

**IMPLEMENTACIÓN DE UN SISTEMA DE VISIÓN ARTIFICIAL PARA LA
CLASIFICACIÓN Y EL CONTROL DE CALIDAD DE FRUTAS**



EDGAR LEONAIRO PENCUE FIERRO

**UNIVERSIDAD DEL CAUCA
FACULTAD DE CIENCIAS NATURALES, EXACTAS Y DE LA EDUCACIÓN
DEPARTAMENTO DE FÍSICA
PROGRAMA DE INGENIERÍA FÍSICA
POPAYÁN
2003**

**IMPLEMENTACIÓN DE UN SISTEMA DE VISIÓN ARTIFICIAL PARA LA
CLASIFICACIÓN Y CONTROL DE CALIDAD DE FRUTAS**

EDGAR LEONAIRO PENCUE FIERRO

Trabajo de Grado presentado como requisito parcial para optar al título
de Ingeniero Físico

Director:
MSc. Jauri León-Téllez

**UNIVERSIDAD DEL CAUCA
FACULTAD DE CIENCIAS NATURALES, EXACTAS Y DE LA EDUCACIÓN
DEPARTAMENTO DE FÍSICA
PROGRAMA DE INGENIERÍA FÍSICA
POPAYÁN
2003**

AGRADECIMIENTOS

El autor manifiesta sus más sinceros agradecimientos a:

- El Grupo de Óptica y Láser – GOL – por el gran apoyo que me brindó durante el desarrollo de este trabajo. Principalmente al profesor Jauri León-Téllez porque creyó en mis ideas y confió en mis capacidades. A los profesores Francisco Racedo, Álvaro Bastidas y Edith Rodríguez con quienes en la crítica constructiva especificamos mejor la idea para el desarrollo del proyecto.
- El Departamento de Física por ofrecerme la oportunidad de formarme como ingeniero y como físico, y por permitirme conocer y explorar la grandeza del conocimiento humano.
- La Vicerrectoría de Investigaciones de la Universidad del Cauca por ofrecer el apoyo para el desarrollo del proyecto marco dentro del que se desarrolla este trabajo.
- El Instituto Valenciano de Investigaciones Agrarias – IVIA – de la Universidad de Valencia, en España, principalmente al Dr. Enrique Moltó por apoyarme con la información sobre sus investigaciones en el tema.
- Dr. Arturo Plata, de la Universidad Industrial de Santander por la asesoría y el apoyo brindados.
- El Servicio Nacional de Aprendizaje – SENA – por las aclaraciones brindadas con respecto al procesamiento de la fruta.
- El Centro Regional de Productividad e Innovación del Cauca – CREPIC – y al Comité Asesor Regional para el Comercio Exterior – CARCE – por ofrecer opciones para que el proyecto continúe creciendo.
- Las directivas de la Corporación Universitaria Autónoma de Occidente, en Cali, por invitarme a participar como ponente en el “Seminario Internacional sobre Avances y Tendencias en Electrónica”, en el que se establecieron verdaderos lazos para futuros trabajos conjuntos sobre la materia.
- La Universidad del Cauca por permitirme un espacio para formarme científica, tecnológica y humanamente.

TABLA DE CONTENIDO

<u>1. INTRODUCCIÓN</u>	<u>10</u>
1.1. LA CALIDAD DE LAS FRUTAS	14
1.1.1. <i>Parámetros para determinar la calidad superficial de las frutas.....</i>	<i>16</i>
1.2. INSPECCIÓN VISUAL AUTOMATIZADA: ¿PORQUÉ Y PARA QUÉ?.....	17
1.3. VISIÓN ARTIFICIAL PARA LA INSPECCIÓN DE FRUTAS	19
<u>2. INSPECCIÓN VISUAL AUTOMATIZADA DE FRUTAS.....</u>	<u>22</u>
2.1. INSPECCIÓN VISUAL AUTOMATIZADA	22
2.1.1. <i>Componentes de un sistema de inspección visual automático.....</i>	<i>24</i>
2.1.2. <i>Adquisición de la imagen.....</i>	<i>26</i>
2.1.3. <i>Procesamiento y análisis de la imagen.....</i>	<i>28</i>
2.1.4. <i>Descripción general del sistema de visión artificial.....</i>	<i>29</i>
2.2. EL COLOR EN LA INSPECCIÓN INDUSTRIAL.....	33
2.2.1. <i>Revisión sobre el cálculo de las características de color.....</i>	<i>35</i>
2.2.2. <i>Constancia del color</i>	<i>36</i>
2.3. INSPECCIÓN SUPERFICIAL DE FRUTAS	38
2.3.1. <i>La calidad de las frutas y su importancia a nivel nacional.....</i>	<i>39</i>
2.3.2. <i>Evaluación de la calidad de las frutas.....</i>	<i>41</i>
2.3.3. <i>Reglas para la evaluación de la calidad en frutas.....</i>	<i>43</i>
2.3.4. <i>Propiedades de las frutas.....</i>	<i>45</i>
2.4. EL DESARROLLO DE LOS SISTEMAS DE INSPECCIÓN AUTOMATIZADA DE FRUTAS.....	50
2.4.2. <i>Aproximaciones basadas en sensores especiales.....</i>	<i>56</i>
2.5. USO DEL COLOR EN LA INSPECCIÓN DE FRUTAS	56

3. DESARROLLO Y DESEMPEÑO DEL MÉTODO..... 59

3.1. AMBIENTE PARA EL DESARROLLO DEL MÉTODO DE INSPECCIÓN	60
3.1.1. <i>Conocimiento de la aplicación</i>	62
3.1.2. <i>Material de imágenes de prueba</i>	63
3.2. HERRAMIENTAS DE DESARROLLO.....	64
3.2.1. <i>El ambiente de procesamiento y análisis de imágenes QWin/QUIPS</i>	64
3.2.2. <i>Otras librerías</i>	69
3.3. DESEMPEÑO DE LOS MÉTODOS	69
3.3.1. <i>Exactitud de la detección de defectos</i>	70
3.3.2. <i>Exactitud del reconocimiento de defectos</i>	74
3.3.3. <i>Costo de implementación y complejidad del algoritmo</i>	76
3.4. ESTIMACIÓN DE LA EXACTITUD DEL CLASIFICADOR DE FRUTAS CON VISIÓN ARTIFICIAL	77

4. MATERIALES Y MÉTODO PARA LA INSPECCIÓN DE FRUTAS 80

4.1. DESCRIPCIÓN GENERAL DEL SISTEMA. VISIÓN DE BAJO NIVEL	80
4.1.1. <i>Materiales y equipos disponibles</i>	81
4.1.1.1. <i>Recolección de las muestras</i>	81
4.1.1.2. <i>Equipo de visión</i>	82
4.1.1.3. <i>Cámara de iluminación</i>	83
4.1.1.4. <i>Fondo de la imágenes</i>	87
4.1.1.5. <i>Software</i>	89
4.1.2. <i>Adquisición de las imágenes y toma de muestras</i>	90
4.1.3. <i>Detección de bordes y mediciones geométricas</i>	91
4.1.3.1. <i>Detección de bordes</i>	91
4.1.3.2. <i>Cálculo de las características geométricas</i>	92
4.1.3.3. <i>Errores geométricos</i>	92
4.2. EXTRACCIÓN DE CARACTERÍSTICAS. VISIÓN DE MEDIO NIVEL	93
4.2.1. <i>Segmentación</i>	93
4.2.1.1. <i>Método de segmentación</i>	94

4.2.1.2. Determinación del umbral.....	96
4.2.1.3. Análisis conectividad	98
4.2.1.4. Características de forma.....	98
4.2.2. Cálculo de las características de color.....	99
4.2.3. Características del histograma de color.....	99
4.2.4. Análisis de texturas	100
4.2.5. Selección de características.....	100
4.3. CLASIFICACIÓN Y EVALUACIÓN. VISIÓN DE ALTO NIVEL.....	106
4.3.1. Análisis contextual	106
4.3.2. Clasificación de los defectos.....	107
4.3.3. Entrenamiento del clasificador.....	109
4.3.3.1. Clasificación supervisada.....	109
4.3.3.2. Clasificación no supervisada.....	110
4.3.4. Evaluación del clasificador	111
4.4. RESULTADOS Y DISCUSIÓN	112
<u>5. CONCLUSIONES.....</u>	132
APORTES DE ESTE TRABAJO DE INVESTIGACIÓN	133
TRABAJO FUTURO	134
<u>REFERENCIAS</u>	136
<u>ANEXOS</u>	143

LISTA DE TABLAS

TABLA 1. TIPOS DE CALIDAD Y PARÁMETROS QUE LA DETERMINAN	14
TABLA 2. PROCESOS DE SELECCIÓN Y CLASIFICACIÓN DE ALGUNAS FRUTAS	42
TABLA 3. PROPIEDADES DE LAS FRUTAS Y SU DIFICULTAD PARA LA DETECCIÓN AUTOMÁTICA	48
TABLA 4. DETERMINACIÓN DE LAS TASAS DE ERRORES POR EVASIÓN Y DE FALSAS ALARMAS	75
TABLA 5. MATRIZ DE CONFUSIÓN PARA LOS RESULTADOS DEL RECONOCIMIENTO DE DEFECTOS.....	76
TABLA 6. SISTEMAS DE ILUMINACIÓN MÁS IMPORTANTES	85
TABLA 7. CÁLCULO DE LOS PARÁMETROS PARA ESTABLECER EL ÁREA EFECTIVA DE UN PÍXEL.....	93
TABLA 8. MATRIZ DE CONFUSIÓN PARA LOS RESULTADOS CON EL CONJUNTO DE PRUEBA	131

LISTA DE FIGURAS

FIGURA 1. COMPONENTES PRINCIPALES DE UN SISTEMA DE VISIÓN ARTIFICIAL PARA LA INSPECCIÓN DE FRUTAS	25
FIGURA 2. ARQUITECTURA PARA EL SISTEMA DE INSPECCIÓN VISUAL DEL SISTEMA DE INSPECCIÓN DE FRUTAS	26
FIGURA 3. DIAGRAMA DE BLOQUES PARA UN SISTEMA GENERAL DE VISIÓN ARTIFICIAL	29
FIGURA 4. ÁREAS DE LOS SISTEMAS DE ANÁLISIS DIGITAL DE IMÁGENES APLICADOS AL PROCESAMIENTO DE LOS ALIMENTOS	52
FIGURA 5. AMBIENTE PARA EL PROCESO DE DESARROLLO DEL SISTEMA DE INSPECCIÓN VISUAL	60
FIGURA 6. EJEMPLO DE LA INTERFAZ DE QWIN	65
FIGURA 7. EJEMPLO DE LA INTERFAZ DE QUIPS	67
FIGURA 8. EJEMPLOS DE LOS ERRORES COMETIDOS DURANTE LA DETECCIÓN	72
FIGURA 9. IMÁGENES TOMADAS SIN CONSIDERAR UN SISTEMA DE ILUMINACIÓN APROPIADO.....	83
FIGURA 10. ESQUEMA LATERAL DE LA CÁMARA DE ILUMINACIÓN.....	86
FIGURA 11. CÁMARA DE ILUMINACIÓN CONSTRUIDA.....	87
FIGURA 12. ESTACIÓN DE PROCESAMIENTO DE IMÁGENES LEICA Q550IW	89
FIGURA 13. CORRELACIÓN DEL ÁREA Y EL PERÍMETRO.....	103
FIGURA 14. CORRELACIÓN DEL PERÍMETRO Y LA REDONDEZ.....	104
FIGURA 15. CORRELACIÓN DEL DIÁMETRO Y EL PESO.....	105
FIGURA 16. IMAGEN DIGITALIZADA DE UNA NARANJA	112
FIGURA 17. DESCOMPOSICIÓN DE LA IMAGEN EN LOS CANALES DE COLOR RGB	114
FIGURA 18. DESCOMPOSICIÓN DE LA IMAGEN EN LOS CANALES DE COLOR HSI.....	114
FIGURA 19. HISTOGRAMA PARA EL CANAL ROJO DE LA IMAGEN	115
FIGURA 20. HISTOGRAMA PARA EL CANAL VERDE DE LA IMAGEN.....	116

FIGURA 21. HISTOGRAMA PARA EL CANAL AZUL DE LA IMAGEN.....	117
FIGURA 22. HISTOGRAMA PARA EL CANAL DE TONO DE LA IMAGEN	117
FIGURA 23. HISTOGRAMA PARA EL CANAL DE SATURACIÓN DE LA IMAGEN.....	118
FIGURA 24. HISTOGRAMA PARA EL CANAL DE INTENSIDAD DE LA IMAGEN	119
FIGURA 25. RESULTADO OBTENIDO AL UMBRALIZAR.....	120
FIGURA 26. DETECCIÓN DE BORDES DE LA FRUTA.....	121
FIGURA 27. BORDE DETECTADO PARA CUANTIFICACIÓN DEL PERÍMETRO Y ÁREA	121
FIGURA 28. IMAGEN UTILIZADA PARA LA MEDIDA DE COLOR DE LA PIEL SANA.....	122
FIGURA 29. ZONIFICACIÓN PARA ESTABLECER LAS REGIONES DE ANÁLISIS	124
FIGURA 30. DETECCIÓN DE DEFECTOS POR UMBRALIZACIÓN	124
FIGURA 31. DETECCIÓN DE BORDES DE LOS DEFECTOS PARA VISUALIZACIÓN.....	126
FIGURA 32. OTROS RESULTADOS OBTENIDOS PARA LA DETECCIÓN DE DEFECTOS	127
FIGURA 33. OTROS RESULTADOS OBTENIDOS PARA LA DETECCIÓN DE DEFECTOS.....	127
FIGURA 34. OTROS RESULTADOS OBTENIDOS PARA LA DETECCIÓN DE DEFECTOS.....	128
FIGURA 35. OTROS RESULTADOS OBTENIDOS PARA LA DETECCIÓN DE DEFECTOS.....	128
FIGURA 36. OTROS RESULTADOS OBTENIDOS PARA LA DETECCIÓN DE DEFECTOS.....	129

1. INTRODUCCIÓN

La calidad de los productos alimenticios es un factor de importancia vital en la actualidad, a diferencia de lo que sucedía años atrás, cuando lo único deseable en un alimento era su disponibilidad al precio más bajo posible. Ahora el panorama ha cambiado radicalmente, el objetivo es la obtención de productos sanos, libres de contaminantes, visualmente atractivos, de bajo precio y, si son perecederos, que su período útil sea lo más extenso posible.

Los productos agrícolas, como frutas y hortalizas, son perecederos, por lo que experimentan cambios constantes. Aunque un fruto sea cosechado, no detiene su proceso de transformación, este continúa y puede alterarse debido a la interrupción del abastecimiento de agua y otras sustancias básicas proporcionadas por la planta; por lo tanto, una vez recolectada, la fisiología de la fruta no se interrumpe; mientras se almacena, procesa o comercializa, el fruto utiliza sus reservas durante los procesos de transpiración, respiración y maduración que, por acción del medio, pueden culminar en putrefacción o deshidratación y pérdida del valor comercial y nutricional del fruto.

Por esto, es muy importante tener la fruta lista lo más rápido posible para el empaclado o procesamiento. Es una carrera contra el tiempo que suele parecer sencilla cuando los volúmenes de producto son pequeños, pero cuando se trata de millones de unidades, se convierte en una tarea compleja, agotadora y costosa. El panorama se complica si se tienen en cuenta los severos requerimientos exigidos por los organismos de vigilancia para la calidad de los alimentos.

El sector fruticultor requiere labores de actualización en la parte de post-cosecha del producto para lograr adaptarse a mercados de alta competitividad y exigencia, esto es válido sobre todo en nuestro país, donde la mayor parte del procesamiento se hace de

manera artesanal, con lo que es difícil conseguir productos realmente normalizados. Así mismo, el consumidor, como base del sistema comercial, demanda frutas de la mejor calidad, de manera que se deben optimizar los procesos de inspección para satisfacerlo.

Existe actualmente una gran demanda de sistemas fiables capaces de realizar las tareas de inspección a altas velocidades con el fin de verificar el 100% del producto y minimizar el desperdicio y las pérdidas por unidades clasificadas erróneamente, esto debido a que el trabajo de selección y clasificación manual hace que el costo total del proceso se eleve acentuadamente, contando, además, con que se introducen errores apreciables durante su ejecución.

Es deseable por tanto un sistema de inspección automatizado y, como las tareas de inspección visual son las más complejas e intensivas, se han invertido enormes esfuerzos en el diseño y construcción de sistemas de inspección visual automatizada capaces de manejar gran cantidad de parámetros y, con estos, tomar decisiones adecuadas.

El sistema lógicamente debe basarse en las normas y criterios de calidad establecidos para determinada fruta, estos principalmente tienen en cuenta el aspecto externo (tamaño, forma, textura, color, defectos y firmeza), el aspecto interno (daños internos no visibles desde el exterior) y las cualidades organolépticas (acidez, aroma, textura de la pulpa, etc.) [1].

Así, entre los parámetros más importantes para definir el aspecto externo (calidad externa) de una fruta están el tamaño, el color, la forma, la textura, y el aspecto visual, a menudo establecido por la cantidad y distribución de los defectos externos. En la actualidad se han diseñado sistemas basados en visión artificial capaces de separar la fruta por su tamaño y color, aunque en la detección y reconocimiento de los defectos externos no se han presentado resultados óptimos. En cuanto a la forma se han realizado algunos avances que permiten establecerla de manera global para un

objeto dado, pero algunas aplicaciones exigen sistemas que puedan determinar la forma de manera muy precisa, con lo que es un campo de trabajo muy activo en la comunidad científica.

Un sistema automático de inspección debe tratar de cuantificar la mayor cantidad de parámetros posibles para establecer, de la forma más aproximada, la calidad del producto. Como esto es técnicamente difícil, lo que se hace generalmente es lo que se ha denominado el control de calidad, es decir, medidas basadas en muestreos de cada partida de producto, de tal manera que se hace una representación del estado global de este. Se trata de una aproximación estadística de estimación de la calidad, con lo que no se obtiene información que asegure la calidad individual de los productos.

El control de calidad generalmente se realiza con la ayuda de métodos destructivos de análisis, ocasionando que el producto inspeccionado sea alterado en sus propiedades de interés y muchas veces parcial o totalmente destruido. En años recientes se han elaborado métodos de análisis no-destructivos aplicables a frutas y hortalizas, estos se basan en el análisis de la reflectancia, transmitancia, fluorescencia y en sistemas de visión infrarrojo y visible (IR-Vis).

La idea en este trabajo de grado es establecer un sistema de inspección automatizado que supere estos inconvenientes, es decir que permita verificar la totalidad del producto y que la técnica empleada para ello no altere el objeto analizado, en otras palabras, que al realizar las medidas sobre la fruta se empleen técnicas de metrología no-destructivas. La técnica empleada es la visión artificial que provee información valiosísima sobre el producto, como lo es la información visual.

El sistema propuesto se basa en el análisis realizado sobre las imágenes tomadas con iluminación y cámaras de operación en rango visible del espectro electromagnético, analizando lo que es el aspecto externo de la fruta, o sea, desde la perspectiva visual humana.

El aspecto externo de un producto es el primer parámetro que el consumidor percibe en el momento de la compra [1]. Además del color, asociado con el grado de madurez, los defectos externos pueden representar la diferencia entre la compra o rechazo por parte del consumidor. En la industria hortofrutícola se tiene el inconveniente de la constante degradación del producto, algunos daños pueden acentuarse durante el almacenamiento y transporte y, lo más delicado, pueden extenderse a todos los frutos del compartimento, ocasionando pérdidas muy cuantiosas con innumerables consecuencias.

Los sistemas existentes se limitan a la detección de manchas oscuras superficiales, suponiendo que los defectos se ubican en la parte baja de los valores de niveles de gris, lo cual es a menudo falso. Si se diseñan e implementan sistemas capaces de analizar y distinguir más parámetros, tales como textura, color y forma, la información obtenida permitiría clasificar los productos de manera más fiable, incluso teniendo en cuenta el destino de la fruta.

Los sensores de visión suministran gran cantidad de datos, dentro de los que se encuentra la información relevante que se puede usar para la toma de decisiones; con base en esto se presenta, mediante este trabajo, la implementación de un sistema de clasificación y control de calidad apoyado en las técnicas de visión artificial con el fin de resolver los problemas de inspección de frutas en las primeras etapas de post-cosecha. La clasificación se realiza de acuerdo al tamaño, color y contenido de defectos externos, en otras palabras, lo que se describe es la implementación de un sistema de inspección visual automatizado aplicado al procesamiento de frutas.

Este documento está organizado de la siguiente manera: en el capítulo introductorio se exponen los conceptos básicos de las materias relacionadas con el trabajo, en el capítulo 2 se profundiza un poco en los sistemas de visión artificial aplicados a la inspección visual de frutas. El capítulo 3 contiene una descripción del desarrollo del método en el que se describen el ambiente y las herramientas de desarrollo, y finalmente se hace un estudio del desempeño de los métodos implementados, la

aplicación se describe en el capítulo 4, donde se hace un completo análisis de los métodos para la inspección de frutas. Las conclusiones, aportes y el trabajo futuro hacen parte del capítulo final.

1.1. LA CALIDAD DE LAS FRUTAS

La calidad se relaciona con las características y cualidades que presenta un producto de tal manera que pueda ser apto para las necesidades del consumidor. Específicamente, para las frutas y hortalizas consiste en el ofrecimiento de productos que cumplan ciertos requerimientos respecto al tamaño, color, textura, firmeza, sabor y contenido de defectos, entre otros. La tabla 1 muestra los tipos de calidad junto con los principales parámetros medibles para determinar la calidad de la frutas [2].

Tabla 1. Tipos de calidad y parámetros que la determinan

CALIDAD	PARÁMETROS
Visual	Tamaño Forma Color Textura Contenido de defectos
Mecánica	Dureza Textura de la pulpa
Físico-química	Acidez Contenido de azúcares Relación Azúcares-Acidez Aroma
Nutricional	Valor nutritivo
Higiénica	Contenido de residuos tóxicos Presencia de organismos dañinos

Fuente: Basada en Evaluación de métodos no destructivos para determinar la calidad de la fruta. Ver referencia [2]

La calidad visual está determinada por el aspecto visual de la fruta, la calidad mecánica se refiere básicamente a la firmeza de la fruta para que resista la manipulación, con la calidad físico-química se busca controlar que, entre otros, el

olor y sabor de la fruta estén dentro de la norma, la calidad nutricional hace referencia al análisis que determina el contenido de nutrientes del producto y que, frente a parámetros internacionales, lo hacen adecuado para la alimentación humana y la calidad higiénica pretende asegurar la carencia de sustancias u organismos nocivos para el consumidor.

La calidad también se clasifica de acuerdo a los entes que se encargan de producir, procesar, distribuir y consumir la fruta. Por esto se habla de calidad legal, que se basa en las normativas emitidas por los organismos de control de calidad de los alimentos; calidad del consumidor, relacionada con lo que el consumidor entiende por ‘buen producto’ y calidad comercial, que se refiere a la frescura y firmeza de la fruta que permita manipularla, transportarla y comercializarla. La más importante es la del consumidor ya que es quien, en últimas, comprará el producto y decidirá quién le ofrece mejor calidad a precios razonables; por lo tanto un factor adicional e importante es la relación calidad-precio ya que influye significativamente para la decisión de compra, pero es un parámetro que depende de los procesos y condiciones anteriores; precisamente con la implementación de un sistema de visión artificial para la clasificación y control de calidad de frutas se pretende mejorar esta relación ya que, de esta manera, se puede obtener un producto de mejor calidad a menor precio.

En definitiva, la clasificación, mediante el código de clase I, II, III, etc., de acuerdo a la calidad de la fruta busca que dentro de las clases se respeten determinados rangos para el tamaño, color, contenido de defectos, contenido de azúcares, etc. Así, se consigue que los lotes de frutas sean homogéneos de acuerdo a las categorías establecidas.

La normalización del producto, además de los inconvenientes operacionales y económicos que conlleva, también tiene sus ventajas [2]:

1. Incremento de la calidad de la fruta al eliminar las unidades de baja calidad.
2. Mejoramiento en el precio ya que el producto es más atractivo.

-
3. Certeza de la producción con que se cuenta: con la estandarización de la producción se tiene perfectamente identificado el producto y su precio.
 4. Se puede orientar la producción: se trasladan diferentes grados de calidad del producto de acuerdo a las exigencias del consumidor.
 5. Como el producto está tipificado, se evitan fraudes en las distintas fases de la comercialización.

En resumen, lo que se busca, mediante los diferentes patrones de calidad, es lograr que la fruta clasificada presente un buen aspecto, posea un tamaño adecuado, tenga alta homogeneidad, se encuentre dentro de los requisitos legales, satisfaga al consumidor y represente ganancias económicas para el productor.

1.1.1. Parámetros para determinar la calidad superficial de las frutas. El tamaño es quizá el factor principal para la clasificación de frutas, se ha alcanzado un grado relativamente alto en la automatización de sistemas de clasificación por tamaño. Muchas veces es obtenido a partir del peso suponiendo frutas con densidad constante [1]. Para determinar el tamaño es más adecuada la utilización de cámaras CCD que ofrecen la posibilidad de cuantificar características adicionales de la fruta, tales como la forma, el color y la textura, esto a cambio de mayores requerimientos en la plataforma y en el poder de procesamiento computacional.

La forma es un parámetro que tiene importancia para algunas especies de frutas, como bananos y peras, que, de acuerdo a la complejidad, se puede tratar de algoritmos de alta intensidad computacional debido a la necesidad de utilizar metodologías, como la morfología matemática, con lo que no es posible, por el momento, implementar sistemas industrialmente factibles.

El color se utiliza principalmente para determinar el grado de madurez, detectar algunos defectos y localizar zonas coloreadas de frutas de distribución heterogénea de color, como en algunas variedades de manzanas.

Los defectos externos (defectos de la piel) son un factor de mucha relevancia y es una labor difícil debido a la diversidad e incertidumbre sobre la localización, tamaño y tipo de estos, cuestión siempre presente en los productos de origen natural. Los defectos externos incluyen desde las magulladuras debidas a golpes, hojas y cicatrices hasta los restos de insectos, hongos, presencia de pedúnculos y ausencia del cáliz. Es fundamental determinar de manera precisa la cantidad, distribución y tipo de defectos presentes en la fruta debido a que algunos pueden extenderse por toda la fruta y, con el tiempo, pueden contaminar otros elementos.

1.2. INSPECCIÓN VISUAL AUTOMATIZADA: ¿PORQUÉ Y PARA QUÉ?

La inspección visual de materiales o productos es necesaria en los procesos industriales. Es importante para la caracterización y clasificación de materias primas, para el control de procesos de manufactura, y para determinar la calidad de los productos finales. Las aplicaciones típicas de la inspección visual incluyen la inspección de las dimensiones y la calidad de las superficies de piezas elaboradas, la calidad de impresión de etiquetas y billetes, la verificación de circuitos impresos, el análisis de imágenes de rayos X, el control de calidad de juntas de soldadura y de herramientas, la inspección de productos alimenticios como pollo, carne, frutas y hortalizas, y el reconocimiento de defectos en textiles, papel, acero y madera, entre otros [3-23].

