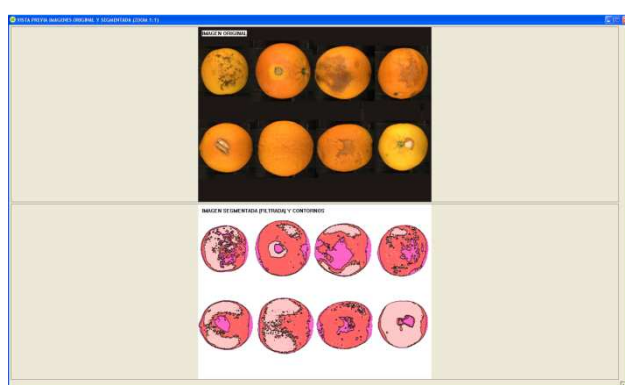


Figura III.5. Muestra de los contornos encontrados sobre la imagen segmentada

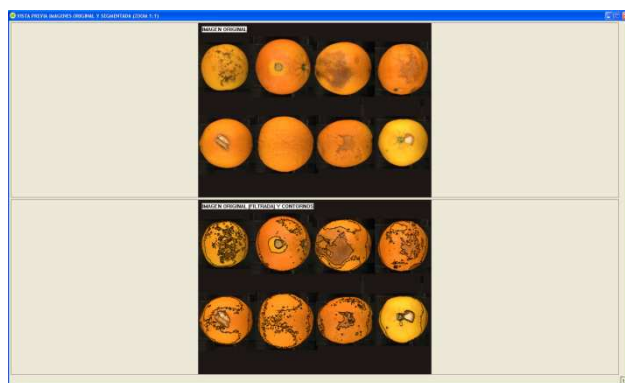


Figura III.6. Muestra de los contornos encontrados sobre la imagen original

Anexo IV. Software de inspección de cítricos

El software de inspección de cítricos consta de una única pantalla (Figura IV.1) donde aparece toda la información y los parámetros necesarios para ajustar la aplicación.