A pesar del alto grado de automatización en las líneas de producción, las tareas de inspección visual de las piezas se confía principalmente al sistema visual humano ya que el proceso de inspección visual se ha automatizado a pasos relativamente lentos [3, 24, 25]. El desarrollo de sistemas de inspección visual automatizada no es fácil. La falta de flexibilidad de las estrategias de diseño existentes, la carencia de métodos bien establecidos de caracterización del desempeño y la escasez de estudios en la materia complican el desarrollo de este tipo de sistemas [26]. Además, la identificación visual automática es bastante difícil, las tareas de inspección son a menudo más complejas de lo esperado y muchos problemas requieren alta velocidad

[27, 88], lo que representa un gran desafío para los desarrolladores. Sin embargo, el sector industrial es entusiasta respecto a la automatización de las tareas de inspección visual.

La mayoría de los beneficios de la inspección visual automatizada se encuentran comparando la inspección automatizada con la inspección humana. Un sistema de inspección automatizado puede operar incansablemente y proporciona calidad y exactitud consistentes en los productos inspeccionados [17]. La inspección automatizada puede encontrar defectos que son demasiado sutiles para la capacidad discriminativa de un humano [29] y operan con velocidades mucho más altas que este [19], por ejemplo, los tejidos en una línea de producción se mueven a varios metros por segundo [30, 31].

En un ambiente automatizado, se puede tener en cuenta la información sobre cada defecto, su tipo, posición y clasificación según el tamaño, y es posible manejar simultáneamente una variedad mucho mayor de opciones de las que sería capaz un inspector humano. Por otro lado, no deben subestimarse la flexibilidad y robusticidad de los inspectores humanos. De aquí que sea difícil incorporar la capacidad de los humanos para manejar situaciones inesperadas en un sistema de la inspección automatizado.

Aunque las ventajas de la inspección automatizada están mejorando la productividad de tal manera que se han superado las desventajas de la inspección manual inconsistente, ahorrando esfuerzo humano, hay también subsecuentemente un trasfondo humanitario ya que muchas tareas de inspección son difíciles, tediosas y, muchas veces, hostiles o peligrosas [19, 23].

También se han comparado las ventajas de la inspección visual automatizada con los métodos de inspección automatizada sin visión, por ejemplo con los basados en inspección por contacto. La visión artificial puede aliviar la necesidad de implementación de líneas de retención y posicionamiento precisos. Además, las

operaciones de inspección mediante visión artificial se hacen sin contacto (pruebas no-destructivas) y no hay riesgo de daño para el producto durante la inspección.

Con todo esto, la inspección visual automatizada no siempre puede ser factible. Para que sea factible, debe ser rápida, fiable, robusta, y rentable [23]. El concepto de rapidez (relacionada con el concepto de tiempo real) es dependiente de la aplicación, por lo que los requerimientos de respuesta del sistema pueden variar de milisegundos a minutos. El funcionamiento en tiempo real de un sistema de inspección es un gran reto debido a los grandes volúmenes de datos y a la complejidad de los métodos. La fiabilidad y la robustez son las capacidades del sistema para operar con iluminación cambiante, objetos inesperados, polvo, humo, vibraciones, o el cambio de velocidad del producto, etc. Debe considerarse también el costo de desarrollo e implementación. Típicamente, la inspección automatizada es económicamente factible cuando el proceso tiene grandes volúmenes, requiere inspección muy consistente o exacta, o está en un ambiente que implica algún riesgo para la integridad de los humanos.

1.3. VISIÓN ARTIFICIAL PARA LA INSPECCIÓN DE FRUTAS

La inspección visual de las superficies de frutas, a partir de aquí “inspección de frutas”, en la industria es un buen ejemplo donde pueden resaltarse fácilmente los beneficios de la automatización [7, 11, 13, 14, 16, 27]. En el procesamiento de frutas los volúmenes del producto pueden ser muy altos, por lo que pequeñas mejoras de la calidad pueden significar notables ahorros o ganancias.

La inspección de frutas es un trabajo costoso, monótono, agotador y, a menudo, el humano realiza la clasificación de manera inconsistente y por lo general de manera muy lenta [14, 17]. Así mismo, el desempeño de los operadores humanos clasificando objetos con defectos superficiales tiene una efectividad relativamente baja en el reconocimiento, localización e identificación de los defectos (menor al 70%). Si los objetos son pequeños y complicados la inspección humana requiere altos niveles de concentración, se ha establecido que solamente durante la primera media hora los

humanos están habilitados para desempeñarse significativamente mejor que un clasificador aleatorio [32].

Si se emplean de 6 a 8 inspectores humanos en la inspección del mismo producto, muchos objetos defectuosos no se detectan [32]. Igualmente, la correspondencia entre personas diferentes al clasificar el mismo material es baja, confirmando que la inspección visual realizada por humanos es un proceso altamente subjetivo [18], dependiente de la experiencia del inspector [33], y cualitativo, por lo que es impreciso [3].

Las inconsistencias cometidas por los humanos hacen también que la inspección automatizada de superficies de frutas sea una tarea desafiante ya que no es muy evidente la disposición de un material de entrenamiento adecuado para un sistema automatizado. El mayor reto, en este caso, es el debido al amplio rango de variación de los materiales naturales [27], la apariencia de las frutas sanas varía enormemente y no hay dos frutas o defectos que tengan exactamente las mismas propiedades, como color, forma, tamaño o textura.

La variabilidad de los objetos en agricultura hace muy difícil adaptar los algoritmos industriales existentes al dominio de esta [13]. Las mayores dificultades surgen en condiciones no controladas [34], por lo que un problema crítico en visión artificial es la percepción de formas sin una estructura geométrica bien definida, o un modelo completo más general no definido directamente por medio de un conjunto de características precisas [35].

Existen comercial e industrialmente algunos sistemas de inspección de frutas y alimentos [13, 16] y varios grupos de investigación han desarrollado y aplicado métodos para la detección y el reconocimiento de defectos de varios tipos de frutas [1-2, 11-12, 15, 36-37]. Sin embargo, debido a la complejidad de la detección y reconocimiento de los defectos, hay todavía muchos problemas para la inspección

automatizada. Aún así, el desarrollo de nuevos métodos de inspección continúa avanzando.

Complementariamente, muchos grupos de investigación han reconocido la importancia del color en el reconocimiento de defectos [38-41] y en el establecimiento del estado general y de maduración de frutas y alimentos [9]. Sin embargo, el reconocimiento de defectos en color está apenas entrando en los sistemas de inspección ya que solo recientemente ha sido posible el establecimiento a velocidades razonables. Con todo, el color exclusivamente no es la solución ya que no puede usarse para reconocer defectos que tienen un color similar al de las frutas sanas. En estos casos, la forma y las propiedades texturales son importantes [42], también lo son las aproximaciones basadas en métodos especiales de imágenes como la polarización de la luz o los enfoques multiespectrales [12, 43].

2. INSPECCIÓN VISUAL AUTOMATIZADA DE FRUTAS

Este trabajo trata dos ramas de la ingeniería diferentes: visión artificial y procesamiento de frutas. Para entender el trabajo desarrollado que se presenta en este documento, es necesario dar una introducción a ambas ramas.

Esta sección empieza con una introducción a la inspección visual automatizada en general. Se explica, con ayuda de un modelo simplificado para la inspección visual automatizada, la terminología relacionada. Puesto que la clasificación y el control de calidad de frutas son las áreas de aplicación principal para el método desarrollado en este estudio, se presentarán el procesado post-cosecha de la fruta desde la perspectiva de la apariencia visual de esta y las prácticas de clasificación usadas actualmente. Finalmente, se presenta una revisión de la investigación y el estado-del-arte acerca de inspección automatizada de frutas.

2.1. INSPECCIÓN VISUAL AUTOMATIZADA

La **inspección** (inspección industrial) es el proceso para determinar si un producto (también llamado parte, objeto o artículo) se desvía de un conjunto de especificaciones dado, de acuerdo a ciertas características de calidad [44]. La **inspección visual** significa inspección basada en información pictórica percibida por un humano o un sensor de visión artificial. Por consiguiente, la **inspección visual automatizada** significa inspección visual por medio de visión artificial. Igualmente, en este caso el término **sistema de visión artificial para clasificación de frutas** es equivalente a **sistema inspección visual automatizada de frutas**, como se designará en adelante.

Una aplicación obvia de la inspección visual es la verificación de la calidad de los productos para clasificarlos o para rechazar los defectuosos. Se puede aplicar en la medición de algunas propiedades del producto para controlar el proceso de manufactura (control de calidad) con el fin de recolectar estadísticas (monitoreo) de la eficacia del proceso industrial.

La inspección visual normalmente involucra la medida de aspectos específicos del producto como la integridad del ensamble, el acabado de la superficie y las dimensiones geométricas [23]. La inspección debe distinguirse de los ensayos o pruebas, como el análisis de tensiones, que involucra un examen activo de funciones operacionales específicas del producto. De acuerdo a Malamas [23], la mayoría de las aplicaciones están relacionadas con al menos uno de los cuatro tipos de inspección: estructural (si hay objetos perdidos o cuerpos extraños), superficial (si la superficie tiene la calidad adecuada), dimensional (medida del tamaño y la forma) y operacional (si el dispositivo opera de manera correcta o precisa).

En el caso del sistema de inspección automatizado de frutas propuesto, se trata de la combinación de al menos tres de estos tipos de inspección: (1) estructural por lo que muchas veces se busca la presencia de objetos extraños, del pedúnculo, del cáliz, de insectos o de sus excrementos, (2) superficial debido a que se buscan características específicas en la piel de la fruta y (3) dimensional ya que, cuando existen defectos superficiales, estos se deben cuantificar y ponderar para establecer la clasificación de la fruta analizada y además se considera el tamaño y la forma global de la fruta.

Generalmente se aceptan tres etapas de aplicación para la inspección en un ambiente de producción: inspección de entrada, inspección durante proceso e inspección de salida [45]. La inspección de entrada es el examen de las materias primas, la inspección durante proceso es el examen del rendimiento de una fase intermedia de trabajo, y la inspección de salida es la inspección exhaustiva de un producto al final de todas las fases de ensamble y manufactura.

Por lo general se necesitan sistemas de inspección visual (automática o humana) en cada una de estas etapas, esta clasificación también es relativa debido a que un sistema de inspección de frutas puede estar, por ejemplo, a la salida del centro de acopio de la compañía fruticultora o a la entrada de una fábrica de mermeladas, donde se encarga del análisis de la materia prima.

El mejoramiento en la relación precio/desempeño de los sistemas de visión significa que el objetivo de la inspección del 100% puede ser una realidad [46]. Así mismo, el establecimiento de sistemas de visión en cada una de las fases del proceso de manufactura ha permitido que empiecen a aparecer conceptos como **visión distribuida** y **redes de visión**, donde se implementan dispositivos sensores de visión, con sus respectivos procesadores y actuadores, en cada uno de los puntos donde son necesarios y las estadísticas obtenidas son enviadas a una estación central, a través de una red, que se encarga de controlar el proceso completo y de recolectar los datos de todos los sistemas de visión.

En la literatura se han presentado varias divisiones para el proceso de inspección. En la **inspección de rectificado** los productos defectuosos son retirados del lote inspeccionado mientras que en la **inspección de aceptación** no se quita el producto deficiente sino que se asignan lotes de diferentes categorías según la calidad de los productos. La **inspección cualitativa** clasifica objetos como aceptables o defectuosos, mientras que la **inspección cuantitativa** produce una medida de alguna característica, como la longitud y el peso del producto, pudiéndose clasificar. La inspección puede ser **del 100%** o **por lotes** si todos los productos se inspeccionan (clasificación) o si solo se inspecciona una muestra de este (control de calidad) [44].

En cuanto a la dirección de este trabajo, se trata de la implementación de un sistema de inspección cuantitativa de aceptación del 100% o por lotes.

2.1.1. Componentes de un sistema de inspección visual automático. En la figura 1 se muestran los componentes de un sistema simplificado de inspección visual

automatizada [23,47]. Aunque el ejemplo es para la inspección de frutas, el esquema es bastante generalizado. Se necesitan un sistema de iluminación y las cámaras para la adquisición de la imagen, con sus respectivas tarjetas de digitalización, actuadores mecánicos para manipular los artículos inspeccionados frente a la(s) cámara(s), el (los) procesador(es) para realizar el tratamiento de la imagen digital y las operaciones relacionadas con el control del proceso, y una interfaz de usuario para controlar y observar el funcionamiento del sistema.

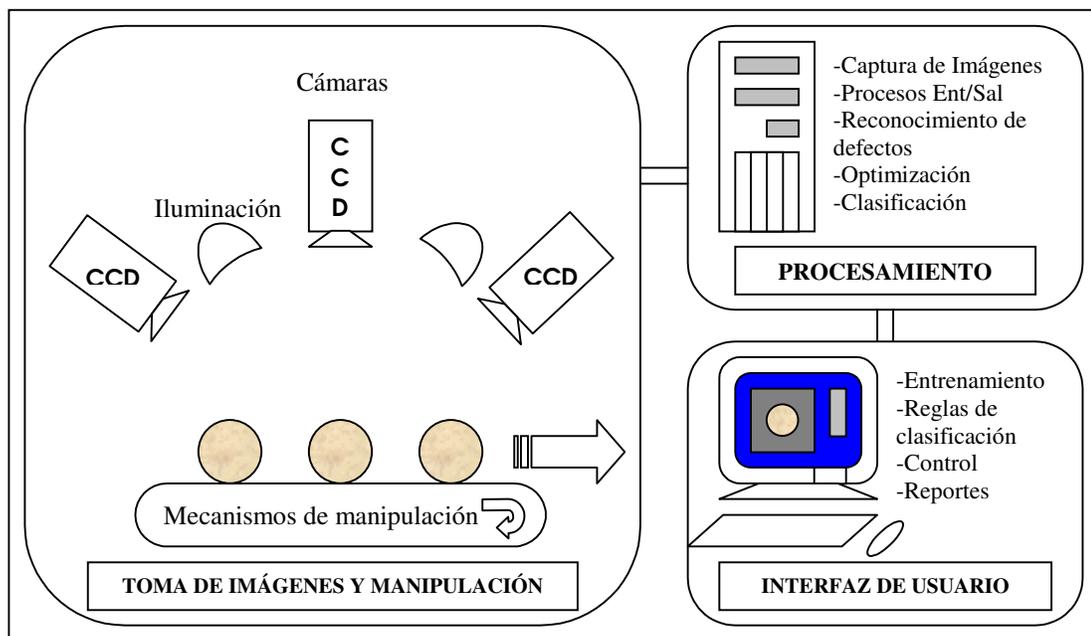


Figura 1. Componentes principales de un sistema de visión artificial para la inspección de frutas

En la figura 2 se muestra la arquitectura general para implementar un sistema automatizado de inspección visual, se presenta un concepto del método para la inspección visual de frutas orientado a la realización de la inspección para el control de calidad o clasificación. La **formación de la imagen**, es decir, la adquisición de la imagen, consiste en capturar una imagen de la fruta, calibrar la cámara mediante el sistema de referencia y realizar los procedimientos para corregir los perfiles de iluminación, y finalmente trasladar los datos a la unidad de procesamiento. La **eliminación de las zonas de piel sana de la fruta** se usa para realizar una detección

preliminar de los defectos con el fin de encontrar regiones sospechosas de la imagen que podrían contener áreas posiblemente defectuosas. La fase de **reconocimiento de defectos** hace mas precisa la detección y clasificación de los defectos que se sitúan en estas regiones. Finalmente, se pasa una lista de defectos, mediante un vector de características, a la **fase de clasificación** que determina la calidad global de la fruta.

Los componentes que se presentan en la figura 1, como son: adquisición de la imagen, tratamiento de la imagen digital y la interfaz del usuario, son explicados con más detalle a continuación.

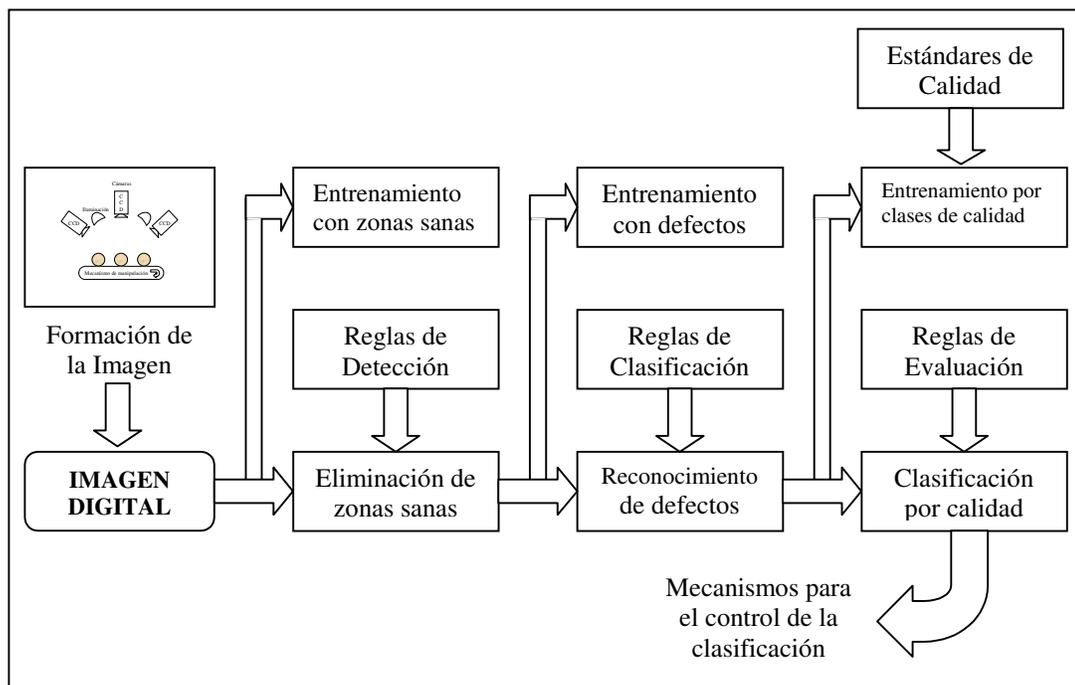


Figura 2. Arquitectura para el sistema de inspección visual del sistema de inspección de frutas

2.1.2. Adquisición de la imagen. La adquisición de la imagen es una parte esencial y crítica dentro de un sistema de visión artificial. La resolución, enfoque o iluminación pobres causan problemas en los procesos siguientes ya que la información es difícil de recuperarse si se pierde durante la adquisición de la imagen. La adquisición consiste en: (1) exponer el sensor de la cámara por un cierto tiempo, (2) configurar la

apertura de la lente y el enfoque en el momento correcto, (3) digitalizar la imagen, realizar la corrección de no-linealidades, si es necesario, y (4) mover la imagen al *buffer* de memoria del sistema para realizar las operaciones de procesado y análisis de la imagen digital.

Las cámaras por excelencia para la industria y la investigación en este momento son las denominadas CCD (Dispositivos de acople por carga, por sus siglas en inglés), las innumerables ventajas que presentan han hecho que se apliquen en todas las ramas de la actividad humana. El elemento de estado sólido que hace de fundamento para su operación permite altos grados de integración, amplio rango dinámico, respuesta lineal, posibilidad de operar en varias bandas, altas velocidades de integración y gran versatilidad para su diseño. Para una revisión sobre estos y otros dispositivos revisar [43, 48, 49].

Para la inspección de las superficies que se desplazan, como textiles o papel, se usan a menudo cámaras CCD de barrido lineal. Una cámara de barrido lineal toma una imagen de una línea estrecha perpendicular al movimiento de la superficie. La imagen de la superficie que se desplaza se forma almacenando las líneas consecutivas de la “tira de imagen” obtenida.

Una ventaja del uso de cámaras de barrido lineal, comparada con una cámara de matriz, como la que se usa en este trabajo, es la economía en iluminación, ya que sólo se necesita iluminar una línea estrecha. Un problema típico es conseguir suficiente luz sobre el área de la escena para la adquisición de imágenes de superficies que se desplazan rápidamente. Así mismo, el control de la iluminación no uniforme es más fácil en el caso de la adquisición mediante barrido lineal.

La adquisición de la imagen puede consistir en una o más cámaras tomando imágenes de uno o más lados del producto. En los entornos industriales, por ejemplo, este asunto depende de la disposición mecánica de las frutas, si es posible colocar espejos

oblicuos o resulta más confiable una cámara desde otra posición, y si se puede detener y voltear la fruta durante la inspección.

2.1.3. Procesamiento y análisis de la imagen. Después de la adquisición de la imagen, esta es sometida al procesamiento y análisis respectivos. El propósito es encontrar cualquier desviación de la apariencia normal. El proceso de inspección normalmente tiene lugar en tres fases: (1) adquisición de la imagen, (2) localización del objeto, y (3) medida y análisis de este. Es importante también la separación entre localización y análisis, ya que es probable que el problema de localización del objeto sea mucho más intenso computacionalmente que su análisis [50].

Los procedimientos para localizar el objeto, conocidos a menudo como **detección de defectos**, y realizarle el análisis, distinguidos como **reconocimiento de defectos**, se realizan por medio del procesamiento y análisis de la imagen y los **métodos del reconocimiento de patrones**, conocidos, en conjunto, como **métodos de la visión artificial**. Los resultados del reconocimiento de defectos son usados por métodos de alto nivel, es decir, por algoritmos de clasificación. Una combinación de un conjunto seleccionado de los métodos de la visión artificial y los métodos de alto nivel se refieren como los **métodos de la inspección visual automatizada**.

En la figura 3 se muestra un diagrama de bloques de un sistema general de visión artificial. Consiste en un preprocesador de la imagen, un detector de defectos, un extractor de características, y un clasificador dispuestos secuencialmente.

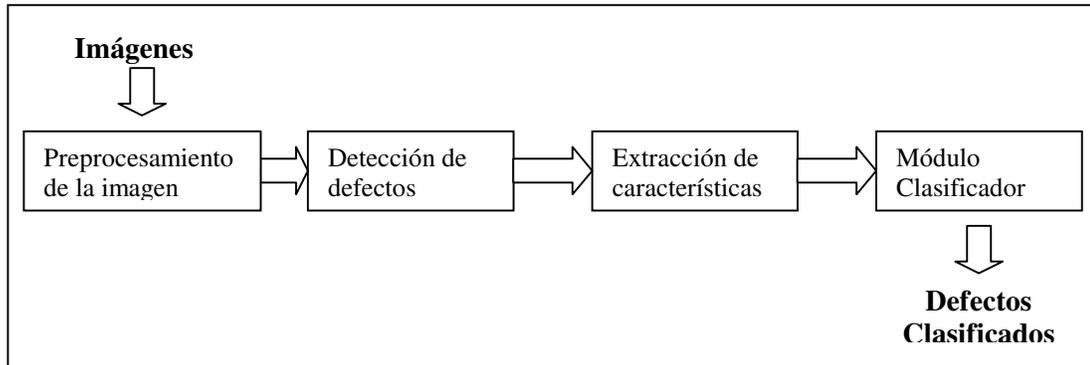


Figura 3. Diagrama de bloques para un sistema general de visión artificial

Básicamente hay dos filosofías distintas en el reconocimiento de patrones: estadístico y estructural. En el reconocimiento estadístico de patrones, los vectores numéricos de características de longitud fija son clasificados con un clasificador estadístico. En el reconocimiento estructural, los objetos se examinan por sus propiedades características y sus interrelaciones, y se asignan a unas clases dadas [51]. Un sistema de inspección práctico necesita, a menudo, una combinación de las dos aproximaciones. El método de visión artificial simplificado presentado en la próxima sección es basado en el reconocimiento estadístico de patrones.

2.1.4. Descripción general del sistema de visión artificial. El propósito del preprocesamiento de la imagen es preparar los datos para la detección de defectos. Las operaciones necesarias son muy dependientes de la aplicación. Entre las operaciones típicas están la calibración de la cámara, la corrección de perfil de iluminación y las transformaciones en los espacios de color. Debido a que el volumen de datos de la imagen en esta fase del sistema de inspección es muy alto, la complejidad de las operaciones debe ser baja.

El algoritmo de detección de defectos también tiene que manipular proporciones de datos muy altas. Tiene que estar basado en métodos relativamente simples que puedan eventualmente implementarse en hardware. Debido al requisito de

simplicidad, la detección normalmente no es perfecta y algunas veces se pasan por alto algunos defectos (llamados errores por evasión, aceptación de objetos defectuosos) y otras veces se hacen detecciones de más (denominados falsas alarmas, rechazo de objetos aceptables) [11].

Los errores por evasión son normalmente más perjudiciales que las falsas alarmas, ya que estos no pueden recuperarse en las fases posteriores. Por consiguiente, la detección de defectos normalmente se pone a punto (sintonización del sistema) para producir algunas falsas alarmas con el fin de garantizar una proporción de errores por evasión más baja. Por otro lado, el propósito del detector de defectos es reducir la cantidad de datos que deben ser procesados en las fases siguientes, de tal manera que hay un límite superior para el número de falsas alarmas que depende de la aplicación. En las fases avanzadas del proceso se minimizan las falsas alarmas con técnicas más complejas que las implementadas en el algoritmo de detección de defectos.

En este trabajo, se usan los conceptos de los métodos basados en la segmentación para la detección de defectos. El propósito de la segmentación es descomponer la imagen en partes que son significativas con respecto a una aplicación particular [41, 52]. La partición es basada en algunas características, como el nivel de gris, el color o la textura de la imagen, que son relativamente uniformes y homogéneas dentro de la región segmentada y difieren de las características del área circundante. Las técnicas de segmentación incluyen umbralizado, agrupamiento espacial, crecimiento de regiones, partición y unión, y segmentación basada en reglas, por mencionar algunas [41, 53].

Se puede realizar la partición sin tener en cuenta el contenido de la imagen, sin descomponer la imagen en regiones significativas. Por ejemplo, se particiona mediante regiones rectangulares no superpuestas de tamaño fijo. Cada región se analiza para establecer si contiene algo que debe ser procesado en fases posteriores con más detenimiento, este procedimiento se denomina método no basado en segmentación. El análisis de regiones se hace, por ejemplo, calculando un conjunto de

características y clasificándolas. El resultado del método es el establecimiento de regiones sospechosas que son sujetas a un procesamiento posterior, como el cálculo de más características o la segmentación como tal. Debido a la partición arbitraria, un defecto puede cubrir varias regiones, o puede ocupar sólo una pequeña parte de una región.

El propósito de este método es evitar los problemas encontrados con el método basado en segmentación. Es muy difícil enseñarle a un computador lo que constituye una segmentación ‘aceptable’ [41, 53]. Además, decidir una segmentación conveniente puede ser difícil para un humano, que puede causar inconsistencias en la recolección del material de entrenamiento. La segmentación puede fallar si las diferencias entre los defectos y el área circundante no son bastante grandes, por ejemplo, en la detección de defectos de gran tamaño o en el caso de maduración no uniforme de una fruta.

Los resultados de ambos métodos son similares: una lista de regiones para la extracción de características. La diferencia es que la técnica no basada en segmentación no proporciona regiones o formas exactas de los defectos, y requiere más procesamiento en las fases subsiguientes si es necesaria la información sobre la localización y la forma. Por esta razón, se usa principalmente el método basado en segmentación, tal como se verá en el capítulo 4.

Los parámetros que calcula el extractor de características son muy dependientes de la aplicación, e incluso pueden variar para productos semejantes dentro de la misma línea de producción. Cuando se establece una aplicación, se seleccionan las características más convenientes. Se recoge un conjunto de imágenes de muestra y se seleccionan y calculan un gran conjunto de características para estas. La selección de las características es realizada por un algoritmo que intenta minimizar una función de costo, relacionada típicamente con los errores en la clasificación, es decir, las proporciones de errores por evasión o de falsas alarmas. No sólo se debe tener en cuenta el desempeño, sino también la complejidad computacional y los aspectos

implementacionales de las características cuando estas son seleccionadas para la aplicación.

El clasificador compara el valor de la característica calculada de una región detectada con los valores de las características de las muestras de entrenamiento, y selecciona la clase para la región. Este puede estar basado en las distribuciones de probabilidad de los valores de las características de entrenamiento, encontrar los vecinos más cercanos en el espacio de características, o puede ser una red neuronal que produce el resultado apropiado, de acuerdo al entrenamiento, en su capa de salida.

Una aplicación real es típicamente más compleja a la que se ilustra en la figura 3. Pueden haber muchos cálculos de características y fases de clasificación, por lo que un problema de clasificación complejo es más fácil de resolver si se divide. La implementación de un sistema de inspección que opere eficientemente requiere también de muchas más funciones relacionadas con el procesamiento y análisis de imágenes de las listadas anteriormente. Éstas incluyen el seguimiento de los bordes del objeto inspeccionado, la determinación de marcadores de referencia, las interfaces de usuario, y las operaciones de entrada/salida, por mencionar algunas.

Para una revisión completa de los métodos y sistemas de tratamiento y análisis de imágenes revisar Castleman [43] y González [54]; para visión artificial Davies [26], Shapiro [16] y de la Escalera [55]; para inteligencia artificial y robótica Nilson [34], Groover [52] y Fu [53] y para reconocimiento de patrones Chen [42]. Son también muy útiles los *surveys* que explican las bases, tendencias y estado-del-arte de temas específicos de la visión artificial y afines [5, 13-14, 23, 45]. Las revistas especializadas presentan lo último en el tema y en estas se encuentran muchas aplicaciones y algoritmos útiles: *Image and Vision Computing*, *Pattern Recognition Letters*, *Pattern Recognition*, *Optical Engineering*, *Applied Optics*, *Computers and Industrial Engineering* y *Computer Vision and Understanding*.

2.2. EL COLOR EN LA INSPECCIÓN INDUSTRIAL

El uso de color en lugar de los niveles de gris en la visión artificial se ha vuelto común en las aplicaciones de inspección industrial. El color es un atributo de la imagen que provee más información que la intensidad solamente, su incorporación en los sistemas de análisis hace que se incremente la precisión del proceso de clasificación [39, 56], sobretodo si los defectos pueden ser definidos en términos de las características de color [9].

La información de color puede mejorar la exactitud del reconocimiento, por supuesto, si el material inspeccionado o las piezas tienen algunas propiedades de color. Las cámaras en color son en la actualidad más baratas y los altos volúmenes de datos producidos por estas pueden manejarse mejor con los procesadores cada vez más rápidos.

Sin embargo, el uso del color puede parecer difícil ya que en la mayoría de los casos la medida de este es afectada más fuertemente por los cambios de iluminación que la medida de los niveles de gris, aunque en algunos métodos se proponen razones y diferencias entre canales, con lo que se atenúan notablemente estos efectos [43]. Siempre se debe considerar cuidadosamente qué tan importante es el color para la aplicación y cómo manejar la adquisición de la imagen en color.

Para las necesidades de inspección industrial, la meta es encontrar características de color que sean rápidas de calcular, proporcionen un nivel de reconocimiento satisfactorio y que se puedan implementar con técnicas baratas. Esto requiere a menudo algunos compromisos en el cálculo de las características, ya que típicamente no se puede extraer y comparar toda la información de color que se desea en los límites de tiempo dictaminados por una aplicación.

Afortunadamente, no se necesita que las características describan todos los detalles de los matices de color. Es suficiente concentrar las diferencias esenciales requeridas para realizar la clasificación de los objetos satisfactoriamente. Por supuesto, los

espacios de color deben contener bastante información de las bandas espectrales conteniendo la información discriminativa que permita diferenciar entre las clases que se estén clasificando. El uso de espacios de color adecuados puede facilitar el reconocimiento o diferenciación entre las clases que se analicen [40-41], por lo que es muy importante tener bien claro qué tipo de información se desea resaltar para realizar el reconocimiento, y con esto seleccionar el espacio de color.

Un requisito importante para las características de color es que estas no deben depender mucho de propiedades diferentes al color, como la intensidad de iluminación y el tamaño o la forma del objeto. Estas propiedades son medidas por otras características, que se combinan después con las características de color en la fase de clasificación de defectos para, a continuación, proporcionar una descripción completa de todas las propiedades necesarias para reconocer el objeto.

La iluminación es de vital importancia en el caso que se deseen hacer análisis cuya base es la información cromática. Las fuentes escogidas para iluminar los objetos se deben escoger de acuerdo a la banda que se desee diferenciar y a la respuesta espectral del sensor. Se debe tener en cuenta que el trabajo con el color no se limita solo a cámaras a color. Es posible registrar esta información con la ayuda de filtros o fuentes de cierta banda del espectro y una cámara de niveles de gris [57], la adición de ciertos dispositivos mecánicos o electrónicos permite el intercambio de estos elementos de manera automática y posteriormente se combinan las imágenes de cada banda para recomponer la imagen en color.

En el caso de la aplicación del color en la inspección automatizada de frutas Aleixos [36] ha obtenido proporciones de clasificación superiores al 95% cuando se usa la información cromática. La mayoría de aplicaciones mejoran prominentemente cuando se adiciona la información del color para la extracción de características, la ventaja es que esto aumenta muy poco la complejidad de los algoritmos, la desventaja es que muchas veces se necesita hardware especializado que soporte mayor intensidad computacional.

2.2.1. Revisión sobre el cálculo de las características de color. Los valores RGB de la imagen digitalizada pueden usarse de varias maneras con el fin de calcular las características para la detección y el reconocimiento. Los valores de los píxeles pueden usarse directamente o se pueden convertir a otros espacios de color [40, 43, 55], ya que pueden ser más adecuados para el tipo de información que se desea extraer, o realizarse estadísticas de sus distribuciones, o sea, pueden calcularse histogramas de regiones de tamaño fijo o segmentadas.

Las propiedades estadísticas de las distribuciones de los canales de color por separado se pueden caracterizar de manera similar al tratamiento que se le realiza a las imágenes en niveles de gris, esto es, con medias, varianzas, sesgados y curtosis, además de puntos de mínimos y máximos globales o locales, por ejemplo. También pueden usarse las medidas de la configuración espacial del color de los píxeles vecinos, o lo que es lo mismo, realizar análisis de la textura en color [39, 40, 58]. A continuación se describen algunas aproximaciones para el reconocimiento y segmentación en color.

Es posible usar características de color basadas en los histogramas RGB normalizados, así como la saturación y el tono calculados de los espacios de color HSI, XYZ, Luv o CIE-Lab [43, 55]. Para áreas coloreadas de manera singular se puede tomar como característica representativa el valor pico de cada histograma de la región.

Es muy común la utilización de relaciones entre diferentes bandas, con lo que se obtienen características que describen de manera sencilla dos o más bandas sólo con un número. Aunque este método disminuye la complejidad, debido a que se disminuye la dimensión del espacio de características, y aumenta la velocidad del reconocimiento, ya que el clasificador tiene que operar con menos datos, esto puede involucrar una marcada disminución en la rata de discriminación entre las clases debida a la combinación de los canales.

Con el método llamado indexado de color por intersección del histograma se calcula el número relativo de píxeles que tienen los mismos colores y se estima un valor de comparación entre un histograma de la imagen desconocida y un histograma modelo. Este método es bastante sensible a las variaciones de iluminación. Para esto se ha elaborado un método mejorado que se trata de un algoritmo de indexado de color basado en la constancia del color [48].

En este se nota que las proporciones de colores son poco sensibles a las variaciones de iluminación debido a que se usan los cocientes de los histogramas de color de los píxeles RGB vecinos en lugar de valores de RGB directos. Las proporciones de color arrojan valores altos en los bordes de dos colores diferentes. De esta manera, la acumulación total en un histograma representa una medida de la longitud del límite entre dos colores específicos.

Para una aproximación a las texturas en color se usan las características estadísticas llamadas inercia, correlación, energía y entropía calculadas de los histogramas tridimensionales y de las matrices de co-ocurrencias de los canales de color R, G y B [22, 38, 39, 58]. La característica energía mide la homogeneidad del histograma y la característica entropía el contenido de información. Estas características son invariantes con la iluminación. La medida para la textura también se puede basar en la transformada discreta coseno de la imagen de niveles de gris de cada banda obtenida de la imagen RGB, como se ha mostrado en los experimentos para el reconocimiento de defectos en frutas [58], clasificación de carnes [10] y otros materiales con propiedades texturales [38, 42].

2.2.2. Constancia del color. La habilidad perceptual del sistema visual humano que permite ignorar la variación espectral de la luz ambiental y asignar colores estables a los objetos se llama constancia del color [48]. Los humanos poseen la propiedad casi perfecta de la constancia del color y por consiguiente no siempre es evidente que un sistema de visión artificial que utilice la información de color no tenga esta propiedad

naturalmente. Lograr la constancia del color es difícil porque las señales de color que alcanzan un sistema de visión dependen de la iluminación, de la reflectancia espectral del objeto observado [43], y de la disposición geométrica de los objetos y detectores.

Las variaciones espectrales de la iluminación pueden causarse, por ejemplo, por las propiedades espectrales cambiantes de una fuente de iluminación, o por alguna fuente de luz inesperada, como la luz del día o la iluminación de fondo. Los cambios de las propiedades espectrales de la iluminación pueden ser a largo o a corto plazo. Los cambios a largo plazo son causados principalmente por el envejecimiento de lámparas o por la acumulación de polvo. Los cambios a corto plazo ocurren dentro de decenas a centenas de microsegundos, y se causan, por ejemplo, por las propiedades físicas del filamento o por los cambios de la corriente de control de las lámparas.

Los algoritmos de constancia de color presentados en la literatura se derivan a menudo de las suposiciones específicas sobre las propiedades de las fuentes de iluminación y las superficies, dando así la constancia del color válida para un conjunto particular de fuentes de iluminación y superficies. La constancia del color sirve como base para realizar una aproximación a la calibración en-línea de la cámara a color, basada en el modelo de la cámara a color. El procedimiento de calibración es dividido en dos fases: la reconstrucción de la fuente desconocida basada en colores de referencia conocidos y la determinación los valores del color (por ejemplo RGB) del objeto por reconstrucción de las reflectancias espectrales o corrigiendo la lectura de la cámara con una matriz de transferencia.

Para el funcionamiento correcto del procedimiento de calibración deben conocerse las sensibilidades espectrales de la cámara, la iluminación debe ser uniforme y se necesitan referencias calibradas de color plano difuso, además, deben conocerse los espectros de reflectancia. La relación para la determinación de nuevos parámetros de calibración de color es gobernada por la proporción de los cambios significativos en la iluminación.

2.3. INSPECCIÓN SUPERFICIAL DE FRUTAS

Las propiedades superficiales de las frutas, desde la perspectiva visual, son importantes para determinar su calidad en la industria alimentaria. La inspección visual de frutas está extensivamente practicada en los centros de post-cosecha tanto de pequeños productores como en empresas de alta producción, en nuestro país se puede decir que casi la totalidad del proceso se realiza de forma manual. Incluso el comprador final realiza la inspección de las frutas que más le agradan visualmente y quien la consume hace una evaluación de la que le parece más jugosa, dulce y de mejor sabor analizando sólo la información pictórica.

Entre los procedimientos de uso común en la inspección superficial aparecen los que usan información visual de la superficie de la fruta, como madurez, tamaño o defectos externos, para localizar y reconocer las propiedades relevantes de la fruta con el fin de resolver el problema de inspección.

Las alteraciones de las frutas, como los hongos, manchas, cisuras, cicatrices, golpes, podredumbres, restos y daños de aves e insectos, decoloramientos y formaciones de granos, afectan la vitalidad, durabilidad y apariencia de la fruta y están directamente relacionadas con la utilidad y el valor comercial. Todas las propiedades que afectan la calidad de las frutas son denominadas defectos a lo largo de este trabajo, aunque en algunos casos se pueden confundir con propiedades deseables, como en el caso de las variaciones en color de ciertos tipos de manzanas y la frecuencia y regularidad de algunas manchas que dan un aspecto agradable a algunas frutas.

Como se ha anotado, la aplicación principal de este estudio es la aplicación de la visión artificial para la inspección visual de frutas con el fin de clasificarlas y realizarles el control de calidad, por lo que el campo del problema se discute más detalladamente en la siguiente sección.

2.3.1. La calidad de las frutas y su importancia a nivel nacional. La fruticultura, junto con la horticultura, han sido consideradas dentro de las actividades agrícolas más promisorias para el país en el contexto de la internacionalización de los mercados. A nivel mundial, los mercados de frutas y hortalizas frescas y procesadas son unos de los más dinámicos del sector agroalimentario [59] y su crecimiento se ha visto favorecido por los cambios en las preferencias de los consumidores, ahora más inclinados hacia alimentos frescos y saludables, por el crecimiento del ingreso per cápita, especialmente en los países desarrollados y por los fenómenos de sustitución y diversificación del consumo, como consecuencia de una mayor liberalización y apertura de mercados, además de los importantes avances tecnológicos en el procesamiento, manipulación, empaque, conservación y transporte.

En Colombia las áreas sembradas en frutas (incluyendo banano) representaron en el año 2000, el 14% del área total dedicada a la agricultura sin café y dieron cuenta del 36% del valor de esta producción en el mismo año. Esto permite destacar la importancia económica y social de la actividad frutícola en el país.

Mientras la producción de banano y plátano, que representan la gran mayoría de la producción de exportación, se ha mantenido relativamente estable durante la última década, la de los demás frutales presenta una tendencia dinámica creciente en el mismo período. A finales de la década pasada, la demanda industrial de frutas frescas alcanzó un volumen superior a las 70.000 toneladas, además de las 17.700 toneladas de frutas con algún grado de procesamiento. Las principales frutas cultivadas en el país son: cítricos, guayaba, mango, piña, aguacate, patilla, tomate de árbol, mora y papaya.

Colombia se convirtió en el principal exportador mundial de plátano a la Unión Europea y a Estados Unidos, pero, en general, la actividad exportadora de frutas diferentes al grupo de bananos y plátano presentó una fuerte caída a partir de 1991 y apenas empezó a recuperarse en 1998, apoyada en una tasa de cambio más favorable. Los principales destinos actuales de la fruta colombiana son la Unión Europea (57%),

4Estados Unidos (20%) y la Comunidad Andina (10%). En orden de importancia, se destacan las exportaciones de uchuva, naranja, granadilla, tomate de árbol, mangos y pitayas, así como las de los jugos de maracuyá y mango [60].

Es muy importante lograr gestionar la entrada de frutas frescas colombianas en mercados de tanta importancia como Estados Unidos, para productos tropicales como los colombianos, que tienen un mercado potencial inmenso. Aunque los pronósticos parecen buenos para los países en desarrollo, los exportadores deben estar conscientes de que el mercado internacional es extremadamente competitivo y que no siempre es técnicamente posible ni económicamente factible construir nuevas instalaciones de producción o aumentar las existentes con fines de exportación [59]. Esto impone retos relacionados con la gestión de la sanidad y la calidad de estos productos, así como en el desarrollo tecnológico.

En este sentido es preocupante que existan debilidades graves en los procesos industriales; entre éstos se pueden mencionar algunos que son debidos a factores como las calidades desiguales del producto y la escasa calificación de tecnología humana, entre otras. También se puede mencionar la reducida oferta tecnológica y la poca experiencia en el manejo post-cosecha [60]. Para suplir en parte este tipo de debilidades, se requieren trabajos como el que se presenta en este documento; con lo que se trata de mantener, hasta donde sea posible, la sanidad y/o calidad del fruto, evitando las pérdidas que pueden ocurrir debido al procesamiento, manejo, transporte y almacenamiento inadecuados.

Así, el objetivo general es normalizar los productos agrícolas dentro del concepto de que la norma nacional sea equivalente a la norma internacional, con el fin de lograr una homogeneidad en la calidad y, así, facilitar el manejo, conservación y comercialización de los productos.

Es de anotar que Colombia tiene los volúmenes de exportación de frutas y hortalizas más pequeños en Latinoamérica. Pero es un país grande, con mucha tierra cultivable

altamente productiva, temperatura uniforme en todo el año, que implica que tiene tierra utilizable para cultivar determinados productos que van a atender un mercado específico independiente de la época del año en que el mercado los requiere. Los productos con mayor potencial de exportación en Colombia son los cítricos, espárragos, frambuesa, mora, pimentón, melón, tomate de mesa, aguacate y piña. [61].

2.3.2. Evaluación de la calidad de las frutas. La industria frutícola es una actividad comercial importante en muchos países como Estados Unidos, la Unión Europea, Asia y la Comunidad Andina. Las grandes compañías deben elaborar planes para establecer el aseguramiento de la calidad de sus productos, para esto, por lo general se coloca el producto en bandas transportadoras y los inspectores se encargan de verificar ciertos aspectos del fruto para determinar el tipo de clasificación que se le dará.

Para una fruta dada se revisan aspectos relativamente específicos con los que se determina su clasificación, esto se puede ver claramente en la tabla 2. Es evidente que el aspecto primario para la clasificación es el tamaño o las dimensiones de la fruta, directamente relacionadas con el peso. Sin embargo no dejan de tener importancia la maduración y el contenido de defectos sobre la cáscara. Todos estos aspectos son cuantificables de manera confiable con un sistema basado en las tecnologías ofrecidas por la visión artificial.

Los requisitos de producción para la venta del producto fresco en los almacenes de cadena son bastante exigentes, por ejemplo Cadenalco tiene porcentajes de pérdidas es de 0.01% porque realiza las compras del producto, lo selecciona y clasifica visualmente, teniendo en cuenta el tamaño, la turgencia y la presentación y los sobrantes se devuelven al proveedor [62], así que las pérdidas recaen directamente sobre el productor.

Tabla 2. Procesos de selección y clasificación de algunas frutas

FRUTA	Proceso de Selección y Clasificación
Mango	Se clasifica manualmente por variedades y con tamaños y grados de maduración similares. Los tipos de la fruta se determinan de acuerdo al contenido de manchas debidas a hongos (antracnosis), arañaduras, abolladuras y otras manchas.
Durazno	Se clasifica de acuerdo al tamaño, deben estar completamente sanos, o sea, que no tengan hongos, ni presenten cuarteamiento. Cuando los frutos están afectados por problemas fisiológicos como picaduras de pajaros, cuarteamiento, y leves afecciones de hongos se destinan al uso industrial.
Tomate de Árbol	El proceso se realiza a mano en una banda transportadora con un grado de madurez de 1/2 a 3/4, un diámetro mínimo de 45 mm y longitud mínima de 60 mm.
Curuba	El diámetro mínimo es de 35 mm y la longitud mínima es de 6 mm. Se busca que el producto en la caja este completamente sano, con tamaño y color homogéneos.
Granadilla	Se realiza a mano en una banda transportadora con un diámetro mínimo de 60 mm y un peso mínimo de 80 gr, se observa que la fruta esté completamente sana y sea homogénea en tamaño y madurez.
Lulo	Se realiza a mano con guantes en una banda transportadora, con un diámetro mínimo de 45 mm; buscando un color y tamaño homogéneos en las cajas que se empaquen, la selección debe ser estricta con respecto a sanidad y presencia de daños mecánicos.
Manzana	Similar al durazno
Naranja, Maracuyá, Banano, Guayaba, Pera, etc.	Se realizan procesos similares en una banda transportadora, donde, por lo general de manera manual, se clasifican de acuerdo al tamaño, madurez y contenido de defectos y daños externos.

Fuente: Este estudio.

En el caso de Corabastos, las frutas y hortalizas son las que presentan mayores pérdidas. A corabastos en total entran entre 80 y 90 toneladas diarias de alimento, el 85 a 90% es material orgánico. Las pérdidas post-cosecha en el caso de las frutas son del 12,45% [63]. Esto representa millones de pesos en pérdidas, que se dan principalmente por el embalaje poco adecuado, ya que por lo general se empaquen frutas de tamaños y calidades diferentes en los mismos compartimentos, conllevando las consecuencias mencionadas.

Por lo tanto, es muy importante que los productores implementen sistemas eficientes de aseguramiento de la calidad para minimizar las pérdidas en el caso de las

devoluciones. Los grandes productores tienen el inconveniente de tener que manejar miles de toneladas en períodos de tiempo limitados, por lo que el aseguramiento de la calidad suele ser complejo y costoso.

Controlar la calidad de altos volúmenes de producto necesita generalmente grados altos de automatización y es un proceso que puede empezar desde que se recolecta la fruta para eliminar objetos extraños como hojas o ramas, pasando por la clasificación como tal, y finalmente verificando la posición y numeración correcta de los productos empacados que están listos para distribución. Éstos incluyen numerosos sistemas de transporte para las frutas, así como el manejo de sistemas para los productos secundarios, si los hay, como productos rechazados y cáscaras.

En la evaluación de la calidad de las frutas, la inspección visual es uno de los procedimientos más importantes para el establecimiento de su clasificación. Además, aspectos como la firmeza, acidez, contenido de azúcar, gases emitidos, entre otros, también afectan la clasificación. Sin embargo después de la inspección visual al producto se le ha agregado un alto valor, por lo que si se desean analizar los otros aspectos, será un proceso menos complejo y costoso ya que, por lo general, una fruta que se ve externamente bien, reflejando su estado global, está internamente sana.

2.3.3. Reglas para la evaluación de la calidad en frutas. En el examen final de clasificación, las frutas se dividen en varias clases de calidad basadas en sus propiedades visuales. Las clases diferentes tienen uso y valor diferentes en los procesos siguientes. Las frutas de mejor calidad se usan, por ejemplo, para la venta directa, mientras que las de calidades inferiores son útiles para extracción del zumo, mermeladas y conservas si están internamente intactas.

La clasificación se realiza de acuerdo a las reglas de clasificación. Hay muchas reglas y normas de clasificación del producto. Para la clasificación se pueden tener varias alternativas, dependiendo las reglas que se deban cumplir de acuerdo a las disposiciones legales, las posibilidades del productor y las exigencias del consumidor.

Así entre las alternativas se pueden enumerar: (1) Según los estándares oficiales de clasificación; (2) de acuerdo a las reglas del personal de clasificación (reglas propias), principalmente basadas en las reglas oficiales; y (3) según las clases de calidad del cliente.

En el caso de los cítricos, de acuerdo a la reglamentación colombiana, los requisitos generales para la presentación y comercialización son [64]:

- Se debe tener en cuenta que los frutos estén enteros
- Deben tener la forma característica de la variedad
- Deben presentar cáliz
- Deben estar sanos (libres de ataques de insectos y/o enfermedades que demeriten la calidad interna del fruto)
- Deben estar libres de humedad externa anormal producida por el mal manejo en las etapas de post-cosecha (recolección, acopio, selección, clasificación, adecuación, empaque, almacenamiento y transporte)
- Deben estar exentos de cualquier olor o sabor extraños (provenientes de otros productos, empaque o recipiente y/o agroquímicos, con los cuales haya estado en contacto)
- Deben presentar aspecto fresco y consistencia firme
- Deben estar exentos de materiales extraños (tierra, polvo de agroquímicos y cuerpos extraños) visibles en el producto o su empaque
- El contenido de cada unidad de empaque debe ser homogéneo y estar compuesto únicamente por frutos del mismo origen, variedad, categoría, color y calibre. La parte visible del empaque debe ser representativa del conjunto.

Lo que se busca en últimas es una **norma de homogeneidad** que depende del producto, la variedad, el clima y la empresa agrícola. Sin embargo existe un común denominador que se refiere básicamente a la salud del producto, que luego repercute directamente en la salud del consumidor. En Colombia no existe un acuerdo generalizado de homogeneidad en las normas y esto impide que los productos

nacionales sean competitivos, con lo que no logran un valor comercial adecuado y seguramente serán rechazados en los mercados internacionales.

Las reglas de clasificación consisten típicamente en los criterios de clasificación, como las definiciones de localización, el máximo tamaño permitido, y el número y tamaño de los defectos en cada clase de calidad. Sin embargo, no se han diseñado reglas de clasificación para que un inspector humano las siga al pie de la letra. Los clasificadores humanos pueden usar las reglas adaptivamente, y tienen en cuenta la calidad global de la fruta. Esto significa que para un humano los límites de las clases de calidad no son absolutos.

Para un computador, es más importante el contenido exacto de los criterios de clasificación. La adaptabilidad del clasificador humano no se incorpora naturalmente, o de una manera directa, en un computador, que obedece estrictamente las reglas de clasificación dadas para ciertas frutas. La adaptabilidad puede ser incluida en una máquina, pero requiere reglas que expliquen como se debe cumplir esto.

En este caso son muy importantes los conceptos introducidos por los enfoques que dan las redes neuronales o los algoritmos basados en la lógica difusa, en donde las reglas no están descritas completamente y son sistemas capaces de operar con información incompleta o difusa. Esto, debido a que este tipo de sistemas están inspirados en la forma como se desempeñan los seres vivos. Últimamente están en creciente apogeo las aproximaciones neurodifusas donde se introducen los conceptos de las dos disciplinas, consiguiéndose implementar sistemas de gran adaptabilidad y excelente desempeño.

2.3.4. Propiedades de las frutas. Como se sabe, hay tantas variedades de frutas que es imposible dar aproximaciones de las propiedades que las describan a todas de manera general. Incluso si se trata de las variedades más comerciales es difícil brindar un descriptor adecuado, la multitud de formas, tamaños, colores y texturas lo impiden. Por esto un sistema automatizado de inspección basado en visión que se encarga de

clasificar un tipo de fruta debe reconfigurarse casi completamente, desde la etapa de iluminación y adquisición de la imagen hasta los mecanismos de manipulación, al tratar de aplicarlo a otras frutas.

Esta es una de las dificultades que hacen que los sectores interesados en la automatización con la ayuda de la visión por computador se muestren renuentes a adquirirlos. Aparentemente los sistemas son poco versátiles y en poco tiempo se vuelven obsoletos. Precisamente en esto se ha estado trabajando en los últimos años, se busca que el operador sea capaz de establecer los parámetros de relevancia para el objeto inspeccionado y los modifique en el sistema para que opere adecuadamente, esto sin necesidad de recurrir a los ingenieros que realizaron el diseño para que establezcan las nuevas rutinas de bajo nivel que necesitaría el sistema.

Como primera aproximación, las configuraciones, medidas y análisis realizados durante este trabajo de investigación están orientados básicamente al sector de los cítricos. Esto tratando de que el sistema pueda ser de interés a un amplio rango de productores y procesadores del sector debido a que estos representan el ramo más amplio del mercado de frutas a escala global, los cítricos representan el 20% de la producción de las frutas más comercializadas [2, 60] y, de acuerdo a las estadísticas de la FAO, América Latina y El Caribe producirá para el año 2005 un 32% del total mundial de cítricos; en el departamento del Cauca se producen anualmente alrededor de 1700 toneladas de cítricos; esta cifra es baja pero pueden representar una oportunidad que se podría explotar ya que muchos países, principalmente de la Unión Europea, tienen crecientes déficits en la disponibilidad de estas frutas.

Por otra parte, las propiedades intrínsecas de las naranjas ofrecen, por ejemplo, variables de medición y análisis relativamente menos complejas que en otras frutas, cuestión importante debido a que este trabajo representa uno de los primeros acercamientos de la visión artificial a la inspección de frutas en nuestro país. Un trabajo futuro podría contemplar el establecimiento de métodos para muchos más productos, incluso diferentes a las frutas, como se ha detallado anteriormente.