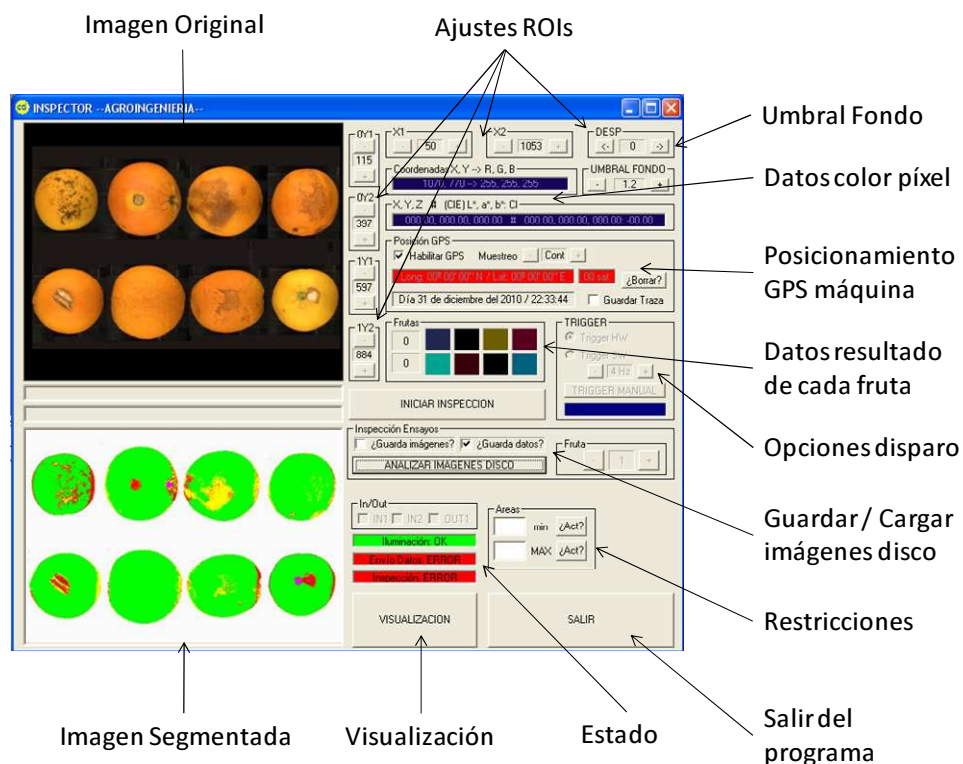


Figura IV.1. Pantalla principal de inspección de cítricos

Las áreas en las que se agrupa el programa son estas:

- **Imagen Original:** En funcionamiento en línea muestra la última imagen que adquiere la cámara mientras que en modo fuera de línea muestra la imagen cargada de disco.
- **Imagen Segmentada:** Muestra el resultado de la segmentación de la imagen actual.
- **Ajustes ROI:** Permite ajustar las 2 ROI de la imagen, una para cada carril. Se puede ajustar tanto su tamaño como su posición. Las zonas de la imagen que quedan fuera de ambas ROI se visualizan en negro y no son analizadas.

- **Umbral Fondo:** Permite seleccionar el valor del umbral que sirve para segmentar entre píxeles de fruta y de fondo. Los píxeles por debajo de este valor son píxeles de fondo mientras que los que se encuentran por encima corresponden a fruta.
- **Datos color píxel:** Muestra la coordenada X, Y del cursor, así como sus valores de color en los espacios RGB, XYZ, Hunter Lab y el valor ICC.
- **Posicionamiento máquina:** Con estas opciones se habilita el uso de un GPS que sincroniza la inspección de la fruta con la posición GPS de la máquina en el momento de la recolección. Este apartado no se ha incluido en la tesis por no haberse probado convenientemente en campo.
- **Datos resultado de cada fruta:** Muestra el valor del ICC de la fruta que se encuentra en la posición indicada y el número de frutas que se han procesado en cada carril.
- **Opciones disparo:** En este apartado se puede seleccionar el modo de disparo de la cámara y puede ser tanto automático como manual. El modo automático corresponde al funcionamiento normal en el que el PLC envía una señal para el disparo de la cámara sincronizado con el movimiento de la fruta mientras que el modo manual sirve para simular dichos disparos sin la necesidad de poner la máquina en movimiento. Además se puede seleccionar la frecuencia de adquisición de imágenes o incluso realizar una toma al pulsar un botón.
- **Guardar / Cargar imágenes disco:** Habilitando esta opción el programa puede almacenar en disco todas las imágenes mientras son adquiridas para un procesamiento posterior y/o almacenar los resultados completos del análisis. Además permite cargar imágenes previamente almacenadas para analizarlas fuera de línea y de este modo probar los algoritmos de análisis desarrollados.
- **Restricciones:** En este apartado se puede introducir un área máxima y mínima de objetos. De este modo si apareciera un objeto menor o mayor a los valores establecidos se descartaría dicho objeto.
- **Visualización:** Con esta opción se puede activar o desactivar la visualización en tiempo real tanto las imágenes adquiridas como de los resultados del análisis. Durante el funcionamiento normal de la aplicación en la máquina, este programa no se visualiza en ninguna pantalla por lo que no es necesario actualizar la información en pantalla. Sin embargo, para ajustar los parámetros internos del programa es necesario visualizar en una pantalla lo que realmente se está inspeccionando, como por ejemplo para ajustar las ROI, seleccionar el umbral de la segmentación o simplemente para realizar ensayos donde se desean guardar las imágenes de la fruta inspeccionada o cargar imágenes de disco para analizarlas.