Sin embargo, las bases sentadas durante el desarrollo de este trabajo facilitarán la aplicación en este y en otros sectores, ya que la arquitectura de los sistemas de inspección visual es bastante genérica. Así que esto es un buen precedente para el establecimiento de aplicaciones que interesen principalmente a las industrias que procesen sus productos en forma masiva.

De acuerdo al tipo de fruta, es posible el establecimiento de diferentes clases para la clasificación. Normalmente, las propiedades visuales más importantes de las frutas, después del tamaño, son el color, la textura y los defectos externos. Estas se encuentran entre las propiedades que un sistema de inspección automatizado debe reconocer de las superficies de las frutas. En el caso de los defectos externos, es deseable que se cuantifique su cantidad, tamaño y distribución.

Además de las propiedades visuales de las frutas, la localización de estas puede afectar el establecimiento de la clase en que se establecen. Para un sistema de visión artificial esto, en principio, no debe constituir un problema, ya que la información del reconocimiento acerca de la localización puede usarse para decidir la clase final. Sin embargo, cuando se colecta el material de entrenamiento para el sistema de visión artificial, se debe tener cuidado al etiquetar las clases. Si la información de la localización no se usa en la recolección del material de entrenamiento, un defecto debe etiquetarse según sus propiedades visuales, por ejemplo, mancha, cisura o golpe.

En la tabla 3 se reúnen algunas de las propiedades más significativas de los cítricos, referentes a su contenido de defectos externos, y las observaciones de la dificultad para la detección y reconocimiento a través de los métodos de la visión artificial. La evaluación de la importancia y dificultad es basada tanto en la opinión subjetiva como en los experimentos hechos en las investigaciones del caso.

Tabla 3. Propiedades de las frutas y su dificultad para la detección automática

TIPO DE DAÑO	SÍNTOMAS	DIFICULTAD PARA LA DETECCIÓN
<i>Manchas</i>	<ul style="list-style-type: none"> ↪ Manchas oscuras distribuidas aleatoriamente en la superficie ↪ Manchas pardas, verdes o azules oscuras ↪ Lesiones y necrosis pardas y oscuras 	Si las manchas por lo general son oscuras, sin importar el canal en el que estén, es relativamente fácil detectarlas ya que estas zonas se ubican en la parte baja de los niveles de gris. La cuestión es si tienen el tamaño adecuado a los parámetros del sistema. En este caso el análisis es centrado en cuantificar los defectos y determinar, si es posible, el patrón de distribución sobre la superficie.
<i>Cicatrices</i>	<ul style="list-style-type: none"> ↪ Manchas grises, plateadas o pardas de contornos indefinidos ↪ Hendiduras de varias profundidades 	Algunas cicatrices sanan relativamente bien, por lo que la zona toma el mismo color que la piel sana, en este caso es difícil detectarlas, teniéndose muchas veces que enfrentar con enfoques bastante sofisticados.
<i>Moteado</i>	<ul style="list-style-type: none"> ↪ Manchas puntuales pequeñas de color oscuro, por lo general decoloradas periféricamente 	El tamaño de las manchas puntuales determinan la resolución mínima del sistema, por lo que la dificultad no está en su detección a nivel digital sino en si el sistema de adquisición de imágenes es capaz de resolver estos defectos. Las decoloraciones por lo general representan dificultades, pero aquí entra en juego el juicio que dé un experto clasificador.
<i>Clareta</i>	<ul style="list-style-type: none"> ↪ Rugosidad de la cáscara manifestada como surcos y estrías distribuidas irregularmente 	Quizá este es el caso que presenta más dificultad para la detección debido a que no hay variación en el valor de color sobre las zonas afectadas. Generalmente es necesaria la aplicación de análisis de texturas, pero puede representar un notable incremento en los requerimientos de poder computacional.
<i>Daños no visibles</i>	<ul style="list-style-type: none"> ↪ Golpes que provocan lesiones que no se manifiestan visualmente de inmediato ↪ Rupturas tempranas superficiales de la piel ↪ Separación entre la piel y la pulpa (bufado) 	Si a un humano le queda difícil detectar estos daños sin palpar la fruta, es prácticamente imposible que una máquina lo pueda hacer. Sin embargo si se usan sensores y sistemas de iluminación especiales, de operación fuera del espectro visible, es posible que los defectos se manifiesten y se puedan cuantificar. Por ahora, no hacen parte de los defectos que se pretenden cuantificar con este sistema.

Fuente: Este estudio

No se incluye los referente a la decoloración por maduración no uniforme, que aunque hace parte de los defectos en muchas frutas, no es un caso muy común en los cítricos, además estos análisis complican un poco el panorama debido a que los requerimientos en la iluminación y en la definición de las cámaras son altamente exigentes.

Se estima que la detección y el reconocimiento son independientes. Para realizar el reconocimiento, se supone que la detección ha tenido éxito. Por ejemplo, algunos defectos no tienen propiedades de color que permitan diferenciarlos de la superficie sana, por lo que es difícil detectarlos, pero su forma y textura circundantes suelen tener importancia en este caso. Por otro lado, cuando se detecta con éxito, el reconocimiento es relativamente fácil porque este tiene un color diferente al de otros defectos.

Los golpes son difíciles de detectar, ya estos son encontrados a menudo sólo después de unos días de evolución o por inspección de contacto. Las cisuras, rayones y algunas marcas de insectos son complejos de detectar porque pueden necesitar alta resolución en la toma de las imágenes, y estas no poseen propiedades especiales referentes al color. La clareta en los cítricos también representa dificultad, ya que es estrictamente una propiedad textural. Debido a la alta variabilidad de la superficie de las frutas, incluso tratándose de la misma especie, puede ser difícil encontrar un modelo para la tal textura, aunque algunos modelos funcionan proporcionando un primer acercamiento para su reconocimiento [58].

Los defectos relacionados con el color, como la maduración no uniforme, algunos hongos y parásitos son difíciles de detectar debido a que este tipo de daños no posee límites bien definidos. Sin embargo, una vez detectados, las distintas propiedades de color ayudan en el reconocimiento.

Los daños que se pretende cuantificar con el sistema son los que están relacionados directamente con su aptitud para ser identificados por métodos ópticos,

específicamente los que están basados en detectores sensibles a la energía electromagnética reflejada en la zona del espectro visible. Otras aproximaciones pueden ser diferentes en el enfoque si usan zonas aledañas al espectro visible o si pretenden medir parámetros diferentes a los tratados aquí, estos son útiles para la detección de los daños no visibles.

Así, las propiedades referidas aquí son exclusivamente las referentes a las propiedades externas medibles con la interacción de la luz denominada visible. Con lo que se miden solo los defectos que presentan una manifestación externa de sus síntomas y que son visibles para un ser humano.

2.4. EL DESARROLLO DE LOS SISTEMAS DE INSPECCIÓN AUTOMATIZADA DE FRUTAS

Los sistemas de inspección automatizada basados en información visual son diseñados principalmente para aplicaciones mecánicas y electrónicas, su introducción en otros campos está siendo fuertemente limitada por la necesidad de operación en ambientes no controlados y por la carencia de una definición precisa de la tarea de inspección [9]. El uso de estos sistemas en la industria de alimentos es de interés primario, por lo que se invierten actualmente inmensos esfuerzos en programas I+D al respecto [23].

En este sentido, la factibilidad de la inspección automática de productos alimenticios por medio de técnicas de visión artificial aún no ha sido investigada en profundidad. De hecho, en este caso, el diseño de los sistemas de visión es más difícil de lo normal, ya que usualmente los alimentos se distribuyen como objetos 3D irregulares, con una forma y tamaño aleatorios, obteniéndose imágenes que no se pueden manipular con la ayuda de técnicas tradicionales basadas, por ejemplo, en segmentación, comparación de plantillas o modelamiento rígido [9].

Así mismo, como se ha notado, las altas velocidades de producción exigidas por los procesos modernos de manufactura de los alimentos no se pueden alcanzar por

inspección manual, que en muchos casos solo puede asegurar la inspección de un bajo porcentaje de la producción. Los primeros intentos de aplicación fueron sobresimplificados, por lo que cubrieron solamente un pequeño número de aplicaciones debido a que, en la mayoría de los casos, el proceso de inspección es mucho más complejo que la simple umbralización de algunas características.

Este momento es adecuado para el desarrollo de sistemas de inspección automatizada en aplicaciones alimentarias por la maduración tecnológica alcanzada. La simplicidad de los primeros trabajos impidieron la aplicación directa en ambientes complejos y no estructurados. Como se ha dicho, particularmente la naturaleza de los objetivos y la necesidad de definiciones precisas de las tareas de inspección han impedido la aplicación de pleno de las herramientas que brinda la visión artificial en el campo alimentario [27].

Por su naturaleza, el sector de los alimentos está estrechamente relacionado con la agricultura, que brinda muchas aplicaciones potenciales para tareas de automatización por medio del análisis de imágenes. Hay muchos procesos en estos sectores donde la tomas de decisiones se basan en la apariencia del producto, pudiéndose determinar qué tan saludable o enferma se encuentra una fruta, por ejemplo.

Los humanos pueden fácilmente desarrollar tareas tan intensivas como el cosechado, el podado y la clasificación usando básicamente su sistema visual. Esto sugiere que un sistema basado en un sensor visual podría emular el proceso de interpretación del sistema de reconocimiento visual humano. El sentido de la vista puede proporcionar, con una simple ojeada, una gran cantidad de información acerca del entorno, de aquí que, aunque la visión es una actividad que aparentemente no supone esfuerzo alguno para los humanos, para las máquinas supone un problema muy complejo, sobretodo si se trata de operación en condiciones no controladas [34].

Para los alimentos producidos en agricultura se han establecido básicamente dos áreas principales de aplicación de la rama de la visión artificial denominada análisis digital

de imágenes: herramientas de investigación y toma de decisiones [13], como se describe en la figura 4.

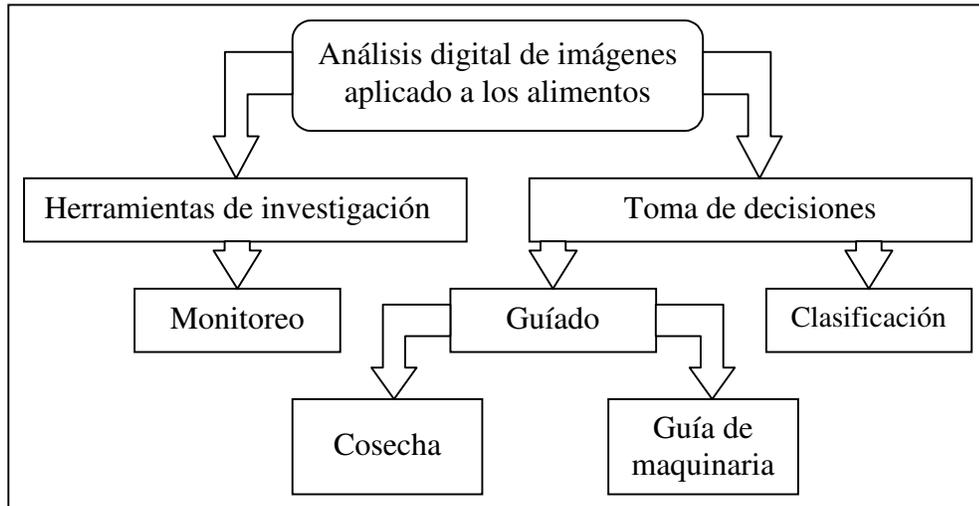


Figura 4. Áreas de los sistemas de análisis digital de imágenes aplicados al procesamiento de los alimentos

El área correspondiente a las herramientas de investigación está relacionada con aplicaciones para el monitoreo del crecimiento de plantas, morfometría de nuevos cultivos o conteo de células biológicas. Este tipo de herramientas permite la obtención automática de los datos a los investigadores, el usuario monitorea el desempeño del sistema y puede intervenir cuando malinterprete una imagen. Las herramientas permiten que las características sean medidas automáticamente, ya que manualmente tomarían mucho tiempo.

En la toma de decisiones se provee información para guiar equipos mecánicos y tiene básicamente dos grupos de aplicación: clasificación y guiado. El procesamiento digital de imágenes se aplica a muchos productos con el fin de clasificarlos, se han realizado investigaciones aplicándolo a varios tipos de frutas, como se realiza en este trabajo. La toma de decisiones para el guiado incluye la cosecha de frutas que van desde tomates y naranjas hasta melones, e incluso recolección de champiñones.

También se enfoca en la navegación de vehículos robotizados usando las estrategias de la visión artificial con el fin de obtener capacidades de movilidad autónoma.

Con todo esto, las técnicas usadas en las aplicaciones nombradas son exitosas bajo condiciones restringidas para las que fueron diseñadas, de aquí que típicamente los algoritmos no son útiles directamente en otras aplicaciones. En principio, los computadores son flexibles debido a que pueden ser reprogramados. Pero en la práctica es difícil correr los algoritmos de visión artificial en una aplicación levemente diferente debido a las suposiciones para lograr la robusticidad y velocidad de una aplicación dada.

Se han presentado aproximaciones iniciales con algunos sistemas comerciales y experimentales de inspección visual de frutas [11-17, 27]. Estos dispositivos han tenido un éxito relativo, y la ayuda de enfoques modernos de los algoritmos de clasificación les ha permitido tener ratas de efectividad superiores al 90%. La implementación en procesos que requieren altas velocidades es posible debido a la implementación en hardware de los algoritmos de procesamiento de imágenes mediante procesadores digitales de señal (DSPs, por sus siglas en inglés).

El resultado realmente palpable del trabajo realizado en el ámbito global sobre la inspección automatizada de frutas es que se han desarrollado herramientas adecuadas para discriminar entre diferentes tipos de frutas. Esto se basa en el establecimiento de los factores importantes en la industria de la fruticultura como son las variaciones durante el desarrollo de la fruta que pueden afectar su composición, madurez y demás atributos mientras se procesa, manipula o almacena.

2.4.1. Aproximaciones basadas en cámaras. Las aproximaciones basadas en cámaras usan cámaras de niveles de gris o a color para la adquisición, normalmente miden la luz reflejada a las longitudes de onda visibles y la convierten en el valor de nivel de gris o en los tres componentes de color: rojo, verde y azul.

Las características usadas en los diferentes acercamientos basadas en cámaras para la inspección de frutas pueden ser divididas en las categorías siguientes:

- Las basadas en las características sobre los valores de los píxeles planos
- Las estadísticas de los valores de los píxeles
- La geometría de los objetos segmentados
- La textura
- La información estructural en los objetos.

Las características basadas en los valores de los píxeles planos son los valores del componente de nivel de gris o de color obtenidos de la cámara o de alguna conversión hecha con estos. Las estadísticas de los valores de los píxeles incluyen las medidas estadísticas de primer orden de varios píxeles, como media, varianza, asimetría o sesgado, curtosis, percentiles del histograma y muchas otras medidas sin tener en cuenta las relaciones espaciales entre los píxeles. Las características basadas en la geometría son las dimensiones, el área de la región, la relación de aspecto, la longitud del límite y la curvatura del límite, por mencionar algunas.

Las características de la textura son basadas en las relaciones espaciales entre algunos elementos primitivos de cierta región de la imagen, por ejemplo, las propiedades tonales. Las estadísticas de segundo o más alto orden, por ejemplo, la relación de dos o más píxeles u otros elementos dentro de la imagen son características de la textura. Las características estructurales contienen información de cómo se relacionan los objetos entre sí, por ejemplo, sobre, dentro de, cerca del borde, etc.

Es atractivo usar áreas rectangulares de tamaño fijo no solapadas para la detección y reconocimiento de defectos debido a la simplicidad de la aproximación. También ofrece posibilidades porque el proceso es de fácil paralelización, lo que mejoraría el desempeño de los algoritmos implementados en hardware. La aproximación general consiste en dividir la imagen en regiones de, por ejemplo, 64x64 píxeles, se calculan

las características para cada una de las regiones, y se clasifican como regiones de piel sana y posiblemente defectuosa o como otros tipos de defectos.

Las características usadas en las aproximaciones de áreas de tamaño fijo pueden incluir: las estadísticas de primer orden, como la media, varianza, asimetría y curtosis, las características de la textura basadas en la matriz de co-ocurrencia [58], las características morfológicas y los valores de color, las mediciones de los parámetros de la textura, mediciones sobre los histogramas de color, entre otras.

Las aproximaciones basadas en segmentación intentan extraer las regiones defectuosas basadas en sus diferencias con las frutas de piel sana. Después de la segmentación, la aproximación es similar a la clasificación de área fija: se calculan las características de las regiones y son clasificadas. La mayoría de las aproximaciones de segmentación se basan en el umbralizado o en el umbralizado adaptivo de la imagen usando niveles de umbral sencillos o múltiples o diferencias del vector de color RGB.

Ya que la segmentación da la forma para los defectos, las características geométricas denotan la forma y localización de estos y se usan en la mayoría de las aproximaciones para el segmentado. También se pueden usar las estadísticas de primer orden de los niveles de gris, las relaciones mutuas de regiones y los percentiles del histograma de color. La clasificación de las características en las aproximaciones de área fija y de segmentado pueden ser realizadas por un clasificador bayesiano un clasificador de mínima distancia, un clasificador de árbol compuesto, un clasificador de distancia de Mahalanobis, un clasificador cuadrático un clasificador k-NN o una red neuronal, entre otros [65].

Las aproximaciones citadas usan los métodos de reconocimiento estadístico de patrones. Aunque existen también métodos sintácticos pero no se aplican en este trabajo, ya que en este caso lo que se busca no es identificar los tipos de defectos sino agrupar las frutas de acuerdo a su grado de similaridad.

2.4.2. Aproximaciones basadas en sensores especiales. Con la radiación visible solo es posible inspeccionar lo concerniente a la superficie del objeto inspeccionado. El interior permanece oculto a este tipo de radiación ya que esta se absorbe por completo en las primeras capas de la superficie. Con la utilización de radiación de otras zonas del espectro como UV y Rayos X, es posible “ver” el interior de la fruta, ya que, de acuerdo a la frecuencia de operación, es una radiación penetrante. Esto lógicamente requiere la utilización de sensores especiales que encarecen estos sistemas, de tal manera que se vuelven poco factibles desde el punto de vista tanto técnico como económico.

Por otro lado, la utilización de radiación ionizante hace que los sistemas de inspección ingresen en la zona de las pruebas destructivas de análisis, resultando en alteraciones en mayor o menor grado del producto que se investiga. Esto constituye un grave problema a la aplicabilidad y conveniencia de los sistemas que operan en estas zonas espectrales.

Un enfoque más práctico se da al examinar puntualmente las propiedades superficiales de la piel de la fruta, tales como reflectancia y transmitancia. En estos casos no se examina la totalidad de la fruta sino que se eligen algunos puntos y se toman las medidas, se analizan y se toman las decisiones. Por lo general el punto escogido es cercano a la zona ecuatorial del fruto. Este método es extremadamente barato pero ofrece muchas desventajas debidas principalmente a la simplicidad del sistema: solo se analiza un punto de la fruta, si esta zona posee propiedades especiales, la fruta será clasificada como tal.

2.5. USO DEL COLOR EN LA INSPECCIÓN DE FRUTAS

La importancia de color en la inspección de frutas es obvia. Los humanos pueden realizar tanto la clasificación como el procesamiento basados solamente en la entrada de información de color al sistema visual. Esto ha sido notado por los grupos de

investigación: muchas de las aproximaciones de inspección de frutas usan la información de color, tanto de una cámara a color como de instrumentos de medición espectral como un espectrómetro de imagen [6, 17, 39, 41, 58, 66].

Las medidas de las propiedades de muchos de los defectos en las frutas muestran que algunos de estos tienen propiedades de color características y, por medio de estas, se consigue valiosa información para la detección y la clasificación de los defectos. Las diferencias más importantes en los defectos de las frutas yacen en el rango visible y en las regiones cercanas a este. El infrarrojo cercano es importante para algunos tipos de defectos y el ultravioleta permite detectar daños subsuperficiales.

Muchas investigaciones han abordado la conveniencia de los modelos de color RGB y HSI para representar las diferencias de color de los defectos de las frutas [1-2, 36]. Algunas concluyen que las cámaras RGB son insuficientes para capturar todas las características espectrales significativas de la superficie de las frutas y que se debería considerar un número extendido de canales de color, de esta manera se podría encontrar que el mayor contraste de algunos defectos permitiría diferenciarlos más fácilmente que en el espacio RGB. De acuerdo a esto, la detección de otros defectos requiere datos del dominio multiespectral, pero el interés de este estudio es el espectro visible, que es el campo de dominio de los humanos, los demás son sistemas de mayor sofisticación que no son necesarios, en principio para esta aplicación.

Las aproximaciones ordinarias basadas en cámaras a color todavía tienen una posición prominente en las aplicaciones de inspección de superficies de muchos productos. Entre los problemas encontrados con las aproximaciones multiespectrales están la enorme cantidad de datos producida y el procesamiento requerido, además de los requisitos de alta intensidad de iluminación. Las aproximaciones para la clasificación en color más extendidas son centradas en los píxeles, o sea, se usa la información espectral de un solo píxel para clasificarlo en las categorías de defectos [1-2]. Si se utiliza la información de color de varios píxeles, entonces el volumen de

información se aumenta aunque se usen menos canales, por ejemplo, los de color RGB.

Para concluir este capítulo es importante tener en cuenta que la suposición en la fase de desarrollo del método es que la iluminación es suficientemente constante para el desarrollo y el análisis de desempeño del sistema, debido a esto la relevancia de una cámara de iluminación adecuada, como la que se diseñó y construyó.

Se presentaron las reglas para la clasificación de frutas, debido a que la aplicación de este estudio es encaminada hacia el diseño de un sistema de clasificación y control de calidad de frutas. Empero, esto no limita el alcance de los métodos desarrollados que se presentan en este trabajo, ya que los principios generales son los mismos sin importar el sector de aplicación.

A menudo, hay una contradicción entre las reglas de clasificación exactas del computador y la clasificación humana. Un clasificador humano no tiene el tiempo, ni capacidad y tampoco la posibilidad de registrar todos los defectos en las grandes cantidades de frutas. La clasificación es probablemente basada en una apreciación global de las frutas, teniendo los defectos más vistosos (con mayor contraste) la mayoría de la influencia sobre la calidad predicha por el humano.

Una revisión de la literatura muestra que aunque muchos investigadores reconocen la importancia del color, existen pocas aproximaciones para la aplicación en tiempo real de los sistemas de reconocimiento de defectos de frutas basados en color. Hay una gran necesidad de tiempo real de los métodos que consiguen información a partir del color. En este estudio se trata lo referente a la detección y reconocimiento basados en la información del color pero el objetivo de este trabajo no es el desarrollo de un sistema que opere en tiempo real, aunque pretende dejar unas bases consistentes para futuros desarrollos a este respecto.

3. DESARROLLO Y DESEMPEÑO DEL MÉTODO

No existe una guía que describa paso a paso el desarrollo de un método de inspección visual. La falta de flexibilidad de las estrategias de diseño es una limitación importante en la forma en la que se producen sistemas de inspección visual [26]. Como no hay *know-how* científico sobre el diseño de sistemas de inspección, por lo general es mejor basarse en sistemas en los que se ha comprobado la efectividad. La falta de estudios completos de sistemas de inspección con visión artificial es un factor importante que influye en la manera como se progresa en esta área. Las razones de estas limitaciones son el secreto industrial, o sea, los factores de ganancia que esto implica, y la política de las publicaciones para la literatura científica.

Es también difícil encontrar metodologías para analizar el desempeño de sistemas de inspección visual. Pocos de los algoritmos publicados presentan la caracterización del desempeño como se ha establecido en la literatura de investigación [7, 17-18]. Esto es preocupante para los ingenieros cuyo trabajo es diseñar e implementar sistemas de análisis de imágenes o de visión artificial. Así, los diseñadores no cuentan con un precedente confiable que les permita tomar decisiones precisas acerca de los algoritmos y el hardware que se emplearán en la aplicación.

A pesar de esto, lentamente se están desarrollando algoritmos de evaluación empírica como un subcampo serio en la visión por computador [66]. De esta manera, están empezando a emerger casos de estudio de varias áreas de aplicación sobre los métodos de desarrollo y análisis, con lo que se están emplazando las bases para desarrollar prácticas y métodos adecuados para evaluar los algoritmos.

En esta sección se presentan las prácticas de desarrollo del método de inspección implementado en este trabajo y el análisis de desempeño correspondiente. La parte

inicial trata sobre los aspectos generales de desarrollo del método para el sistema. Se presenta un ambiente de software, y en la parte final se considera la evaluación de los sistemas de inspección visual. Se presenta una aproximación para determinar el desempeño de la detección y el reconocimiento de defectos. La aproximación es adecuada para evaluar otras aproximaciones similares de detección y reconocimiento de defectos.

3.1. AMBIENTE PARA EL DESARROLLO DEL MÉTODO DE INSPECCIÓN

La figura 5 ilustra el modelo del ambiente para el desarrollo del método de inspección visual de las propiedades superficiales de un objeto. El proceso de desarrollo de método requiere combinar el conocimiento de la aplicación con la habilidad de un experto investigador y un experto en el sistema. Hipotéticamente, estas áreas especiales pueden ser divididas en tres grupos, a saber, el personal de aplicación, los desarrolladores del método y los integradores del sistema.

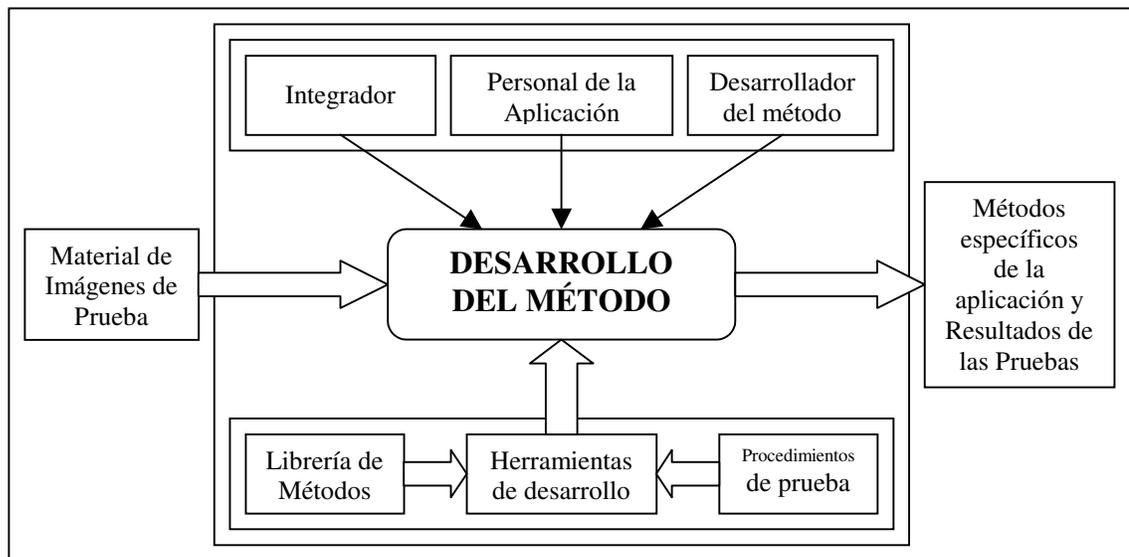


Figura 5. Ambiente para el proceso de desarrollo del sistema de inspección visual

La habilidad de investigación de los sistemas de visión artificial es proporcionada por los desarrolladores del método. Ellos pueden desarrollar aplicaciones prototipo de software con algunas herramientas de desarrollo y probar el método fuera-de-línea con las imágenes de prueba. El conocimiento de la aplicación es proporcionado por el

personal de la aplicación, que representa a los usuarios finales del sistema de inspección. La experiencia del sistema es proporcionada por los integradores del sistema, quienes forman un equipo multidisciplinario y son expertos en la construcción de máquinas de inspección, incluyendo adquisición, iluminación, software y hardware del sistema y los actuadores o dispositivos de manipulación. No obstante, la división del personal en tres categorías es un ejemplo académico estrictamente, puede haber personal de la aplicación que también es integrador del sistema, o integradores del sistema que trabajan también en el desarrollo del sistema.

Con el fin de proponer otros métodos para que surjan nuevas áreas de aplicación, el desarrollador del método no debe ligarse a un hardware en especial o a un conjunto pequeño de métodos adecuados para dispositivos muy particulares. Lógicamente, el conocimiento de lo que está disponible o es factible durante el período de desarrollo, es esencial para el diseñador del sistema, pero un enlace absoluto repercutiría en el desarrollo de un sistema poco flexible, cerrado, e impedido para expansiones futuras.

En un proyecto de desarrollo, la decisión acerca del hardware puede tomarse antes o después del desarrollo del método. La primera opción restringe el conjunto de métodos que pueden usarse dependiendo de la generalidad del hardware y es posible que releven la tarea de los diseñadores del método. La segunda opción da más libertad para el desarrollo de este, pero también se debe tener cuidado porque tiene que asegurarse la implementabilidad. La última opción incluye el desarrollo de nuevo hardware según los métodos propuestos.

3.1.1. Conocimiento de la aplicación. En la figura 5 el conocimiento de la aplicación es la información necesaria para que el diseñador del método entienda el alcance que debe tener y, así, desarrolle la aplicación del método específico de inspección. El intercambio de conocimiento de la aplicación normalmente requiere mucho esfuerzo tanto del desarrollador del método como del personal de la aplicación. Una forma de conseguir el conocimiento de la aplicación es estableciendo parámetros como:

- Propiedades de la superficie del objeto inspeccionado
- Clases de defectos que están ocurriendo y qué tan a menudo
- Magnitud de la variación de los defectos sobre la superficie sana
- Costo de cada tipo de defecto
- Costo de los posibles errores del sistema
- Factibilidad para la separación de los defectos en clases
- Confusiones que podrían presentarse
- Velocidad de los objetos inspeccionados
- Requerimientos de resolución y definición de las imágenes
- Requerimientos de tiempo de procesamiento
- Tipo de iluminación que se adecua al aspecto que se va a medir
- Limitaciones para realizar el entrenamiento
- Objetivos de los resultados obtenidos
- Parámetros que son necesarios y permitidos
- Formas para controlar los parámetros
- Requerimientos para la visualización o almacenamiento de los resultados
- La necesidad de una interfaz de usuario determinada

Es posible que el personal de la aplicación no pueda proporcionar respuestas a todas las preguntas presentadas si no se usa el sistema de visión antes en la aplicación. Entonces el desarrollador debe usar su experiencia o debe tomar algunas imágenes y experimentar con un método para entender los requisitos de la aplicación. Muchos de los problemas se resuelven presentando varias aproximaciones alternativas para la

resolución de las imágenes, el orden de separación para los defectos, el entrenamiento, la visualización, y discutiendo con el personal de la aplicación para encontrar la mejor solución.

3.1.2. Material de imágenes de prueba. Normalmente el primer paso para obtener una idea de cómo puede llevarse a cabo la inspección es la recolección de una cantidad pequeña de imágenes de prueba en-línea o de muestras de prueba para ser analizadas fuera-de-línea. Esto permite hacerse una impresión de la posible calidad de las imágenes, se puede también estimar la visibilidad de las propiedades deseadas en las imágenes. La idea es realizar pruebas preliminares del método con algunos métodos conocidos con el fin de establecer un estimativo de la complejidad del problema.

Algunas veces es necesario un conjunto más completo de imágenes para el ulterior desarrollo del método, representando así posibles variaciones del material a ser inspeccionado. Se debe asignar un cuidadoso etiquetado de los defectos en y con las imágenes de prueba. El etiquetado consiste en distinguir manualmente las áreas de los defectos y las clases para conseguir una base de conocimientos fiable para el sistema de inspección. Normalmente, el etiquetado consume mucho tiempo y es una tarea propensa a errores, y debe ser llevada a cabo con ayuda del personal de la aplicación.

El requisito básico para lograr resultados con desempeños fiables para el sistema, es que estén disponibles bastantes imágenes de prueba etiquetadas. El número de defectos etiquetados, denominados muestras, debe ser preferiblemente de cientos por cada clase de defecto. A más muestras disponibles, pueden hacerse mejores estimaciones del desempeño, aunque se debe tener en cuenta que gran cantidad de muestras para la fase de entrenamiento pueden resultar en sobreentrenamiento, lo que también representa un problema a la hora de la implementación del método.

3.2. HERRAMIENTAS DE DESARROLLO

Para hacer una distinción entre las herramientas de desarrollo genéricas y las ligadas al hardware, las herramientas de desarrollo discutidas aquí son herramientas de software para el desarrollo de métodos genéricos de procesamiento de imágenes y reconocimiento de patrones. El integrador del sistema puede tener otras herramientas para el desarrollo de software en tiempo real con ayuda algún hardware especializado, como el procesamiento de imágenes con PC, ASICs o con tarjetas DSP.

Las herramientas de desarrollo del método consisten en una biblioteca de procesamiento básico de imágenes y en procedimientos de reconocimiento de patrones, herramientas para el desarrollo de nuevos procedimientos, un ambiente para ligar los procedimientos a los métodos por medio de programación visual, por ejemplo, y un medio para procesar grandes conjuntos de imágenes a través del método. Como un ejemplo de herramienta de desarrollo, se presenta el ambiente de procesamiento de imágenes QWin/QUIPS, ya que fue la plataforma de desarrollo básico de los métodos durante los experimentos de este estudio.

3.2.1. El ambiente de procesamiento y análisis de imágenes QWin/QUIPS. QWin es una sofisticada aplicación desarrollada por Leica Microsystems capaz de dirigir y resolver tareas complejas de análisis digital de imágenes. Funciona bajo el ambiente de los sistemas operativos Microsoft® Windows™. Provee una interfaz amigable y de fácil uso para acceder a vastas facilidades de procesamiento y cálculo de imágenes que ofrece QWin [67-68].

En el Laboratorio de Óptica y Láser de la Universidad del Cauca se cuenta con la licencia del paquete QWin *Standard* que contiene las características más comúnmente usadas durante el procesamiento y análisis de imágenes tales como mediciones de campo y de características. Además de las funciones de adquisición en vivo desde una cámara, permite establecer funciones para el control de una plataforma de microscopio y su correspondiente iluminación.

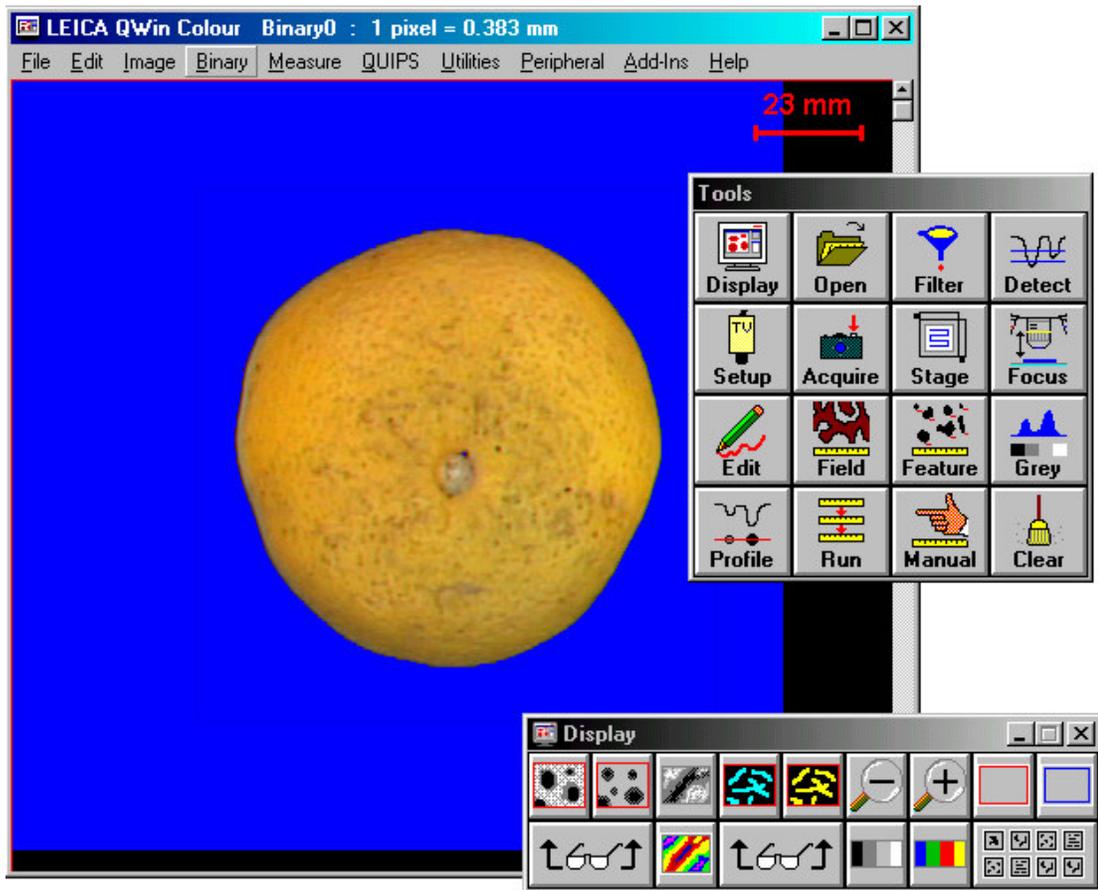


Figura 6. Ejemplo de la interfaz de QWin

La figura 6 muestra el despliegue típico de la interfaz de QWin. En la barra de título se presenta la información de la imagen presentada en pantalla junto con los parámetros para la calibración de la imagen. Bajo esta barra están los menús, desde los cuales es posible acceder a todas las funciones que ofrece la aplicación. A continuación está la ventana de la imagen, donde se muestran los cuadros de imagen y de medición. En la parte derecha se observa un cuadro en el que se encuentran las funciones de uso más común para la adquisición, procesamiento y análisis de imágenes, en la parte inferior hay una ventana que muestra la caja de herramientas de presentación que es útil para manipular los parámetros concernientes con la visualización de las imágenes.

QWin provee muchas clases de mediciones: desde análisis interactivos manuales hasta medidas completamente automatizadas, que no necesitan intervención por parte del usuario. Soporta muchos formatos de imágenes, tiene varias herramientas de detección basadas en umbrales, permite el manejo de espacios de color RGB y HSI, las herramientas para las tablas de referencia (LUTs, *Lookup Tables*) tienen diálogos que facilitan la toma de decisiones para los valores de los parámetros. Se destaca también lo correspondiente a las herramientas de la transformada rápida de Fourier y de morfología matemática binaria y en niveles de gris, que son realmente sofisticadas, permitiendo realizar aplicaciones avanzadas.

QUIPS (*Quantitative Interactive Programming System*) es una facilidad de macro-programación dentro de QWin. Permite registrar una secuencia de operaciones de análisis de imágenes que luego se pueden ejecutar con un simple clic sobre el ratón. Esta secuencia a menudo se conoce como rutina y permite crear soluciones que el personal de la aplicación puede usar repetidamente sin necesidad de que tenga un conocimiento especializado sobre QUIPS [69-70].

Tal como en las instrucciones de análisis de imágenes, se pueden insertar instrucciones dentro de la rutina que desarrollen los cálculos, realicen la entrada y salida de datos, y que permitan interactuar con esta mientras se ejecuta. También se puede cambiar el control del flujo dentro de la rutina, mediante las instrucciones de control, esto cuando las operaciones no tienen que ser ejecutadas necesariamente en el orden en que fueron insertadas. Es posible, por ejemplo, seleccionar diferentes operaciones basadas en los resultados de las mediciones, o en los valores que el usuario determine para la rutina.

Con las instrucciones de análisis de imágenes y la programación con QUIPS, una rutina es por consiguiente más ventajosa que un programa convencional, esto desde el punto de vista del diseño de los algoritmos. La diferencia es que no es necesario crear un programa escribiendo las instrucciones carácter por carácter, sino que se crea

interactivamente usando las facilidades de los diálogos y los menús de QUIPS y QWin.

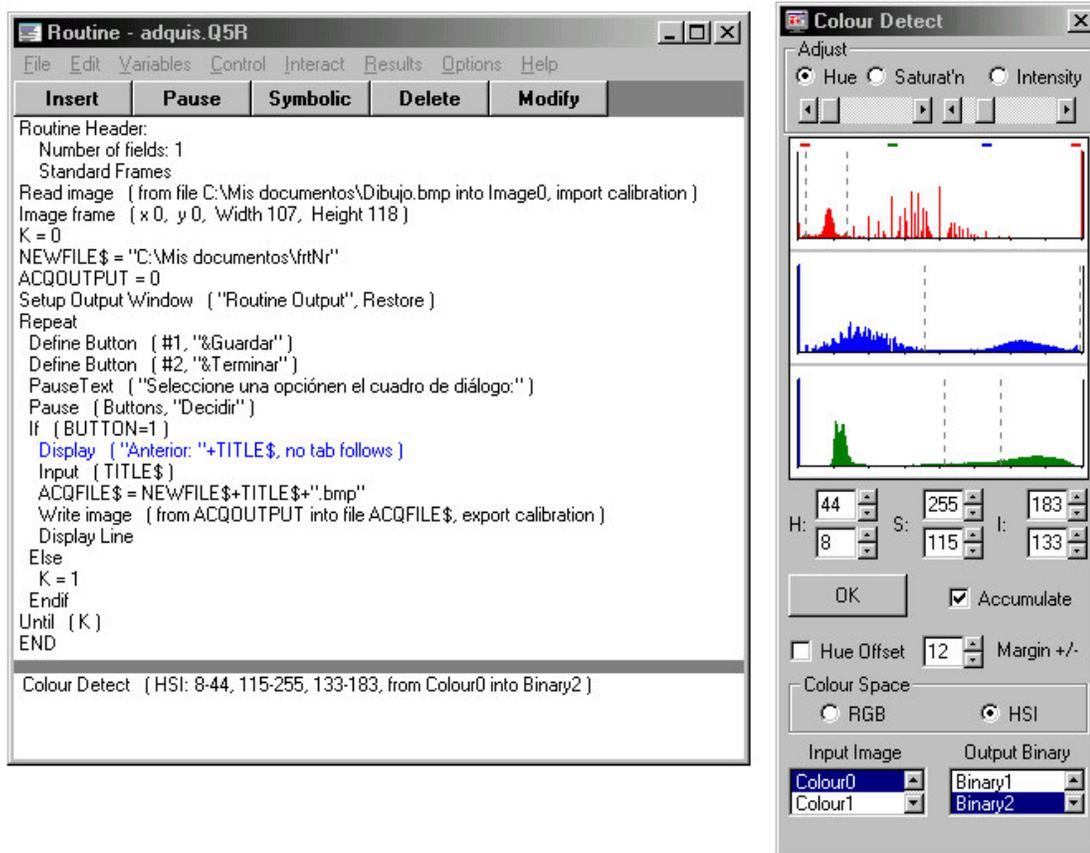


Figura 7. Ejemplo de la interfaz de QUIPS

Cada diálogo para el análisis de imágenes de QWin tiene una instrucción correspondiente en QUIPS, que es creada automáticamente si está desplegado un diálogo mientras la ventana de QUIPS está abierta. Inicialmente, QUIPS simplemente despliega la instrucción sin insertarla dentro de la rutina, mientras esto sucede la instrucción se puede insertar en cualquier momento. Opcionalmente, se puede insertar la instrucción automáticamente cuando se presione el botón de “Aceptar” (OK) del diálogo.

Esto se puede interpretar más claramente observando la figura 7, donde se muestra la interfaz del ambiente de programación de QUIPS. Bajo la barra del título están los

menús que contienen todas las herramientas y funciones que ofrece QUIPS, como la manipulación de variables y el manejo de las instrucciones de control, inmediatamente después hay una barra de botones de funciones para la instrucción seleccionada. La mayor parte de ventana la ocupa el listado de la rutina, presentando las instrucciones que contiene la rutina. En la parte inferior se encuentra, separada del listado de la rutina por una gruesa línea, la línea que indica la instrucción pendiente.

La instrucción pendiente es la instrucción correspondiente a la operación de análisis de imágenes que se esté configurando en el momento. Por ejemplo, en la parte derecha de la figura 7 se observa el cuadro de diálogo para la detección en color en el espacio HSI, la instrucción correspondiente aparece en la parte inferior de la ventana, junto con los parámetros que se han configurado en el cuadro de diálogo. Una vez se oprima el botón *OK*, la instrucción pendiente pasará a hacer parte de la rutina ubicándose en la línea inmediatamente anterior a la resaltada con color azul en el listado de la rutina.

QUIPS también provee algunas operaciones de programación que permiten:

- Realizar la entrada de datos a la rutina desde el teclado
- Ejecutar cálculos
- Hacer salidas de datos para presentar reportes personalizados
- Ejecutar condicionalmente ciertas instrucciones
- Repetir una secuencia de instrucciones
- Interactuar con la rutina mientras esta se ejecuta
- Establecer enlaces para el intercambio dinámico de datos (DDE, por sus siglas en inglés) con otros programas.

Aunque el ambiente de desarrollo QWin/QUIPS se proyecta para el desarrollo y prueba de secuencias de procesamiento y análisis de imágenes usando programación visual, este no es un ambiente adecuado para aplicaciones industriales o que tengan requisitos de tiempo de procesamiento exigentes. La complejidad de este ambiente es

muy alta, tanto operacional como computacionalmente, por lo que usarlo a manera dispositivo de inspección en una línea de producción no es razonable. Para labores de investigación, por ejemplo en el desarrollo de rutinas más eficientes y rápidas o en la resolución de problemas de inspección, como en este caso, es una aplicación ideal, principalmente por las herramientas tan sofisticadas que brinda. También es muy útil en el caso que los análisis se puedan hacer fuera-de-línea, por ejemplo en un laboratorio donde se necesita para el conteo de células y los requisitos de tiempo no representan un limitante.

3.2.2. Otras librerías. Como es lógico, existen varias librerías para el procesamiento digital de imágenes y visión por computador, estas se pueden dividir entre las de libre distribución y las comerciales. Entre las de libre distribución se pueden enumerar Image Magik, Gandalf, Gimp, CVIP Tools, entre otras. Por lo general son sólo para procesamiento fuera-de-línea, o para propósitos de diseño de nuevos algoritmos, debido a que generalmente solo soportan ser ejecutadas sobre plataformas tipo PC.

Las librerías comerciales muchas veces son diseñadas para correr sobre un hardware específico, por lo que en estos casos las velocidades alcanzadas permiten realizar aplicaciones muy avanzadas. Entre estas se pueden nombrar *Matrox Imaging Library (MIL)* y *Sherlock*. Para plataformas PC también existen aplicaciones como *IMAQ Vision* para Labview y el *toolbox* de procesamiento de imágenes de Matlab.

3.3. DESEMPEÑO DE LOS MÉTODOS

El desempeño de un sistema de inspección visual depende del desempeño de los subsistemas que lo forman, como la adquisición, la detección y el reconocimiento de los defectos, la calidad de la clasificación y el ensamble mecánico. La determinación del desempeño total es normalmente difícil en la fase de desarrollo del método, ya que no existe todavía un sistema de inspección completo y puede ser difícil simular en un ambiente de desarrollo un sistema de inspección en-línea.

Hay algunas prácticas para determinar el desempeño de los métodos de reconocimiento de defectos. La estimación del desempeño del método es obtenida ejecutando los algoritmos sobre las imágenes de prueba etiquetadas y realizando la detección y el reconocimiento de los defectos, finalmente se observa cómo el sistema encuentra los defectos y los resultados se comparan con las etiquetas. Para hacer una comparación objetiva, el material de muestra tiene que ser dividido en conjuntos de entrenamiento y conjuntos de prueba. El sistema de inspección es entrenado y puesto a punto con el conjunto de entrenamiento, y se establece el desempeño del sistema entrenado con el conjunto de prueba. Se puede usar un tercer conjunto, denominado conjunto de validación, para verificar los resultados. Otra forma consiste en realizar la división del conjunto de diferentes maneras y repitiendo el entrenamiento y la prueba para cada caso [1], es lo que se denomina validación cruzada.

Si embargo, es difícil encontrar metodologías para determinar la exactitud de la detección de los defectos, en la inspección para el control de calidad de frutas es una tarea importante la forma de determinar con exactitud la precisión alcanzada en el reconocimiento de los defectos, de esto depende en gran parte la factibilidad del sistema. En la siguiente sección se describen algunas prácticas para evaluar la exactitud de la detección de defectos y se establecen algunas medidas para esta labor.

3.3.1. Exactitud de la detección de defectos. La exactitud de detección de defectos es caracterizada a menudo por la tasa de detección de defectos, la tasa de errores por evasión y la tasa de las falsas alarmas. La información necesaria para calcular estos parámetros es la siguiente:

- El número de detecciones producidas por el sistema de inspección: N_{Det}
- El número de defectos realmente etiquetados: N_{Etq}
- El número de defectos etiquetados que se han detectado: N_{Det_Etq}

La proporción de detección de defectos indica la razón entre el número de defectos etiquetados detectados y el número de defectos reales, y es determinada por

$$Tasa_detección_defectos = N_{Det_Etq} / N_{Etq} . \quad (1)$$

La proporción de errores de evasión indica la razón entre los defectos pasados por alto y el número de defectos reales, y se relaciona con la proporción de detección de defectos así

$$Tasa_errores_evasión = 1 - Tasa_detección_defectos. \quad (2)$$

La proporción de falsas alarmas se define como la razón entre el número de detecciones que no están en el área de los defectos etiquetados y el número de detecciones totales,

$$Tasa_falsas_alarmas = (N_{Det} - N_{Det_Etq}) / N_{Det} . \quad (3)$$

En la práctica, la determinación de los errores de evasión y las falsas alarmas no es tan directa como se describe arriba. Pueden haber varias detecciones de un solo defecto, una detección puede cubrir varios defectos, o pueden haber detecciones que no corresponden muy bien con los defectos reales o que tienen dimensiones equivocadas. La figura 8 ilustra estas situaciones problemáticas comunes. Las zonas punteadas representan los defectos y las grises las partes detectadas.

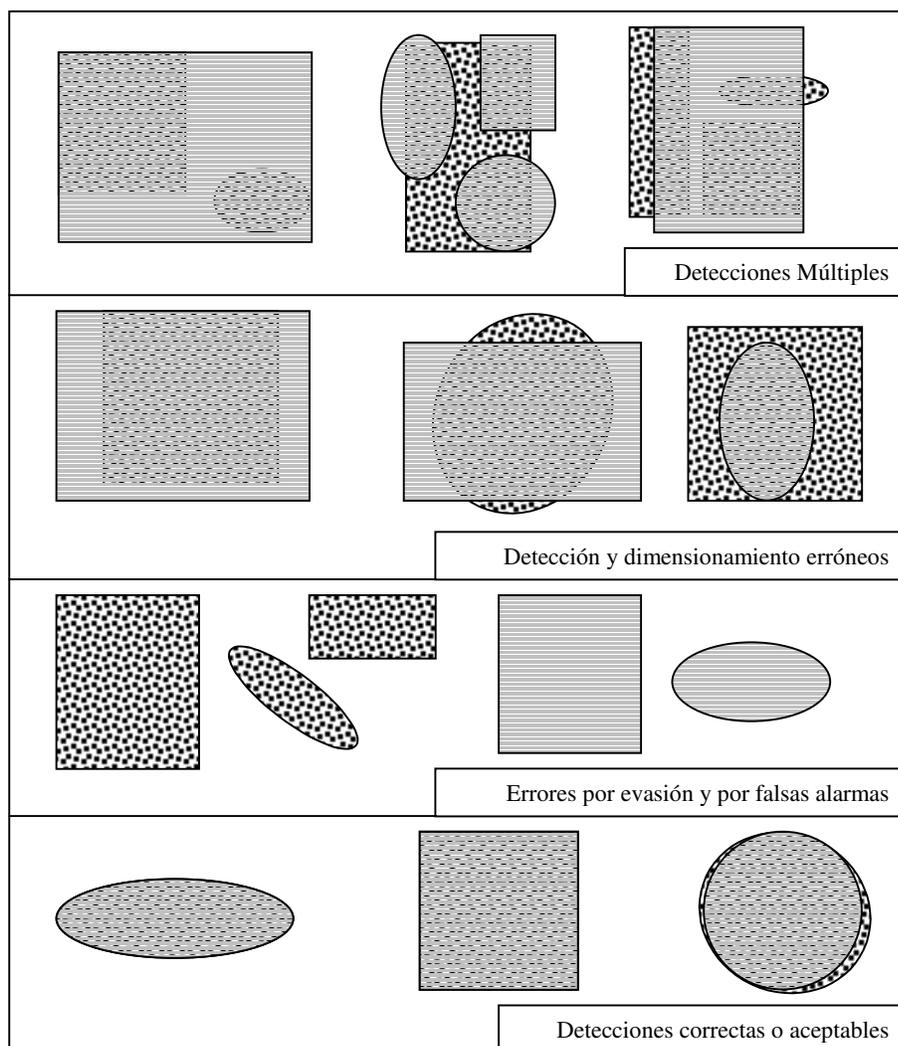


Figura 8. Ejemplos de los errores cometidos durante la detección

Las tasas de errores de evasión y de falsas alarmas no contienen información sobre la calidad de la detección. Si una detección es demasiado pequeña o se superpone un poco con el defecto real, como se observa en la parte inferior derecha de la figura 8, probablemente no debe ser considerada como detección aceptable. Una medida que describe la calidad de la detección es, por ejemplo, el solape de la detección y el defecto correspondiente,

$$solape_detectado = \text{área_solapada} / \text{área_real_defecto}, \quad (4)$$

donde el *área_solapada* es el área común entre la detección y el defecto. Otra medida es la relación de las áreas de detección y del defecto correspondiente

$$\text{relación_área} = \text{área_detectada} / \text{área_real_defecto}. \quad (5)$$

Las medidas anteriores se calculan sólo para un par detección-defecto. Si hay defectos múltiples en una detección, sólo se tomará en cuenta un defecto en la determinación de los valores en un momento dado. Los valores no son determinados para las falsas alarmas.

La combinación de estas dos medidas da información sobre la correspondencia y las dimensiones de la detección. Entre más cercanos estén ambos valores, mejor es la detección. Para evaluar la bondad de las detecciones con todo el material de prueba disponible se puede hacer un análisis estadístico, pero puede ser una labor muy dispendiosa si se tienen muchas muestras de entrenamiento, ya que el establecimiento de la zona realmente cubierta por el defecto se debe hacer manualmente.

Al usar detecciones rectangulares es posible que no se puedan mantener correspondencias exactas para defectos elípticos, como se muestra en la figura 8. Sin embargo, las ecuaciones (4) y (5) también trabajarán para detecciones elípticas.