- **Estado:** Muestra el estado del sistema respecto de la iluminación, inspección o comunicación con el PLC. En caso de que se produzca algún error, se lo comunica al PLC para que tome las acciones oportunas como paralizar la inspección, reiniciar el sistema y/o dar información al operario para que actúe sobre la pantalla táctil que gobierna la máquina. Si el PLC no recibe ningún mensaje durante un tiempo determinado también considerará que no hay comunicación y realizará las acciones predeterminadas al igual que en el caso anterior.
- **Salir del programa:** Permite abandonar la aplicación en modo manual ya que con el funcionamiento en línea es el PLC el que da orden de finalización de la misma.

Anexo V. Fórmulas de conversión de color

En este anexo se describen las formulas empleadas para convertir el valor RGB de los píxeles de las imágenes al espacio de color Hunter Lab. Esta conversión no se puede hacer de forma directa y es necesario realizarla en dos fases. La primera fase consiste en la conversión de RGB a XYZ (Poynton, 1996) y la segunda de XYZ a Hunter Lab (Hutchings, 1999).

Como primer paso hay que normalizar los valores RGB a rgb (valores entre 0 y 1) utilizando las Ecuaciones V.1, V.2 y V.3 para cada valor R, G y B respectivamente.

$$\begin{aligned} \text{Si } \frac{R}{255} > 0,04045 & \quad r = \left(\frac{R + 0,055}{1,055} \right)^{2,4} \\ \text{Si } \frac{R}{255} \leq 0,04045 & \quad r = \frac{R}{12,92} \end{aligned} \quad (\text{V.1})$$

$$\begin{aligned} \text{Si } \frac{G}{255} > 0,04045 & \quad g = \left(\frac{G + 0,055}{1,055} \right)^{2,4} \\ \text{Si } \frac{G}{255} \leq 0,04045 & \quad g = \frac{G}{12,92} \end{aligned} \quad (\text{V.2})$$

$$\begin{aligned} \text{Si } \frac{B}{255} > 0,04045 & \quad b = \left(\frac{B + 0,055}{1,055} \right)^{2,4} \\ \text{Si } \frac{B}{255} \leq 0,04045 & \quad b = \frac{B}{12,92} \end{aligned} \quad (\text{V.3})$$

Posteriormente se convierten los valores rgb a XYZ utilizando la matriz M para un iluminante-observador D65-10° según aparece en la Ecuación V.4. Se ha utilizado el iluminante-observador D65-10° por considerarse el estándar recomendado por la CIE y que más se adapta a la iluminación que se ha empleado.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = 100 \times [M] \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad (\text{V.4})$$

Donde:

$$[M] = \begin{bmatrix} 0,4116694 & 0,3567891 & 0,1796505 \\ 0,2126729 & 0,7151522 & 0,0721750 \\ 0,0140739 & 0,1139320 & 0,9450441 \end{bmatrix} \quad (V.5)$$

Así pues, desarrollando la Ecuación V.4 utilizando la Matriz V.5, nos quedan los valores X, Y y Z (Ecuación V.6).

$$\begin{aligned} X &= 100 \times r \times 0,4116694 + 100 \times g \times 0,3567891 + 100 \times b \times 0,1796505 \\ Y &= 100 \times r \times 0,2126729 + 100 \times g \times 0,7151522 + 100 \times b \times 0,0721750 \\ Z &= 100 \times r \times 0,0140739 + 100 \times g \times 0,1139320 + 100 \times b \times 0,9450441 \end{aligned} \quad (V.6)$$

Posteriormente ya podemos obtener los valores Hunter Lab, siguiendo la Ecuación V.7 para calcular la luminosidad L , la Ecuación V.8 para el valor de a y la Ecuación V.9 para el valor de b .

$$L = 100 \sqrt{\frac{Y}{Y_n}} \quad (V.7)$$

$$a = K_a \left[\frac{\left(\frac{X}{X_n}\right) - \left(\frac{Y}{Y_n}\right)}{\sqrt{\frac{Y}{Y_n}}} \right] \quad (V.8)$$

$$b = K_b \left[\frac{\left(\frac{Y}{Y_n}\right) - \left(\frac{Z}{Z_n}\right)}{\sqrt{\frac{Y}{Y_n}}} \right] \quad (V.9)$$