Algunas veces es necesario evaluar el número de detecciones múltiples, conocimiento útil debido a que con esta información es posible determinar si la resolución de las imágenes es adecuada. Muchas veces una detección múltiple se puede dar porque la separación entre un par de defectos es tan pequeña que en los píxeles de la cámara no es posible diferenciarlos, si es así, es necesario establecer una óptica de acondicionamiento que aumente el tamaño de la imagen que captará el sensor o tratar de cambiar el dispositivo por uno de mayor resolución.

Hay dos alternativas para calcular las proporciones de errores de evasión y de las falsas alarmas en el caso de detecciones múltiples. El primer acercamiento permite

verificar qué proporción de detecciones cubren varios defectos y las detecciones múltiples de un solo defecto. El segundo es más severo y acepta sólo un defecto en una detección, considerando el resto como errores de evasión y aceptando sólo la detección de un defecto, considerando el resto como falsas alarmas. Las alternativas son:

- **Aprox. 1:** Para determinar la tasa de errores de evasión, se incrementa $N_{Det_Etq_E}$ en uno para cada defecto real si cualquier detección se solapa con este. Para determinar la tasa de falsas alarmas, se incrementa $N_{Det_Etq_F}$ en uno para cada detección si cualquier defecto la solapa.

- **Aprox. 2:** Para determinar la proporción de errores de evasión, el procedimiento es similar a la aproximación 1, pero el incremento de $N_{Det_Etq_E}$ no se hace si la detección que se solapa con el defecto ya se ha contado con algún otro defecto. Similarmente, para determinar la proporción de falsas alarmas, el procedimiento es similar a la aproximación 1, pero el incremento de $N_{Det_Etq_F}$ no se hace si el defecto que se solapa con la detección ya se ha contado con alguna otra detección.

En la tabla 4 se muestran algunos ejemplos para determinar las tasas de errores por evasión y de falsas alarmas con las aproximaciones descritas para las detecciones de ejemplo de la figura 8, en este caso se tienen 13 detecciones y 15 errores etiquetados, los cálculos se realizan con las ecuaciones (1-3). Como se observa, la primera aproximación da resultados optimistas, mientras que la segunda es pesimista. No puede justificarse cuál es la aproximación correcta, pero pueden usarse para definir los límites superior e inferior para las tasas de errores de evasión y de falsas alarmas.

3.3.2. Exactitud del reconocimiento de defectos. La determinación de la exactitud del reconocimiento de defectos puede realizarse después de hacer la detección de estos. Las detecciones son comparadas con los defectos reales y se producen resultados del reconocimiento para estas. La exactitud del reconocimiento de defectos se determina

comparando los resultados del método de reconocimiento y las etiquetas de los defectos reales.

Tabla 4. Determinación de las tasas de errores por evasión y de falsas alarmas

PARÁMETRO	Aprox. 1	Aprox. 2
N_{Det}	13	
N_{Etq}	15	
$N_{Det_Etq_E}$	12	9
$N_{Det_Etq_F}$	11	9
<i>Tasa_errores_evasión</i>	0.20	0.4
<i>Tasa_falsas_alarmas</i>	0.13	0.27

Fuente: Este estudio

La aproximación usada normalmente para presentar los resultados del reconocimiento de defectos es la matriz de confusión, que muestra los números o porcentajes de las muestras clasificadas correcta y erróneamente para cada clase de defecto y para las clases en que las muestras no fueron clasificadas. Los errores de evasión y las falsas alarmas también se pueden incluir en la matriz de confusión, como se muestra el ejemplo de la tabla 5, que también se basa en la información obtenida a partir del ejemplo que se presenta en la figura 8. Las columnas representan el reconocimiento que hizo el sistema y las filas la etiqueta real de los defectos, un sistema que se desempeñe óptimamente debe tener en la diagonal principal los números o porcentajes más elevados.

Si ya se hizo la interpretación de las detecciones múltiples en el análisis para la detección de defectos, no hay necesidad de hacerlo de nuevo en el análisis de reconocimiento de defectos. Por esta razón, los resultados del análisis de precisión del reconocimiento siempre deben presentarse junto con los resultados del análisis de precisión de la detección.

Es fácil calcular varias métricas numéricas que ilustren el desempeño de los métodos, pero se tiene que tener cuidado al interpretar el significado de estas. Para lograr una interpretación correcta de los valores del desempeño, no hay nada más ilustrativo que

el examen directo de las imágenes donde se realizaron las detecciones y reconocimientos de los defectos.

Tabla 5. Matriz de confusión para los resultados del reconocimiento de defectos

		Resultado del Reconocimiento		Errores de Evasión	% de Acierto
		Rectangular	Ovalado		
Etiquetado del Error	Rectangular	6	3	2	55
	Ovalado	3	2	1	33
Falsas Alarmas		1	1	Proporción de Aciertos: (8/19*100) 42%	

Fuente: Este estudio

3.3.3. Costo de implementación y complejidad del algoritmo. Cuando se desarrollan algoritmos para aplicaciones en tiempo real, es importante evaluar los recursos computacionales necesarios. La evaluación ayudará en la determinación del costo de implementación y en la selección de una plataforma de hardware adecuada. Si el algoritmo no es implementable con costos razonables, se debe llevar a cabo una optimización o un rediseño de las rutinas.

Es difícil evaluar la bondad de las implementaciones de algoritmos en hardware. Aunque la comparación de programas que corren en computadores comunes es una fuente importante de información, los resultados son inevitablemente afectados por las habilidades en la programación y por las características de la máquina [23]. Por ejemplo, soluciones diferentes de hardware proveen apoyo con diferentes tipos de alternativas de optimización para el uso de memoria y de las estructuras de control. Una alternativa útil a las medidas empíricas es un análisis matemático de la dificultad intrínseca para resolver computacionalmente un problema. Esto se puede lograr con un análisis de complejidad de los algoritmos que sea independiente del hardware [23].

La complejidad puede definirse en función de la complejidad de tiempo, de la complejidad de tamaño y de la complejidad computacional. La complejidad de tiempo es que una medida del tiempo requerido para ejecutar el algoritmo sobre un problema de cierto tamaño. La complejidad de tamaño es una medida del espacio en memoria requerido para la ejecución del algoritmo. La complejidad computacional estima el poder computacional requerido para resolver un problema y es medido por el número de operaciones aritméticas o lógicas requeridas. La medida de la complejidad computacional es considerada como una rama de la medida de la complejidad de tiempo.

La medida de la complejidad computacional parece ser conveniente para la evaluación de los algoritmos con independencia del hardware. Para hacer esta evaluación, se necesita contar el número de operaciones para la ejecución del algoritmo. Con el conteo de operaciones, y teniendo el conocimiento anterior de las proporciones de los datos de entrada a ser procesados, se estiman los millones de operaciones por segundo (MOPS) que se pueden hacer. Para convertir esto a millones de instrucciones por segundo (MIPS) se necesita el conocimiento del hardware.

Hay un peligro para el diseñador del método cuando se usan módulos de procesamiento de imágenes prediseñados de un ambiente de desarrollo, como en este caso, ya que la complejidad computacional puede permanecer incierta. Además, pueden existir métodos que proporcionen buenos resultados, pero su aplicación en tiempo real es difícil, cara o incluso imposible de conseguir.

3.4. ESTIMACIÓN DE LA EXACTITUD DEL CLASIFICADOR DE FRUTAS CON VISIÓN ARTIFICIAL

Uno de los requisitos principales para un sistema de clasificación de frutas es que tenga una buena exactitud en la clasificación. Como se notó anteriormente, la determinación del desempeño total es normalmente difícil en la fase de desarrollo del método. Para hacer experimentos de clasificación, se necesita una cantidad grande de

imágenes de frutos ya clasificados. Éstas, muchas veces son difíciles de recolectar, se requieren arreglos extensos para la adquisición y una cantidad grande de almacenamiento y, por consiguiente, ésta es una operación que puede exigir mucho trabajo al principio de la fase de desarrollo del sistema de inspección.

Es más fácil trabajar con un conjunto de imágenes tomadas sólo de las partes defectuosas de las frutas, de esta manera, se le provee información suficiente al diseñador del método, que realiza el procesamiento de las imágenes con el fin de conseguir estimaciones preliminares de la precisión alcanzable en las operaciones. Si se conoce una relación entre la detección de defectos y la exactitud del reconocimiento y la clasificación, se pueden dar los estimados alcanzables del desempeño en la clasificación. El conocimiento de esta relación también ayuda a entender la importancia de los diferentes defectos para la clasificación y como se relaciona la exactitud del clasificado con la exactitud del reconocimiento de defectos.

Aunque la estructura de las reglas de clasificación de frutas es relativamente compleja, sin necesidad de experimentos es posible determinar una relación directa de la dificultad de los procedimientos.

En este capítulo se presentaron las prácticas para el desarrollo del método y la evaluación de desempeño del sistema desde el punto de vista de la inspección de frutas, pero estas pueden generalizarse en cierta medida a otras aplicaciones que tienen naturaleza similar, o sea, donde están buscándose defectos sobre superficies. Esto incluye la inspección de tejidos, como el papel, textiles, maderas, superficies de acero, partes manufacturadas, entre otros.

Por otro lado, las medidas hechas para comparar la calidad en la detección de defectos deben ser especializadas para ser más adecuadas a cada aplicación específica. Por ejemplo, en la clasificación de frutas, las reglas de clasificación definen los principios de medida de las dimensiones para las propiedades de las

frutas. Estos principios deben seguirse para determinar la calidad de la detección con el fin de obtener información más exacta sobre esta.

Los conceptos presentados para el ambiente de desarrollo, el conocimiento de la aplicación, y la evaluación del desempeño, así como los ejemplos de herramientas de desarrollo de un sistema de inspección completo complementan lo requerido para enfrentar el diseño de un sistema de inspección específico, tal como se realiza en el capítulo siguiente.

4. MATERIALES Y MÉTODO PARA LA INSPECCIÓN DE FRUTAS

La meta del desarrollo del sistema de inspección es encontrar un método simple y efectivo para la clasificación de frutas basado en su tamaño, color y defectos externos. En esta sección se describen los detalles del método desarrollado. Aunque no es el objetivo de este trabajo de grado, es posible implementar aplicaciones en tiempo real del método con soluciones de hardware actuales, constituyendo este un precedente para la aplicación en sistemas de alta velocidad. El método que se usa aquí es para la clasificación de frutas, aunque también es adecuado para otros problemas de inspección que involucren el análisis de color, forma, tamaño, textura o la cuantificación de defectos superficiales.

A continuación se describen los materiales utilizados y el detalle de las diferentes partes del método. Las características, su extracción y selección son parte fundamental de un método de inspección, por lo que se detallan junto con la metodología para su cuantificación y posterior tratamiento. El capítulo concluye con lo referente a los resultados obtenidos y su correspondiente discusión.

4.1. DESCRIPCIÓN GENERAL DEL SISTEMA. VISIÓN DE BAJO NIVEL

En las secciones siguientes se presenta el método de inspección superficial de frutas que se diseña sobre la idea del concepto del sistema de clasificación propuesto en la figura 2 (Capítulo 2).

Se presenta la secuencia del método propuesto para la inspección visual del color, tamaño y defectos externos en frutas, es basada en el diagrama propuesto en la figura 3 (sección 2.1). En las siguientes secciones se describen los pasos detallados de la

secuencia. No se necesitan obligatoriamente todos los pasos en otras aplicaciones de inspección, ya que esto depende de la información que se desee extraer y de los recursos disponibles para la implementación de la aplicación.

La parte de la segmentación se encarga de la detección de los defectos, determinando la forma en que estos se distribuyen sobre la superficie de la fruta, en principio se puede realizar el análisis contextual para preclasificar los defectos, en la etapa del cálculo de características se hacen las mediciones de los parámetros de interés y se seleccionan los que serán más útiles para la tarea de inspección y, finalmente, durante la clasificación se hace la clasificación de los defectos y otros parámetros para determinar la clasificación final de la fruta. Cada una de estas etapas se describe en detalle a continuación.

4.1.1. Materiales y equipos disponibles. En esta sección se describe detalladamente como se obtuvieron las muestras de frutas para el desarrollo del método de inspección. Luego se especifican los componentes del equipo de visión, la cámara de iluminación y demás, junto con las especificaciones y parámetros adecuados para la aplicación, también se menciona brevemente el software empleado en el desarrollo del método para la inspección de frutas.

4.1.1.1. Recolección de las muestras. Se utilizaron naranjas de la variedad valenciana, cultivadas y cosechadas artesanalmente en la meseta de Popayán, a una altura 1760 metros, lo que significa que se trata de un clima templado.

Las frutas fueron recolectadas directamente de las plantaciones, tratando de no realizar discriminación entre la calidad visual de las frutas con el fin de obtener muestras que representaran una producción normal lo más ampliamente posible en cuanto a contenido de defectos, maduración y tamaños. En un lapso de tres semanas se tomaron muestras, que totalizaron 165 frutos para la realización de las operaciones de entrenamiento, prueba y validación del sistema.

La identificación del tipo de defectos se llevó a cabo teniendo en cuenta la norma NTC4086 [64], que está de acuerdo con la calidad visual que busca un consumidor a la hora de la elección de las frutas. Los tipos de daños presentes fueron principalmente: cicatrices externas provocadas por insectos, rozaduras con hojas, ramas y otras frutas, manchas en la piel (debidas a la oleocelosis y a otros agentes), lesiones oscuras causadas por golpes y magulladuras, podredumbres, clareta (surcos o estrías) y diversos tipos de cisuras y rayones causados por varios factores.

4.1.1.2. Equipo de visión. El equipo utilizado para la toma de imágenes consta de una cámara de vídeo CCD a color que envía una señal de vídeo YC a una tarjeta de adquisición de imágenes, donde se digitaliza, obteniéndose una imagen RGB lista para el procesamiento, aunque se dispone también de una cámara monocromática para otro tipo de ensayos.

La cámara a color utilizada es de marca JVC, modelo TK-C1380, con un sensor de media pulgada, la tecnología CCD es *interline-transfer*, una matriz de 768 x 494 elementos detectores y genera señales de video tipo NTSC, la sensibilidad es buena con lo que puede operar hasta con 0.95 lux. de iluminación. Su tamaño es de 67 x 70 x 159 mm. La cámara se puede conectar a la red eléctrica mediante un adaptador que genere 24 VAC o a la tarjeta digitalizadora que posee una salida de alimentación de 12 VDC. Se empleó un objetivo Cosmicar/Pentax de 12 mm.

La tarjeta de digitalización en color, de la casa Matrox, serie Meteor II/*Standard*, se trata de un *frame grabber* para señales análogas monocromas o a color. Se conecta al bus PCI del computador y tiene la posibilidad de adquirir imágenes de hasta 12 cámaras monocromáticas o de 6 a color. Decodifica señales de diferentes tipos de codificación, que incluyen CVBS y Y/C sobre NTSC o PAL para video a color y RS170 y CCIR para video de intensidad. Al digitalizarlas las convierte en RGB 8:8:8, YUV 4:2:2 o YUV 4:1:1 La velocidad de adquisición puede llegar a ser de hasta 60 imágenes por segundo.

4.1.1.3. Cámara de iluminación. La iluminación correcta es crítica en un sistema de visión artificial, por lo que si se tiene que la iluminación no es adecuada, se obtendrán una buena cantidad de problemas sobre la imagen tal como se ilustra en la figura 9.(a). Los brillos o resplandores que se observan ocultan información importante en la imagen, en la zona brillante de la imagen los sensores de la cámara se han saturado de tal manera que la imagen obtenida no corresponde fielmente con las propiedades de la superficie del objeto.



Figura 9. Imágenes tomadas sin considerar un sistema de iluminación apropiado

Lo mismo ocurre con las sombras que aparecen en la escena, las zonas que son oscuras debido a la iluminación insuficiente introducen incertidumbre acerca de la información que de éstas se puede derivar. Los sombreados, que muchas veces son agradables al sentido visual humano ya que dan una sensación de tridimensionalidad, pueden causar que se detecten bordes falsos durante los cálculos, lo que resulta en mediciones imprecisas. Si se trata de superficies dieléctricas, el uso de un polarizador orientado apropiadamente en el objetivo de la cámara CCD ayuda a que se mejore notablemente la imagen en cuanto al contenido de brillos sobre ésta, tal como se observa en la figura 9.(b). Lamentablemente, esto solo soluciona una parte del

problema, se debe analizar qué esquema de iluminación se debe implementar para eliminar las sombras y el sombreado.

Una iluminación pobre puede también resultar en una relación señal a ruido muy baja. En particular, la iluminación no uniforme puede estropear una buena señal y hacer que las operaciones, tales como los umbralizados, sean más complicadas. Estas son solo unas pocas razones para darle mucha importancia al esquema de iluminación que se debe emplear en un sistema de adquisición de imágenes.

La escogencia del sistema de iluminación no consiste simplemente en conseguir un par de lámparas y colocarlas a funcionar cerca del objeto que se va inspeccionar mientras se adquiere la imagen, lo más probable es que se obtendrán los resultados que se muestran en la figura 9. Se deben tener en cuenta las características de la superficie del objeto que se va a analizar, qué parámetros se desean resaltar, la posición y el tamaño, la velocidad a la que pasa en frente al sensor, el rango dinámico del sensor, las características del fondo, etc.

Por esto se han diseñado muchos esquemas de iluminación y diversos tipos de elementos iluminadores. Los esquemas de iluminación pueden consistir en luz direccional o difusa, de campo oscuro o de campo claro, luz estructurada, luz axial e iluminación a contraluz, entre muchos otros, en la tabla 6 se describen los principales sistemas junto con sus ventajas y desventajas. Entre los iluminadores se encuentran las lámparas incandescentes, fluorescentes o espectrales, el láser, los leds, entre otros. No se pueden ignorar los filtros que sirven seleccionar cierta banda con el fin de detectar solo determinado color o para eliminar cierta zona del espectro como la radiación infrarroja.

Tabla 6. Sistemas de iluminación más importantes

ESQUEMA DE ILUMINACIÓN	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS
Direccional	Iluminación puntual de una o varias fuentes, se pueden usar lentes para concentrarla o extenderla	<ul style="list-style-type: none"> ↯ Intensa ↯ Flexible ↯ Se usa en muchas aplicaciones ↯ Se puede acomodar fácilmente 	<ul style="list-style-type: none"> ↯ Producción de sombras ↯ Los reflejos especulares producen resplandores
Difusa	Luz uniforme y multidireccional de una fuente de luz extensa	<ul style="list-style-type: none"> ↯ Reduce los resplandores o brillos ↯ Provee iluminación uniforme 	<ul style="list-style-type: none"> ↯ Es difícil obtener iluminación realmente uniforme
Anillo de Luz	Iluminación coaxial que se monta directamente en los objetivos	<ul style="list-style-type: none"> ↯ Reduce las sombras ↯ Es uniforme a distancias adecuadas 	<ul style="list-style-type: none"> ↯ Se obtienen patrones de resplandor circular en superficies reflectivas ↯ Distancias de trabajo cortas
Axial	Coaxial a la entrada de la imagen, se logra gracias al uso de un divisor de haz	<ul style="list-style-type: none"> ↯ Es muy uniforme y difusa ↯ Reduce enormemente las sombras y el resplandor 	<ul style="list-style-type: none"> ↯ Difícil de montar ↯ Distancia de trabajo limitada
Contraluz o campo claro	Los objetos son iluminados desde atrás. Se usa para obtener las siluetas de objetos opacos o para tomar imágenes de objetos transparentes	<ul style="list-style-type: none"> ↯ Alto contraste para la detección de bordes 	<ul style="list-style-type: none"> ↯ Elimina los detalles de la superficie
Campo Oscuro	La luz entra en un objeto transparente o translúcido a través de un borde perpendicular al objetivo	<ul style="list-style-type: none"> ↯ Alto contraste de los detalles internos y de la superficie ↯ Se mejora la detección de rayones, grietas y burbujas en objetos claros 	<ul style="list-style-type: none"> ↯ Contraste pobre en los bordes ↯ No es útil para objetos opacos
Luz Estructurada	Se proyectan patrones de luz sobre el objeto, típicamente son líneas, puntos o mallas generadas con láser	<ul style="list-style-type: none"> ↯ Mejora la adquisición de las características de la superficie por la intensidad de la iluminación ↯ Se puede usar para obtener la información de profundidad del objeto 	<ul style="list-style-type: none"> ↯ Puede causar resplandores ↯ Es absorbida por algunos colores

Fuente: Edmund Optics and Optical Instruments Catalog 2003

Teniendo en cuenta lo anterior se construyó una cámara de iluminación con 8 tubos fluorescentes (luz blanca) de 20 W cada uno, como se ilustra en la figura 10. La cámara se diseñó pensando en la generación de un esquema de iluminación difusa, por lo que su interior se recubrió con pintura color blanco mate, y se dotó con un par de difusores para impedir el golpe directo de la luz sobre los objetos de análisis. La

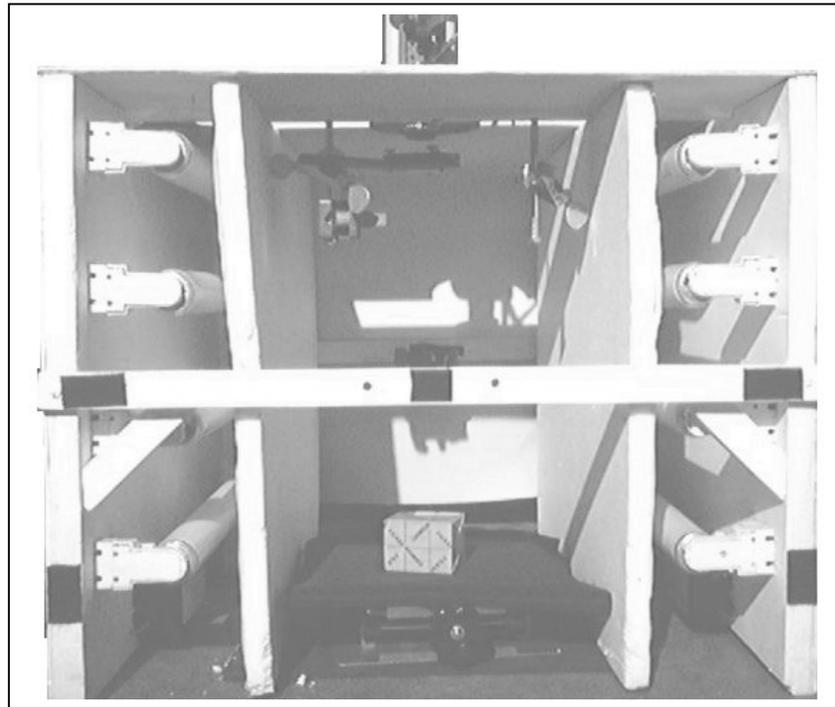


Figura 11. Cámara de iluminación construída

Las lámparas fluorescentes tienen un período de vida útil de aproximadamente ocho a doce veces mayor que las lámparas incandescentes convencionales y pueden consumir hasta un 85% menos energía que éstas, manteniendo la misma luminosidad. Actualmente, los tubos fluorescentes proporcionan una máxima eficacia luminosa para temperaturas que oscilen entre los 45 y 50°C, por lo que estas lámparas proporcionan una radiación infrarroja pobre, diferente a las incandescentes.

Antes de la entrada de la imagen al objetivo de la cámara, esta debe pasar por un polarizador debidamente orientado, para eliminar los posibles brillos y zonas de saturación en la superficie de la fruta o en otras zonas de la escena. Con este dispositivo se ha logrado captar apropiadamente la fruta, eliminando el sombreado, las sombras producidas entre frutas y los brillos en la superficie de las mismas.

La cámara CCD se sitúa en un orificio en la parte superior, de tal manera que la entrada y salida de luz es mínima, consiguiéndose así una iluminación constante,

homogénea y difusa, o sea, un ambiente completamente controlado. La parte inferior de la cámara de iluminación está construída de tal manera que permita adicionarle en el futuro una cinta transportadora, con lo que se evitará colocar las frutas manualmente frente al sistema de inspección como se hizo en este trabajo.

4.1.1.4. Fondo de las imágenes. Durante la adquisición de las imágenes de las naranjas se hicieron varias pruebas para establecer el fondo más adecuado. El primer aspecto que se debe tener en cuenta es que este debe tener componentes de color, en lo posible, suficientemente disímiles a las frutas sanas o defectuosas, además debe contener colores y texturas uniformes de tal manera que la detección de la fruta en la imagen no se convierta en una tarea incluso más difícil que la detección y reconocimiento de los defectos.

Primero se pensó en un fondo totalmente saturado de tal manera que se consiguiera un alto contraste con los defectos, que por lo general son oscuros, pero esto constituyó un problema debido a que se usan polarizadores que producen coloraciones espurias principalmente en las partes altas de los niveles de gris. Las pruebas con un fondo oscuro, con el que generalmente fabrican las cintas transportadoras, fueron satisfactorias principalmente porque la detección de la fruta en la imagen no representa un problema complejo y los defectos de la piel de la fruta son, en su mayoría, oscuros pero no tienen un valor tan bajo de nivel de gris como el negro, con lo que es posible diferenciarlos. Así es que en la toma de las imágenes se utilizó un fondo negro.

4.1.1.5. Software. Como se ha descrito anteriormente, la plataforma de desarrollo para el sistema de inspección es el QWin/QUIPS, corriendo en una estación de procesamiento de imágenes Leica Q550IW, como la que se ilustra en la figura 12. Se realizaron varias rutinas en el lenguaje de macro-programación que posee QUIPS. El sistema solo brinda herramientas para el procesamiento y análisis avanzados de imágenes, pero no posee librerías para el procesamiento numérico de datos, y menos para el reconocimiento de patrones, elementos esenciales en un sistema de visión artificial. Afortunadamente permite realizar enlaces dinámicos DDE, con lo que se puede comunicar con otras aplicaciones corriendo sobre la máquina al mismo tiempo.



Figura 12. Estación de procesamiento de imágenes Leica Q550IW

En este caso, para el reconocimiento de patrones se implementó y entrenó sobre Matlab una red neuronal tipo perceptrón multicapa de tres capas alimentada hacia delante y entrenada mediante el algoritmo de retropropagación. QWin envía las características extraídas a las imágenes durante el análisis a Matlab, que al recibirlas, las normaliza y se le entrega a la red neuronal. El resultado arrojado se envía de vuelta a QWin para que muestre la imagen, junto con los defectos, demás parámetros detectados y el resultado final obtenido.

Esta forma de realizar el procesamiento puede ser muchas veces lenta porque la estación de procesamiento de imágenes, como es basada en PC, fue diseñada para análisis fuera-de-línea, por lo que es muy difícil con este equipo establecer sistemas de procesamiento en tiempo real si se trata de sistemas de alta velocidad. No obstante, los resultados obtenidos son buenos, por lo que los algoritmos se podrían trasladar a máquinas industriales u otros sistemas a la hora de implementar el sistema en ambientes de procesamiento altamente masivo.

4.1.2. Adquisición de las imágenes y toma de muestras. Las imágenes que se utilizan en este trabajo son a color, la adquisición se realiza a la resolución de la cámara, que cuenta con una resolución espacial de 768 x 494 píxeles, sin embargo, la fruta cubre un región de la imagen de tal manera que es posible limitar el tamaño a un cuadrado de 440 píxeles de lado.