Donde X_n , Y_n y Z_n son los valores tri-estímulo de un objeto blanco específico utilizando en este caso el iluminante D65 (luz día) y el observador 10° (CIE 1964) con los valores mostrados en las Ecuaciones V.10.

$$X_n = 94,811; \quad Y_n = 100; \quad Z_n = 107,304 \quad (V.10)$$

Y K_a y K_b son los coeficientes que dependen también de la fuente de iluminación utilizada, según se muestra en las Ecuaciones aproximadas V.11 y V.12.

$$K_{a\approx} \frac{175}{198,04} (X_n + Y_n) \quad (\text{V.11})$$

$$K_{b\approx} \frac{70}{218,11} (Y_n + Z_n) \quad (\text{V.12})$$

Anexo VI. Software de inspección de arilos de granada

En la pantalla principal del programa (Figura VI.1) se permite seleccionar la variedad de granada que se va a inspeccionar.

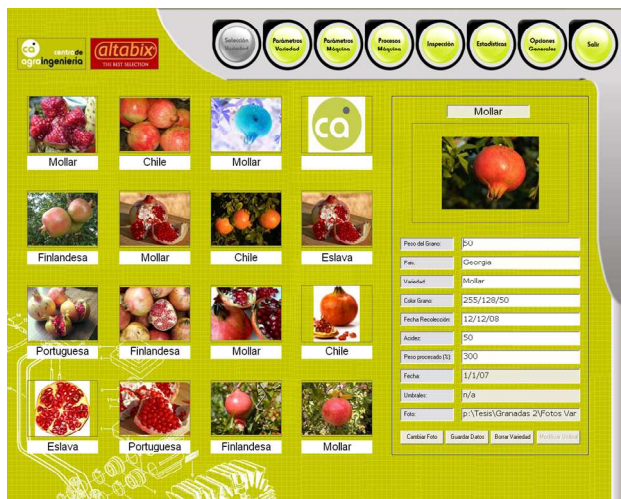


Figura VI.1. Selección de variedad de granada

Es posible crear hasta 16 perfiles con sus datos y parámetros individualizados, ya que los granos de cada variedad tienen diferentes tonos y de este modo se pueden guardar los umbrales más apropiados para su análisis.

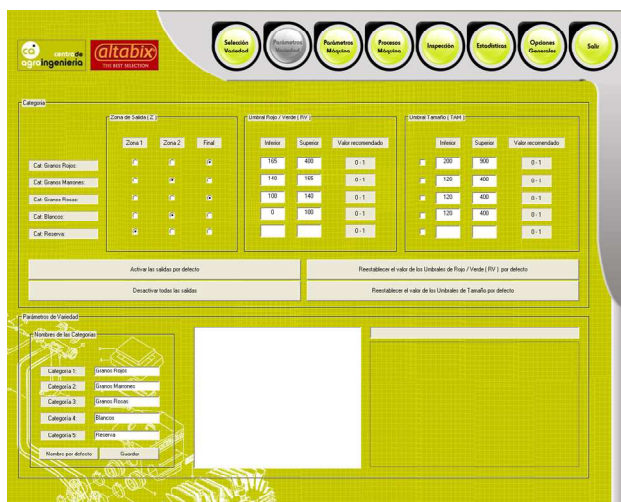


Figura VI.2. Configuración variedades de granada

En la Figura VI.2 se muestran las opciones de configuración de cada variedad. Se puede seleccionar a que salida se derivará cada tipo de producto y que umbrales clasifican los píxeles de la imagen en cada categoría, así como el nombre de cada una de ellas. Además se puede seleccionar también la opción de clasificación por tamaño, permitiendo ajustar sus valores mínimo y máximo para descartar el producto que se encuentre fuera de sus límites.

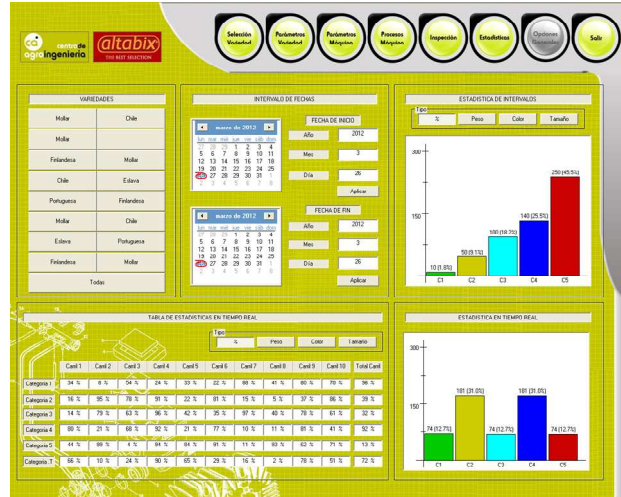


Figura VI.3. Estadísticas

En la parte superior de la Figura VI.3 se muestran las estadísticas parciales de producto inspeccionado por el prototipo con anterioridad. Se pueden seleccionar tanto la variedad como el rango de fechas de los datos a filtrar y se muestran los datos obtenidos de cada categoría.

En la parte inferior de la Figura VI.3 se muestran los datos de la inspección en línea, separando la información tanto por carriles como por categorías. La información de los carriles resulta importante para comprobar si el alimentador reparte bien el producto entre todas las cintas transportadoras. A la derecha se muestra una gráfica con la cantidad de producto de cada categoría y su porcentaje respecto del total que se ha clasificado.

Anexo VII. Software de inspección de gajos de satsuma

La aplicación consta de una pantalla principal donde se visualizan las imágenes (Figura VII.1) y otras dos ventanas auxiliares que corresponden a la configuración y estadísticas.

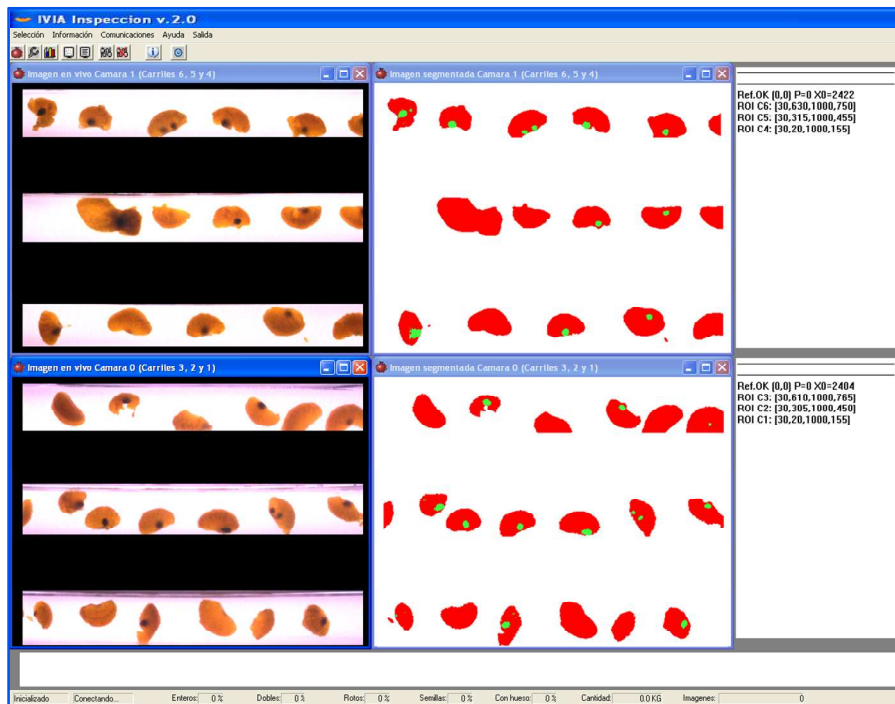


Figura VII.1. Pantalla principal de inspección de gajos de satsuma

La pantalla principal muestra las imágenes adquiridas donde se observan las 6 cintas transportadoras con los objetos sobre ellas. A su lado se muestra el resultado de la segmentación de cada una de las ROI que corresponden con las seis cintas. A la derecha se muestra información sobre el análisis de los objetos encontrados.