En cuanto a la definición, cada canal posee una profundidad de 256 niveles de gris, que se pueden almacenar en 8 bits (1 byte) por píxel. Como se trata de una imagen en color, se deben manipular 3 canales por píxel, con lo que la imagen se almacena en un arreglo de 24 bits (3 bytes) por píxel, para un total de 567 KB. Cada imagen se almacena en formato TIFF o BMP, que fueron elegidos debido a que en estos, aunque el tamaño de archivo resultante es un poco grande, no hay pérdida de información debida a los algoritmos de compresión. Así mismo, al operar con imágenes comprimidas el proceso de decodificación puede ser un factor más de consumo del tiempo del procesador.

Para la adquisición de las imágenes las frutas fueron colocadas manualmente frente a la cámara CCD, dentro de la cámara de iluminación, y se tomaron imágenes tanto de la parte superior (hemisferio en el que se encuentran el pedúnculo y el cáliz) como de la parte inferior, almacenándolas en el disco duro, de este conjunto de imágenes se establecerán los conjuntos de entrenamiento, prueba y validación de forma aleatoria.

4.1.3. Detección de bordes y mediciones geométricas

4.1.3.1. Detección de bordes. Los bordes hacen parte fundamental de la geometría del objeto, por esto es importante tener procedimientos que ofrezcan la posibilidad de extraer la información de los límites de los objetos de manera fiable. En este caso, la ventaja es que se cuenta con un ambiente controlado para la adquisición de las imágenes, de tal manera que el fondo escogido maximiza el contraste para facilitar la extracción de los bordes.

Para esta tarea se aprovecha el resultado obtenido en la fase inicial, en donde se extrae la zona de ubicación de la fruta, con lo que se obtienen los bordes con buena exactitud, se usan los algoritmos de morfología matemática binaria para encontrar los bordes mediante una operación de erosión o dilatación y una comparación lógica. De esta manera se pueden lograr bordes completamente definidos, diferente a lo que sucede con los algoritmos basados en núcleos de convolución [71].

Para el uso de los núcleos de convolución se buscan discontinuidades utilizando una máscara sobre la imagen. Para una máscara de 3 x 3 este procedimiento implica realizar la suma de los productos de los coeficientes con los niveles de gris contenidos en la región delimitada por la máscara. Esto es, la respuesta de la máscara en cualquier punto es:

$$R = w_1 z_1 + w_2 z_2 + \dots + w_9 z_9 = \sum_{i=1}^9 w_i z_i . \quad (6)$$

Normalmente, la respuesta de la máscara está definida con respecto al centro de su localización. Cuando la máscara está centrada en un píxel del borde de la imagen, la respuesta se calcula en función de la vecindad parcial apropiada. El problema es que debe implementar un algoritmo de enlazado a continuación, cuestión que se evita con la extracción de bordes basada en los operadores morfológicos, aunque estos, si no se aplican adecuadamente, pueden ser muy intensivos.

4.1.3.2. Cálculo de las características geométricas. Para la cuantificar los parámetros dimensionales de la fruta se realiza la extracción de las características geométricas para lo que se distinguen los siguientes pasos:

- Elaboración del código de cadena de los bordes
- Cálculo del área y perímetro de la fruta
- Cálculo del centro de masa
- Cálculo del eje principal y estimación del radio de la fruta

El código de cadena [43, 54] consiste en la codificación de los datos para la descripción del borde de un objeto en una imagen binaria. Únicamente se almacenan las coordenadas del píxel inicial, el código restante representa las direcciones seguidas por los píxeles vecinos sucesivos hasta completar el recorrido de todo el contorno.

La revisión de los vecinos se puede realizar considerando vecindades de 8 o 4 píxeles, o sea, en todas las direcciones o solo vertical y horizontalmente. De esta manera, el código de cadena representa el contorno completo de un objeto de forma compacta. La ventaja es que permite calcular el perímetro, el área y otros parámetros del objeto sin necesidad de realizar el conteo de píxeles sobre la imagen, lo que hace que los cálculos se realicen de manera mucho más rápida.

4.1.3.3. Errores geométricos. Debido a la perspectiva cónica con respecto al volumen del fruto, la relación entre el radio del fruto captado por la cámara y el radio real es diferente a la unidad. Esto no representa problema en este caso debido a que los parámetros establecidos para el sistema dan una relación superior a 0.995 [1], por lo que el error es despreciable.

El error que no es despreciable es el error de curvatura cuando se tratan de inspeccionar objetos que no son planos. Este es debido a que el tamaño efectivo de la

imagen que representa un píxel aumenta con el ángulo de inclinación de la superficie, que idealmente debe permanecer paralela al sensor. En el caso de las frutas redondas, la curvatura del fruto ocasiona que la superficie representada por un píxel sea mayor para aquéllos elementos situados en la periferia del fruto.

Para resolver esto se deben tener en cuenta el radio promedio de un fruto, el área nominal del píxel y el área real o área efectiva que representa [1]. El radio promedio de un fruto es de 40 mm, el área nominal del píxel en este caso es de 0.176 mm^2 , al hallar la superficie real del píxel sobre la superficie esférica se obtiene el factor de corrección para la zona, tal como se observa en la columna derecha de la tabla 7.

Tabla 7. Cálculo de los parámetros para establecer el área efectiva de un píxel

Radio (mm)	Area real (mm²)	Área real/ Área nominal
0-10	0.181	~1
10-18	0.202	1.15
19-26	0.257	1.46
27-35	0.301	1.71

Fuente: Este estudio

El factor de corrección se utilizará en la etapa de cuantificación de los defectos, también es útil para análisis del contenido de color, si se trata de frutas coloreadas heterogéneamente.

4.2. EXTRACCIÓN DE CARACTERÍSTICAS. VISIÓN DE MEDIO NIVEL

4.2.1. Segmentación. Con la segmentación se intenta dividir la imagen entre las regiones que contienen los defectos y las que contienen piel sana u otras regiones de interés. La ventaja principal es que se pueden determinar la localización y la forma de los defectos discretos. También puede determinarse con precisión la categoría del

defecto, ya que la extracción de las características puede dirigirse al área del defecto específicamente.

4.2.1.1. Método de segmentación. Como explicó en la sección 2.1.3, la segmentación es basada en algunas características que son relativamente uniformes y homogéneas dentro del área segmentada, y que difieren de las características del área circundante.

En este trabajo, el método usado para la producción de características en la segmentación es el umbralizado orientado a píxeles, aunque se hacen pruebas con el umbralizado orientado a regiones. Con este último, se calcula el número de píxeles umbralizados dentro de las regiones pequeñas de tamaño fijo. Si hay bastantes píxeles umbralizados en la región, esta es considerada una región segmentada. No se requiere conectividad de los píxeles dentro de la región. En la sección 4.4 hay un ejemplo que muestra los resultados de este método.

Las ventajas principales del umbralizado orientado a regiones sobre el umbralizado orientado a píxeles tradicional son: tiene la propiedad de agrupación, alivia el cálculo de características en las fases siguientes y los requisitos del umbral son menos estrictos.

La propiedad de agrupación supera el problema de las regiones angulosas y desconectadas del umbralizado orientado a píxeles. Lógicamente, también el análisis orientado a píxeles puede diseñarse para permitir brechas entre las áreas vecinas, esto a costa del aumento en la complejidad del análisis de conectividad.

El alivio del proceso en las fases siguientes se da por la reducida cantidad de datos. Si el tamaño de la región es 8×8 píxeles, la imagen del bloque resultante es de sólo $1/64$ del tamaño de la imagen original y esto causa una reducción de los recursos de

procesamiento para el análisis de conectividad y para el cálculo de las características de forma.

Los requisitos menos estrictos para el umbral significan que el umbralizado orientado a regiones no es tan sensible al valor del umbral como lo es el umbralizado orientado a píxeles. Con el umbralizado orientado a regiones, la región se detecta similarmente aún cuando el número de píxeles umbralizados dentro de una región varíe de un número mínimo requerido al número máximo de una región totalmente umbralizada. Esto afecta, por supuesto, a las características si se usa el número de píxeles umbralizados como momentos, aunque la ventaja es que se pueden usar valores de umbral más lejanos de los valores de la piel sana para evitar demasiadas falsas alarmas.

Como es lógico, el umbralizado orientado a regiones también tiene desventajas y tienen que ver con que se obtiene una aproximación tosca de la forma real del defecto original y se forman agrupamientos indeseados de defectos localizados muy cerca entre sí.

Una forma tosca para los defectos no es un problema grave para las características si lo que interesa no es la forma en sí, sino el área y distribución general, ya que las cantidades pequeñas del área de piel sana, posiblemente visible alrededor del área del defecto, no afectan mucho los valores de las características. Debido a que, en principio, la mayoría de los defectos son *blobs* convexos, para mejorar la estimación de las dimensiones, la forma puede ser estimada ajustando una elipse a las regiones segmentadas, pero esto no es preponderante para los objetivos de este trabajo investigativo, por lo que no se realiza.

Si las áreas segmentadas de los defectos separados son más cercanas entre sí que el tamaño que tiene la región, no es posible evitar los agrupamientos indeseados. El tamaño de la región debe seleccionarse según la distancia más pequeña entre dos defectos separados si se desea evitar los agrupamientos [72]. Las pruebas realizadas

ofrecieron mejores resultados con el umbralizado orientado a píxeles, sobretodo porque para el sistema se necesitan estadísticas sobre las distribuciones de los defectos, que son proporcionadas por el área y la disposición física de cada uno de estos sobre la superficie de la fruta.

La umbralización, sea orientada a píxeles o a regiones se puede ver como una operación que implica realizar comprobaciones frente a una función T de la forma:

$$T = T[x, y, p(x, y), f(x, y)] \quad (7)$$

donde $f(x, y)$ es el nivel de gris del punto (x, y) y $p(x, y)$ representa alguna propiedad local de ese punto, por ejemplo, el valor del tono o la saturación. De esta manera, la imagen umbralizada $g(x, y)$ está definida por:

$$g(x, y) = \begin{cases} m, & \text{si } f(x, y) > T \\ 0, & \text{si } f(x, y) \leq T \end{cases} \quad (8)$$

con lo que los píxeles marcados con m corresponden a la zona del objeto umbralizado o detectado, mientras que los marcados con 0 corresponden al fondo.

4.2.1.2. Determinación del umbral. En el umbralizado orientado a píxeles, el valor del umbral es un parámetro importante. Si las condiciones de adquisición son estables y el material de análisis es homogéneo, como en este caso, puede usarse un valor de umbral fijo. El umbralizado orientado a regiones tolera bastante bien las variaciones pequeñas, ya que, por ejemplo, cinco píxeles umbralizados dentro de la región producen una región detectada de la misma manera que lo hacen 50 píxeles. Lo único que esto afecta son las características de forma descritas al momento de usar el número de píxeles umbralizados.

Si la variación de la intensidad de la superficie es grande, se necesita la habilidad de adaptar el umbral a la luminosidad u oscuridad general de la superficie de la fruta. Si la superficie de la fruta es clara, el umbral debe ser más alto que el umbral para la oscura.

Las áreas sanas de la fruta son adecuadas para la determinación de un umbral adaptable y pueden ser obtenidas con frutas completamente sanas bien representativas durante la fase inicial de inspección. Los histogramas pueden ser útiles para el cálculo del valor de umbral. La aproximación más simple para determinar el umbral es relacionarlo con los valores mínimos del histograma total, ya que los defectos típicamente tienen una intensidad más baja que la piel sana en los canales de color.

En lugar del valor mínimo, pueden establecerse comparaciones sobre otras características. Por ejemplo, relacionando el umbral con los percentiles de color por medio de mínimos cuadrados lineales. Para determinar la relación, los datos tienen que ser colectados para varias frutas sobre los valores buenos de umbral y los percentiles de la fruta limpia correspondientes, que deben representar las variaciones de toda la fruta tan bien como sea posible para que sea umbralizada.

El problema de los umbrales adaptivos es que, si la fruta es oscura o muy defectuosa, es posible que no se produzca área alguna de fruta sana como base para la determinación del umbral. En este caso, el umbral puede tomarse basado en la historia de los valores anteriores del umbral o , por ejemplo, en el área más clara encontrada en la imagen. Pero esto también es problemático, ya que es posible que la sección no tenga áreas sanas, entonces la determinación del umbral puede ser basada en el histograma total que también contiene áreas defectuosas de la imagen completa o de algunas partes de él.

La adaptabilidad también puede ser lograda produciendo una imagen de fondo, y luego substrayéndola a la original. En la imagen diferencia resultante, las variaciones del fondo desaparecerán, y pueden aplicarse umbrales fijos. Aunque, en este caso, se

deben cumplir a cabalidad los requerimientos para un sistema de iluminación completamente uniforme, que no altere la iluminación del fondo adyacente al objeto analizado, si no es así, es posible que se deba resolver un problema aún más complejo.

En el caso de la determinación del umbral basado en el histograma se pueden tener algunos problemas. El tamaño del área donde se calcula debe ser bastante grande para proporcionar estadísticas suficientes, y por otro lado, suficientemente pequeño para adaptarse a los cambios de la superficie de la fruta. Un conjunto de frutas aparentemente similares puede tener una variación notable de intensidad; el tamaño del área de apoyo para la compilación del histograma, por ejemplo, 1, 10 o 100 frutas, depende de las propiedades de estas y debe elegirse en pruebas experimentales.

4.2.1.3. Análisis conectividad. Después de realizar la segmentación, se realiza el análisis de conectividad a las regiones segmentadas para encontrar las regiones que pertenecen a los mismos objetos. La conectividad de los píxeles de la imagen de bloques vecinos se analiza con un algoritmo de conectividad 8 que examina los píxeles vecinos en todas las direcciones alrededor del píxel bajo análisis. El análisis de conectividad produce una imagen etiquetada, donde los píxeles pertenecientes al mismo *blob* conectado tienen el mismo valor. Esta tarea es realizada por una función de morfología matemática denominada etiquetado, que asigna un nivel de gris diferente a cada defecto conectado.

Esta información es importante luego para el establecimiento de las estadísticas de los defectos encontrados en la fruta, como son: conteos, cálculo del tamaño, relación de aspecto, perímetro, entre otros.

4.2.1.4. Características de forma. Durante el análisis de conectividad pueden recogerse y almacenarse características de forma para los *blobs*. Éstos incluyen por ejemplo, coordenadas mínima y máxima de la caja limitante, área, número de píxeles

umbralizados, distancia al borde más cercano, los momentos y las características derivadas de estos, como las longitudes de los ejes principales, la relación de aspecto, la redondez y el ángulo. Estas características pueden usarse como guía para un análisis posterior de los *blobs* en la fase del análisis contextual.

4.2.2. Cálculo de las características de color. En el método de segmentación, los *blobs* han sido preclasificados por análisis contextual, y de estos se calculan las características relativas al color. En el método de segmentación, las características se calculan con la ayuda de la máscara dada por la detección del fondo y del contenido de defectos. Por lo general, en la detección de los defectos se debe permitir detectar algún exceso de área de piel sana para mejorar el cálculo de las características de color, ya que se asegura que las mediciones se realicen realmente sobre zonas de piel sana.

La selección de las características de color a ser calculadas depende del problema. Si las características se calculan por primera vez para las muestras de entrenamiento, entonces se calcula un conjunto grande de estas para que sean reducidas por el algoritmo de selección de características. Si las características a ser usadas son conocidas, sólo se calculan estas.

Ya que la intensidad de la fruta cambia de muestra a muestra, e incluso dentro de la misma fruta, esta necesita ser compensada por las características. Las características que se forman con las diferencias o razones pueden adaptarse a cambios de intensidad en alguna magnitud, pero de esta manera puede perderse un poco de información.

4.2.3. Características del histograma de color. Las características de color usados en este trabajo son basadas en los parámetros obtenidos de los histogramas unidimensionales de los canales de color R, G, B, H, S e I. Los parámetros del histograma son simples de calcular y, así, adecuados para aplicaciones de tiempo real. Se pueden capturar detalles importantes del histograma de color, como se discutirá en

la sección siguiente. Se usaron los espacios de color RGB y HSI, aunque se podría probar con otros canales, que, por la forma como han sido concebidos, pueden ser más adecuados para la medición del color. En este caso las estadísticas usadas son la media y la varianza dentro de los canales de la zona de interés, como la parte sana de la piel de la fruta.

4.2.4. Análisis de texturas. La textura es un parámetro que en principio no fácil de manejar con herramientas poco sofisticadas. Para un análisis realmente concluyente es necesario aplicar conceptos las estadísticas de segundo orden, como las matrices de co-ocurrencias, la transformada discreta coseno o la transformada *wavelet*, que poseen parámetros a partir de los cuales se extraen innumerables características, útiles de acuerdo a la aplicación [58, 73].

El análisis de texturas inicialmente estuvo principalmente ligado a imágenes en niveles de gris, las necesidades han hecho que se desarrollen métodos para la extracción de características de texturas en color como se puede ver en el anexo. En el caso de las matrices de co-ocurrencias, se pueden extraer características análogas a las que se obtienen con los histogramas unidimensionales, solo que están describen la distribución de la información en forma bidimensional.

4.2.5. Selección de características. Cuando se ha realizado la extracción de características, por lo general se obtiene una cantidad de información en la que no es posible establecer la que es importante o redundante, de tal manera que se permita establecer un criterio para reducir el volumen de datos. Esto, por lo general, se debe hacer cuando existe una elevada cantidad de variables, donde el espacio de características poseerá muchas dimensiones, haciéndose difícil y compleja su manipulación.

Después de la segmentación pueden derivarse un gran número de características de la imagen tanto en color como en niveles de gris. Sin embargo, en la clasificación de los

defectos, el número de las características debe ser relativamente pequeño, ya que el cálculo y la comparación de estas consumen un tiempo considerable. Al usar demasiadas características también se puede confrontar un problema de dimensionalidad que causa que la tasa de clasificación se deteriore cuando se agregan nuevas características para resolver el problema.

Las pruebas han mostrado que son suficientes unas cuantas características bien seleccionadas para producir resultados de clasificación que, típicamente, no pueden mejorarse agregando nuevas características, o el costo de la implementación no justifica la ganancia en exactitud del clasificador. El problema es cómo seleccionar un juego de características que contengan la información discriminativa esencial para el problema de clasificación.

Existen métodos estadísticos de análisis para la selección de características como el análisis de discriminante paso a paso o el análisis de componentes principales. Se usan si no es posible que el diseñador pueda establecer de manera simple o directa las características que son preponderantes para la alimentación del clasificador.

En este trabajo se usa un método empírico para seleccionar un buen conjunto de características. Es basado en las pruebas de clasificación hechas con combinaciones diferentes de características a partir del material de entrenamiento que es importante en el problema de clasificación. Se selecciona el conjunto de características que proporciona un resultado de clasificación satisfactorio. También se hace una revisión para establecer las características más estrechamente correlacionadas y eliminar las redundantes con el fin de evitar que se sature el clasificador y no pueda generalizar apropiadamente los patrones que se le presenten.

Cuando dos variables están altamente correlacionadas significa que estas describen más o menos la misma información y al incluirlas en el clasificador se le estaría proporcionando información redundante, que a la larga es también un problema. Por ejemplo, el volumen y el peso tienen alta correlación, por lo que, en principio, a partir

del volumen se puede obtener el peso y viceversa. Por lo tanto un parámetro de entrada del clasificador debe incluir solo una de estas o una combinación entre las dos, como el producto o el cociente, que permita elevar los niveles de discriminación.

Una búsqueda completa a través de todas las combinaciones posibles de las características produce una selección óptima de características para el material de entrenamiento, pero demanda cantidades típicamente grandes de recursos computacionales. Por ejemplo, el número de combinaciones de 15 características a partir de 100 posibles es aproximadamente de $2.5 * 10^{17}$. Con un computador capaz de realizar un millón de clasificaciones por segundo, la revisión a través de todas las combinaciones tomaría más de 8000 años, si el resultado para una combinación de características se decide sobre la base de una clasificación. Esto constituye lo que se denomina una aproximación por fuerza bruta, pero el problema se puede enfrentar con aproximaciones más ingeniosas y factibles.

El problema de la búsqueda de características es que el conjunto obtenido puede especializarse mucho para el material de entrenamiento. En este caso, el resultado de la clasificación para un material desconocido puede ser notablemente deficiente comparado con el resultado para el material de entrenamiento. Esto se puede evitar intentando no alcanzar el mejor resultado posible, y aceptar un resultado de una dimensión más baja que la obtenida para un resultado completamente satisfactorio, es decir, se busca generalización en vez de memorización.

Un aspecto importante es que el conjunto de entrenamiento debe contener bastantes muestras representativas de los defectos de todas las categorías a ser clasificadas. Esto significa preferiblemente cientos de muestras por la clase, en lugar de sólo unas pocas. La importancia de una clase y el nivel de dificultad de su clasificación determina el número relativo de muestras necesario para cada clase.

Una regla general es que por cada clase que se necesite discriminar se debe contar aproximadamente con un número igual de muestras. Normalmente los tipos raros de

defectos deben representarse mejor de lo que implica su número relativo en el material disponible, es decir, el sistema debe tener información completa acerca de estos, para evitar que, cuando aparezcan, se confunda o no pueda decidir.

Para seleccionar las características, algunas veces es obvio que algunas tienen correlaciones muy altas, como sucede con el área, el perímetro y el diámetro que, en las mediciones realizadas, dieron coeficientes de correlación superiores a 0.99. La figura 13 da una muestra de la forma como están relacionadas el área y el perímetro de la imagen de la fruta.

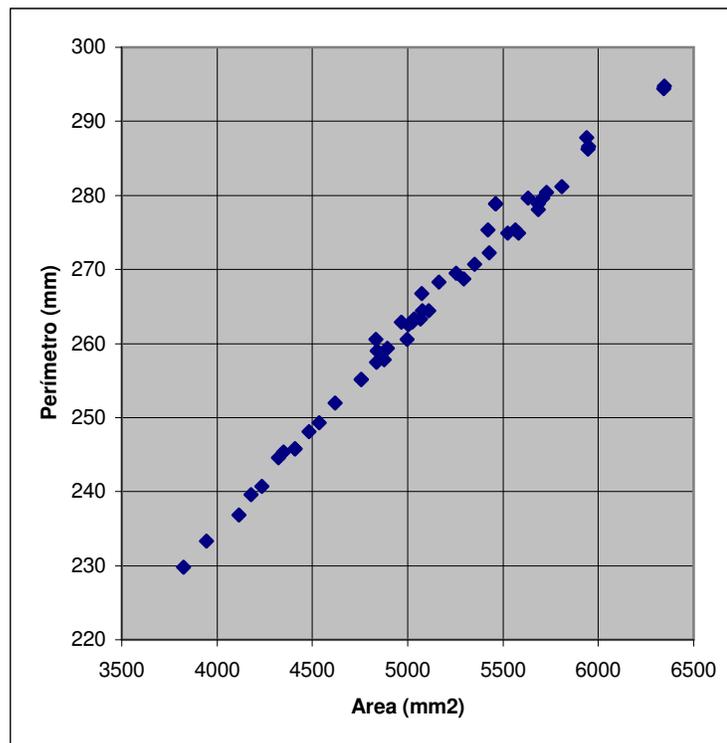


Figura 13. Correlación del área y el perímetro

Como para el clasificador se buscan características que estén poco correlacionadas entre sí, se hace el análisis de las variables que presentan estas propiedades. Por ejemplo, en la figura 14 se puede observar la forma como se relacionan el perímetro y la redondez, la nube de puntos está tan dispersa que no parece seguir un patrón bien

definido como sucede en la figura 13. En este caso el coeficiente de correlación fue de 0.103, lo que indica que no hay una relación directa. Para muchas características es posible que no haya necesidad de hacer los cálculos porque la falta de relación es evidente, como en este ejemplo que se coloca solo a manera de ilustración.

Si se buscaban coeficientes de correlación bajos para las características de entrada al clasificador, para las características que se desean predecir es necesario encontrar la característica que la describe de la manera más precisa posible, es decir, con la que correlacione mejor. En este caso se desea que el sistema proporcione un estimativo del peso de la fruta basado en los parámetros geométricos que capta la cámara. Es lógico que, si las frutas poseen densidad uniforme, entre más grandes, más pesadas serán.

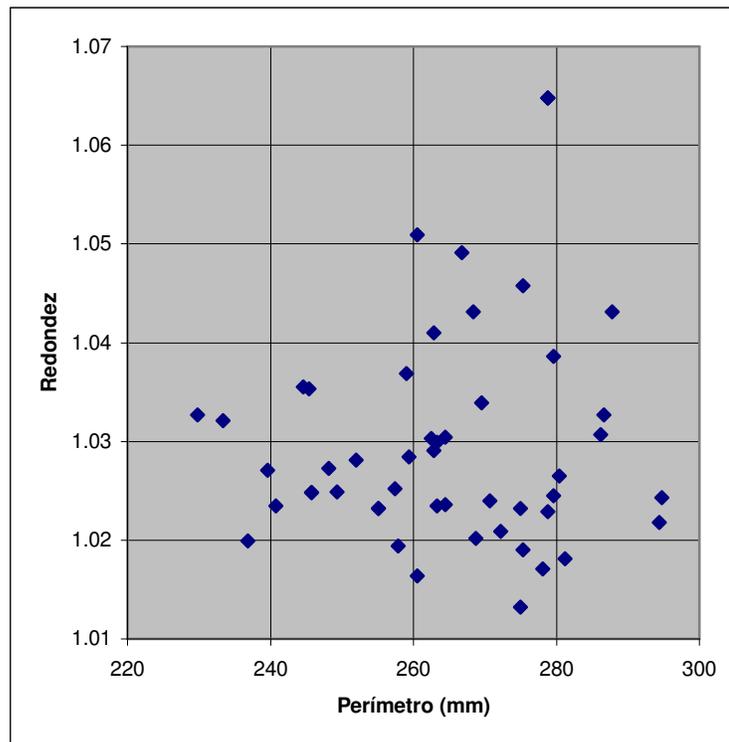


Figura 14. Correlación del perímetro y la redondez

Se deben estudiar entonces las correlaciones del peso con características como el área, perímetro y diámetro, que por su alta correlación entre sí, daran correlaciones muy similares con el peso. La cuestión es encontrar la que dé el resultado más alto, en la figura 15 se muestra el diagrama de correlación entre el diámetro y el peso, para lo que se obtuvo un coeficiente de correlación de 0.943, los coeficientes con el área y el perímetro fueron 0.941 y 0.931 respectivamente.