En la parte inferior se muestra información del estado de la aplicación y su comunicación con la aplicación que actúa sobre la máquina en el equipo de control. Además se muestran las estadísticas sobre los objetos clasificados en cada una de las categorías.

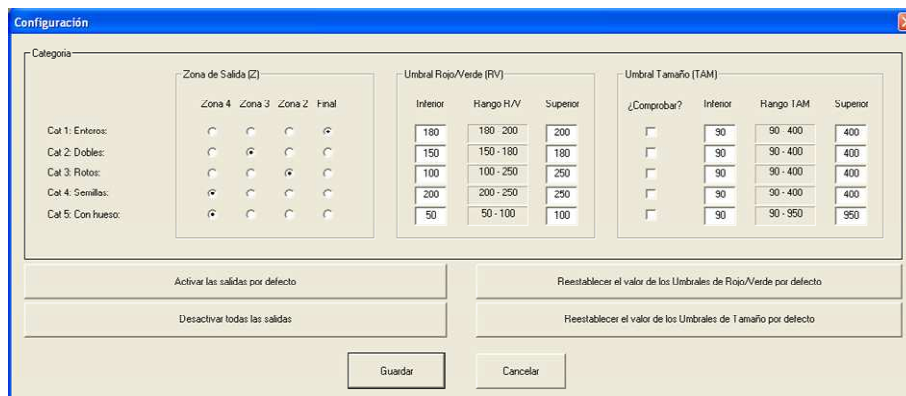


Figura VII.2. Parámetros de selección

En la Figura VII.2 se muestran las opciones de usuario para configurar el sistema. En ellas se puede seleccionar a que salida se derivará el producto clasificado en cada categoría, e incluso de forma provisional dejar pasar todo el producto sin clasificar. Otra opción muy importante es la selección de los umbrales sobre los que se realizará la clasificación para cada categoría. Es posible combinar la información de color con información sobre el tamaño de los objetos. Para ello se permite habilitar esta opción y ajustar sus valores mínimo y máximo.

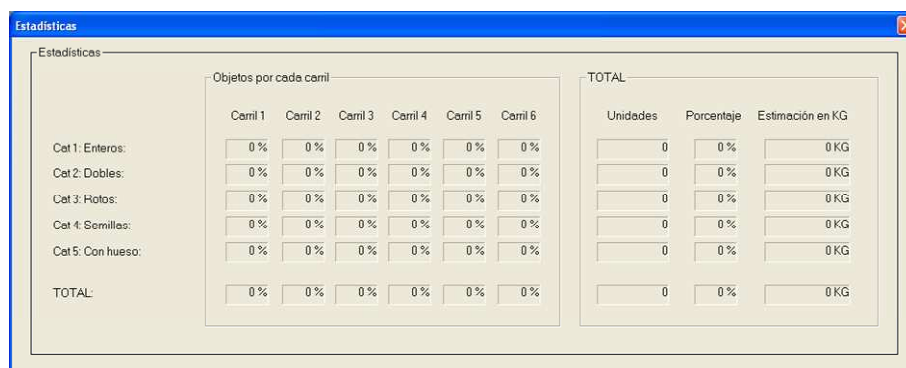


Figura VII.3. Estadísticas

En la Figura VII.3 se muestran las estadísticas sobre los productos inspeccionados. Esta información se muestra separada tanto por producto como por carriles para comprobar si el alimentador de producto funciona de manera uniforme sobre todas las cintas.

La información aquí mostrada puede resultar importante para que se puedan ajustar los umbrales y conseguir mayor o menor cantidad de producto de una determinada categoría según intereses comerciales.