Es interesante observar que en la parte baja de la figura 15 el coeficiente de correlación es más alto, por lo que para naranjas menores a 78 mm de diámetro se puede estimar con más precisión el peso, para las naranjas mayores a 78 mm, el error en la estimación es mayor. En este caso la correlación para naranjas mayores o iguales a 78 mm es de 0.8378, lo que implica que se puede estimar el peso con un error de ± 12 gr, mientras que para las pequeñas (< 78 mm) la correlación es de 0.9449, con lo que el error se reduce a ± 4 gr

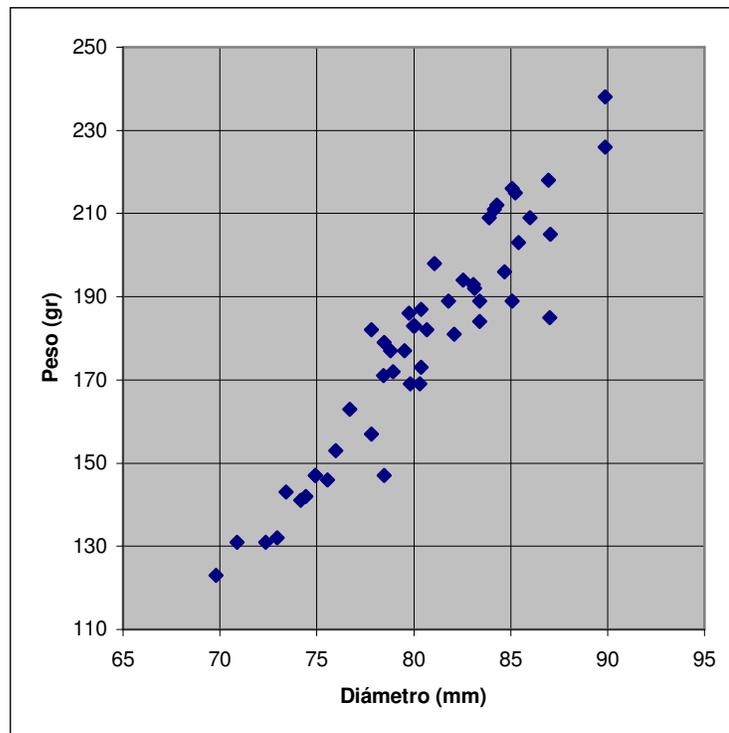


Figura 15. Correlación del diámetro y el peso

4.3. CLASIFICACIÓN Y EVALUACIÓN. VISIÓN DE ALTO NIVEL

4.3.1. Análisis contextual. La información contextual, como la forma, orientación y localización de los *blobs* en la superficie de las frutas puede usarse para hacer suposiciones sobre la forma en que los defectos podrían estar repartidos en las categorías preliminares. Esto aliviará la clasificación posterior. Ya que hay menos clases a ser separadas, la clasificación probablemente puede realizarse con un número más pequeño de características especializadas para cada categoría, y posiblemente algunas no necesiten un cálculo y clasificación adicional de las características.

Al realizar el análisis contextual se debe usar el conocimiento proporcionado por el usuario sobre la localización y la forma de las diferentes categorías de defectos. En este trabajo la información resultante del análisis contextual (posición de la fruta) es entregada directamente al clasificador, junto con las demás características.

La posición de la fruta afecta la apariencia visual de los defectos. Si el lado es conocido de antemano, puede usarse como una característica contextual. No deben encontrarse defectos que sólo aparecen en el lado del pedúnculo en la región inferior. Si el lado de la superficie no es conocido, puede determinarse a partir de los tipos de defectos que aparecen en esta.

Las características contextuales calculadas de los píxeles dependen de la resolución de la adquisición, de aquí que un algoritmo dado funcione correctamente para las imágenes de las naranjas, no para las naranjas, ya que, como se notó, la formación de la imagen depende de muchos factores. Si la resolución de la adquisición no es constante, las características deben calcularse de las dimensiones reales, convertidas de las dimensiones de los píxeles de los defectos, con ayuda del sistema de referencia.

Las características contextuales generales son relativamente fáciles de encontrar y son válidas para muchas frutas. Debido a la alta variabilidad de los defectos en las frutas, siempre hay excepciones. Las reglas no deberían ser tan detalladas, sino más bien de

un nivel general que produzcan clasificaciones aceptables para la mayoría de los defectos.

4.3.2. Clasificación de los defectos. Es aquí donde se debe tener tomar la decisión del clasificador que se utilizará. Como se dijo anteriormente, se hará uso de las metodologías proporcionadas por el reconocimiento estadístico de patrones. El clasificador se escoge de acuerdo a la información y los recursos disponibles. En cuanto a la información, si se tienen las estadísticas *a priori* y las expresiones generales de las funciones de densidad de probabilidad en el espacio de características de cada una de las clases, se pueden utilizar clasificadores paramétricos como el esquema de clasificación de Bayes, que consiste en la minimización de la función de costo del sistema.

Al no tener acceso a esta información es necesario implementar un clasificador no-paramétrico. En este caso, en el momento del aprendizaje, el clasificador se adapta a los requerimientos para proporcionar las salidas mejor ajustadas a los requerimientos, donde, de manera indirecta, también se minimiza la función de costo. Algunas veces se presentan inconvenientes debidos, principalmente, al desconocimiento del espacio de características como un todo, situación que no sucede con los clasificadores paramétricos. Entre los clasificadores no-paramétricos se pueden enumerar las redes neuronales y los *k*-vecinos más cercanos (*k*NNs, por sus siglas en inglés).

Para las labores de clasificación de este trabajo se han elegido las redes neuronales por la gran versatilidad y facilidad de uso que tienen. El único inconveniente que presentan para la aplicación es que el entrenamiento puede ser intensivo computacionalmente, por lo que puede tomar algún tiempo. Pero esto no es de importancia ya que el entrenamiento solo se realiza una vez, al inicio de la configuración del sistema, cuando se le presentan por primera vez los patrones que debe clasificar. Durante la operación como tal, la red neuronal es suficientemente rápida y no representa problema alguno, sobre todo si se implementa en hardware.

El clasificador, compuesto por un perceptrón multicapa de arquitectura 7:12:5, se entrena con el vector de características extraído de las imágenes de muestra después de la segmentación. Se utilizaron las características de 45 frutas para el entrenamiento de la red neuronal. Una vez entrenada, se evaluó aplicando las características del conjunto de prueba, lo importante es que ninguna de estas muestras haya estado en los datos usados para el entrenamiento. En esta fase de evaluación se estimó la eficiencia y fiabilidad del clasificador y el sistema en general para la identificación y cuantificación de los daños.

En general, no hay una alternativa mejor que las demás para escoger un clasificador, este debe seleccionarse según los requisitos y la naturaleza del problema de clasificación. La escogencia normalmente es un compromiso entre aspectos como la exactitud de la clasificación, la complejidad de entrenamiento y clasificación, y la posibilidad de que el usuario pueda ajustar la tasa de la clasificación [65, 74].

Se pueden comparar los clasificadores para verificar cual arroja la mayor exactitud o cual lo hace con mayor velocidad en una la aplicación dada. Los experimentos indican que la tasa de clasificación de los diferentes clasificadores parece ser bastante similar, las diferencias están en la complejidad de la aplicación y en el uso específico del clasificador.

Se requiere un escalado correcto de las características para que a la red neuronal se le proporcionen datos del mismo rango en las entradas. Las características diferentes deben tener un rango similar de valores para tener pesos iguales en el cálculo del parámetro que se le entregará a la función de activación. El rango de valores es obtenido típicamente normalizando los valores de cierta característica para localizarla entre unos valores mínimo y máximo, o para tener un ciertas media y desviación.

Una ventaja del clasificador neuronal, y la razón de por qué se usó en los experimentos, es la simplicidad y comodidad de uso. No se necesita conocimiento *a priori* de las funciones de distribución de las características. Ya que la clasificación es

basada directamente en las muestras de entrenamiento, estas deben seleccionarse cuidadosamente, como discutió con el algoritmo de selección de características.

4.3.3. Entrenamiento del clasificador. En la Figura 3 se muestra de manera general el diagrama de un sistema de visión artificial simplificado y consiste en un preprocesador de la imagen, un detector de defectos, un extractor de características, y un clasificador. El interés principal en esta sección es describir cómo el operador, una persona, realiza el entrenamiento y operación del clasificador.

La clasificación es supervisada si las clases son conocidas *a priori*, y no supervisada si no lo son, a continuación se describen las aproximaciones supervisadas y no supervisadas.

4.3.3.1. Clasificación supervisada. El entrenamiento supervisado de un clasificador significa que el entrenamiento es realizado con un profesor, con el objetivo de minimizar la diferencia promedio esperada entre la clasificación deseada para las muestras de entrenamiento y la clasificación actual. En el sistema de inspección implementado en este trabajo se usa el entrenamiento supervisado.

Se escogen las muestras de entrenamiento con las características a partir de la detección de defectos. Las muestras de entrenamiento son etiquetadas y se proveen como datos de entrenamiento al clasificador y los resultados de la clasificación se pueden observar revisando los defectos clasificados.

El problema con la aproximación supervisada es que el proceso de etiquetado manual necesario, muestra por muestra, es propenso a errores. En algunos casos es difícil para un humano discriminar entre las diferentes clases de defectos. Como resultado, las muestras de entrenamiento pueden ser etiquetadas inconsistentemente, lo que resulta en una degradación de la precisión en la clasificación. Por ejemplo, los límites de las clases entre varios tipos de manchas no están completamente definidos y una

persona puede confundirlas fácilmente, un tipo de daño puede ignorarse o se pueden establecer etiquetas a aspectos que realmente no representan defectos.

4.3.3.2. Clasificación no supervisada. En la clasificación no supervisada, las categorías de las muestras no necesitan conocerse de antemano. La aproximación usa un método de agrupamiento para detectar si las muestras caen en un conjunto finito de categorías, por ejemplo, de acuerdo a sus relaciones de similitud [75]. Los métodos de agrupamiento incluyen agrupamiento jerárquico, métodos de partición y unión, agrupamiento por k-medias, esquemas neurodifusos, entre otros.

Como en el caso supervisado, se hace la detección de los defectos, obteniendo las características, que son alimentadas a un método de agrupamiento. Cuando se han formado las agrupaciones, estas pueden ser etiquetadas por el usuario, y, de esta manera, se ha establecido el clasificador. En otras palabras, se necesita una etapa supervisada para obtener los nombres de las clases a partir de los agrupamientos.

La ventaja de la clasificación no supervisada es que se reducen el esfuerzo para el etiquetado y los problemas debidos a los errores del etiquetado de las muestras. Esto es debido a que la decisión de los nombres de las clases no es basada en muestras individuales, sino en muestras de agrupamientos enteros.

Sin embargo, puede parecer difícil el control del clasificador basado en agrupamientos. Ya que en muchas aplicaciones de inspección visual las clases diferentes pueden parecer muy similares, por lo que tendrán agrupamientos superpuestos. Se necesitan entonces controlar los límites de los agrupamientos para ajustar la clasificación. La forma más intuitiva de hacerlo podría ser cambiando la forma de los límites de la clase. Esto es fácil en el caso de dos características, pero en un caso típico de clasificación el espacio de características tiene muchas dimensiones y la visualización del clasificador se vuelve más difícil.

4.3.4. Evaluación del clasificador. Es necesario evaluar la eficiencia del clasificador para conocer su comportamiento en un proceso de inspección con muestras que no conoce. Esto se lleva a cabo empleando muestras de prueba obtenidas de forma semejante a las usadas para el entrenamiento, para lograr resultados objetivos y realistas es importante que las muestras de prueba no se hayan usado durante el entrenamiento.

Como método de evaluación se utiliza la matriz de confusión (o matriz de errores), tal como se describió en la sección 3.3.2. La suma de la diagonal principal de esta matriz indica los frutos (defectos, objetos, etc) que han sido correctamente clasificadas, si se divide por el total de la muestra se obtiene la proporción de aciertos o fiabilidad global. La ventaja de la matriz de confusión es que detalla los errores del clasificador en cada clase, permitiendo establecer también los errores por defecto o por exceso.

En resumen, el algoritmo general para el sistema de inspección visual, partiendo de la existencia de un objeto tridimensional que se debe analizar, es el siguiente:

1. Adquisición de la imagen
2. Digitalización y almacenamiento
3. Mejoramiento y adecuación (preprocesamiento)
4. Análisis de la imagen
 - 4.1. Segmentación
 - 4.1.1. Umbralización
 - 4.1.2. Detección de bordes
 - 4.2. Procesamiento morfológico
 - 4.3. Obtención de características
5. Interpretación (Reconocimiento de patrones)
 - 5.1. Ponderación de características
 - 5.2. Comparación de patrones
6. Datos de salida
 - 6.1. Decisiones
 - 6.2. Acciones de control

4.4. RESULTADOS Y DISCUSIÓN

La figura 16 muestra la imagen digitalizada de una naranja. Se observa que la imagen tiene muy buena calidad, los bordes se observan claramente, las manchas de tamaño pequeño con bordes bien definidos aparecen realmente definidas y la separación entre estas es bien notable. En general, el contraste de la imagen es muy bueno con lo que se pueden discriminar claramente las diferentes partes de la imagen.

Las medidas para la relación señal a ruido de las imágenes obtenidas dieron un valor de 32, que es una cantidad que afirma la buena calidad de la imagen obtenida [76], por lo que el poco ruido existente distorsiona los datos de manera imperceptible.

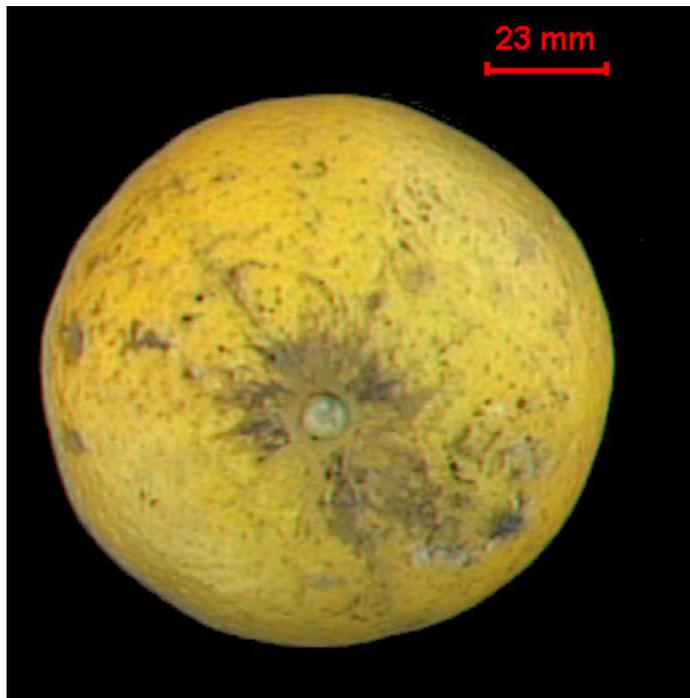


Figura 16. Imagen digitalizada de una naranja

Esto evita que se tengan que usar filtros pasabajas para eliminar ruido de baja frecuencia o de otro tipo. Como se verá adelante, las estadísticas de las distribuciones de los píxeles dentro de cada uno de los canales presentan que la imagen tiene una distribución bastante uniforme a través del rango permitido, esto es muy ventajoso ya

que se pueden minimizar los pasos de preprocesamiento y mejoramiento de la imagen.

Es notable también la ausencia de sombras y brillos en la imagen, características debidas al esquema de iluminación difusa no direccional y al polarizador apropiadamente orientado en el objetivo de la cámara, que absorbe las reflexiones especulares de los objetos con superficies dieléctricas.

Todas estas ventajas son debidas principalmente al establecimiento de un sistema de iluminación controlado, a la escogencia de un fondo apropiado y a la configuración óptima del sistema óptico de acondicionamiento y de los parámetros de la cámara CCD.

La figura también muestra una barra de calibración en la parte superior derecha que indica relación entre los píxeles en pantalla y la medida real de la zona de la imagen. El sistema de referencia, en este caso, consiste en la colocación de una regla calibrada en la ubicación para la toma de imágenes de las frutas. Esta es una forma de relacionar de manera directa, precisa y efectiva los parámetros adquiridos con las medidas reales.

En la figura 17 se presenta la descomposición de la imagen de la figura 16 en sus componentes RGB, cada canal describe la intensidad de los píxeles en un nivel de intensidad determinado por el contenido de ese componente cromático. En el caso de las naranjas se observa que el contenido del canal R (rojo) es el dominante para la fruta, por cuanto la imagen que lo describe tiene los valores más altos de intensidad.

En el caso de la imagen para el canal G (verde), es también muy significativo el nivel de intensidad alcanzado, aunque es menor al canal R, se nota la gran importancia de este componente en la descripción del color, por lo que no debe dejarse de lado a la hora de realizar los análisis. En cuanto al canal B (azul), es muy evidente la falta de contenido de este color en la piel de la fruta, definitivamente este componenete no

almacena información que permita establecer algún parámetro de interés para la clasificación.

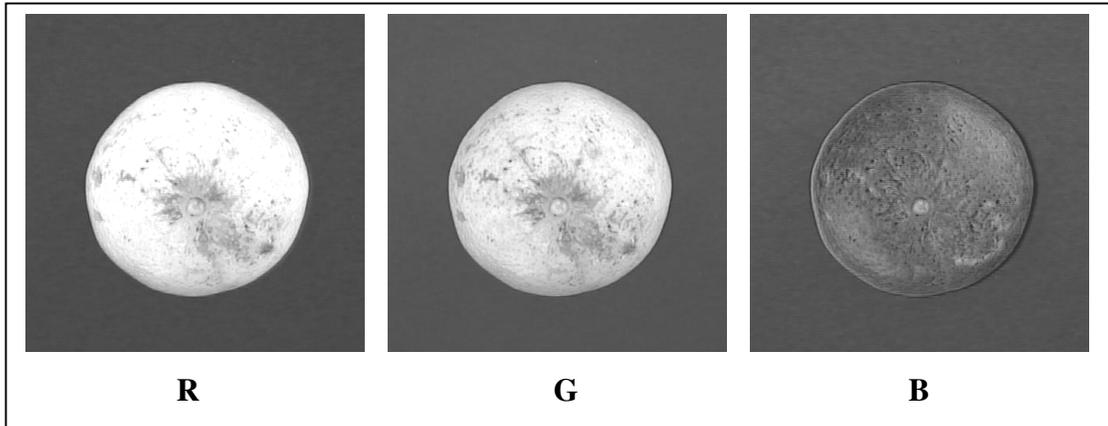


Figura 17. Descomposición de la imagen en los canales de color RGB

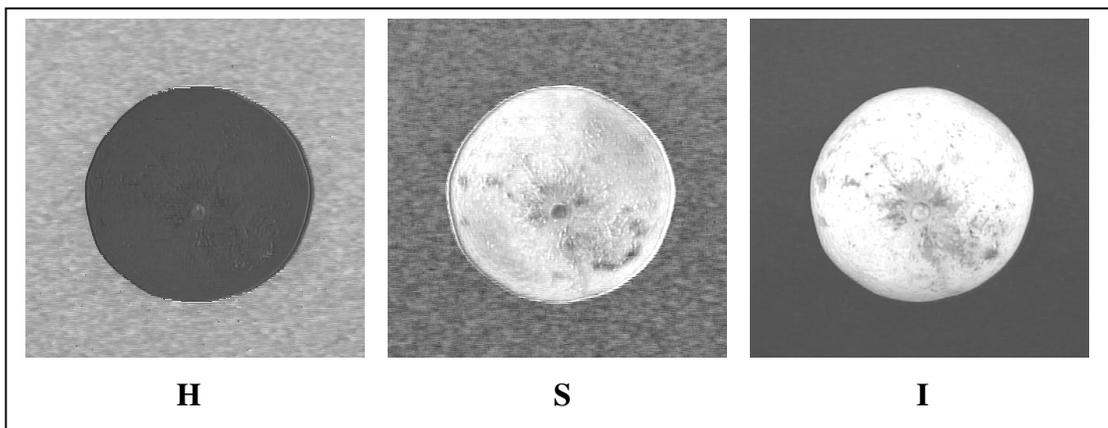


Figura 18. Descomposición de la imagen en los canales de color HSI

En la figura 18 se muestra la descomposición de la imagen en el espacio HSI. Estas imágenes también son muy descriptivas de la estructura cromática y estadística de los píxeles de la imagen de una fruta, como lo es una naranja. En el caso del canal H (tono), la piel de la naranja aparece totalmente oscura, precisamente por lo que resultó

del análisis anterior, como el color dominante es el rojo y el canal H describe el contenido cromático comenzando en las longitudes de onda más largas, al rojo le corresponde la parte baja de los niveles de la escala para la representación en la imagen. El fondo aparece un poco más claro por lo que posee algunos componentes de color de más alta frecuencia.

Para la descomposición en el canal S (saturación) se encuentra que las zonas claras pertenecen a regiones donde se encuentran colores más puros, más saturados. La piel de la naranja, por su naturaleza colorida es bastante saturada sobretodo por el alto contenido de rojo y verde. El fondo da como resultado una mezcla de colores tan poco saturados que se puede considerar que son variaciones aleatorias. En el canal I (intensidad) se observa una tendencia como la dada por los espacios RGB debido a que existe una relación directa con este espacio, el canal I representa simplemente la imagen que captará una Cámara CCD a blanco y negro sin filtros de color.

Una forma muy confiable de establecer la distribución de cada uno de los canales es mediante los histogramas para la distribución de los niveles de gris. En las figuras 19 a 24 se muestran los diferentes histogramas obtenidos para la imagen de la figura 16.

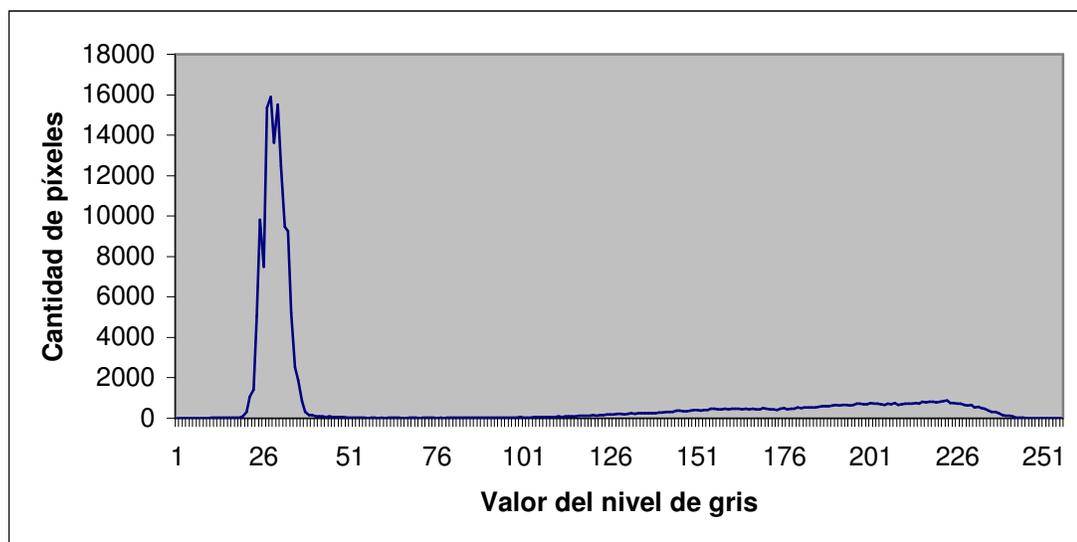


Figura 19. Histograma para el canal rojo de la imagen

En la figura 19 se observa que para el canal rojo existen dos picos que representan las componentes principales de este color para la imagen. El pico de la izquierda representa el contenido de bajo nivel de gris del fondo, en la parte derecha se tiene un pico muy ensanchado representando la amplia distribución en los niveles de la parte alta del rojo sobre la piel de la naranja. Estas apreciaciones son válidas también para el histograma del canal azul mostrado en la figura 20, ya que presentan características muy similares tal como se vión en la figura 17.

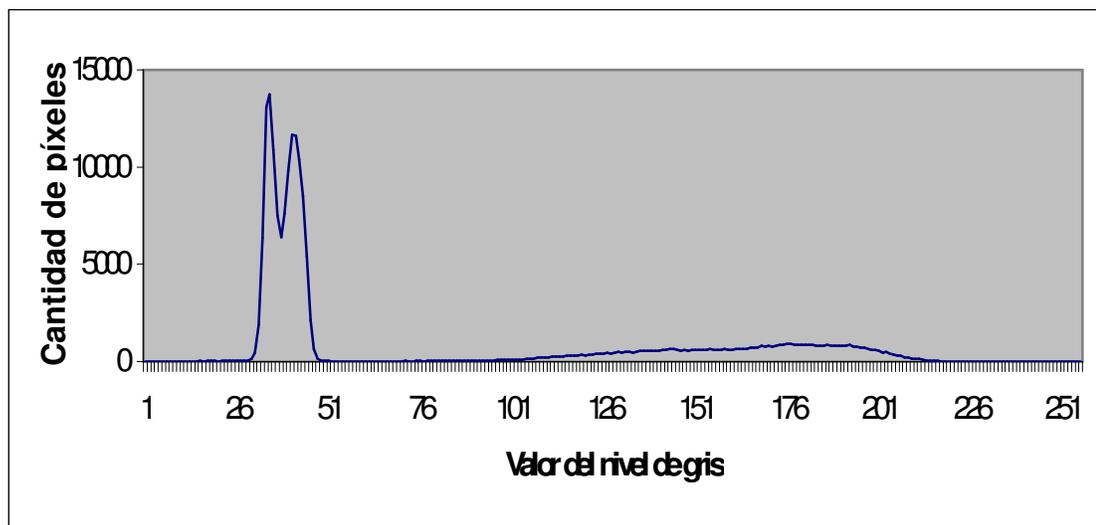


Figura 20. Histograma para el canal verde de la imagen

En el caso de la figura 21, que representa el histograma del canal azul, el pico ensanchado de la derecha se ha desplazado a la izquierda hasta solaparse con el pico correspondiente al contenido del fondo, esto hace que sea muy difícil distinguir entre el fondo y la fruta si se desea segmentar mediante umbralización en el canal azul. De allí la poca importancia de este canal para los análisis realizados durante esta investigación, aunque es posible que para otros objetos represente la fuente primaria de información.

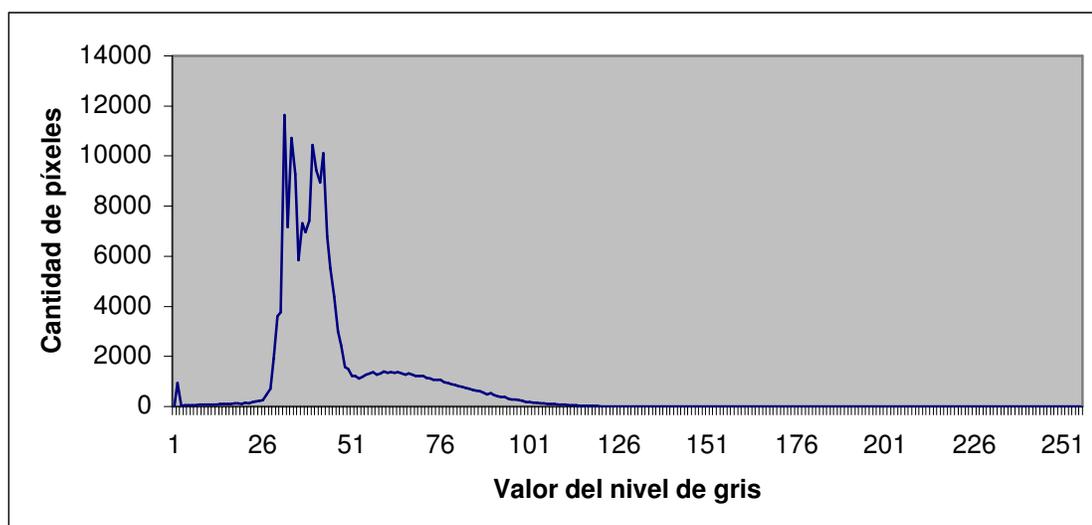


Figura 21. Histograma para el canal azul de la imagen

En la figura 22 se observa un histograma muy interesante. El pico de la izquierda representa el contenido fuerte y homogéneo del color rojo, en la parte central los picos representan una distribución un poco heterogénea y más ancha en el espectro del contenido de diversos colores que arroja el fondo, la zona correspondiente al canal azul es la de la derecha, que por los análisis realizados hasta ahora, no representa mucha información.

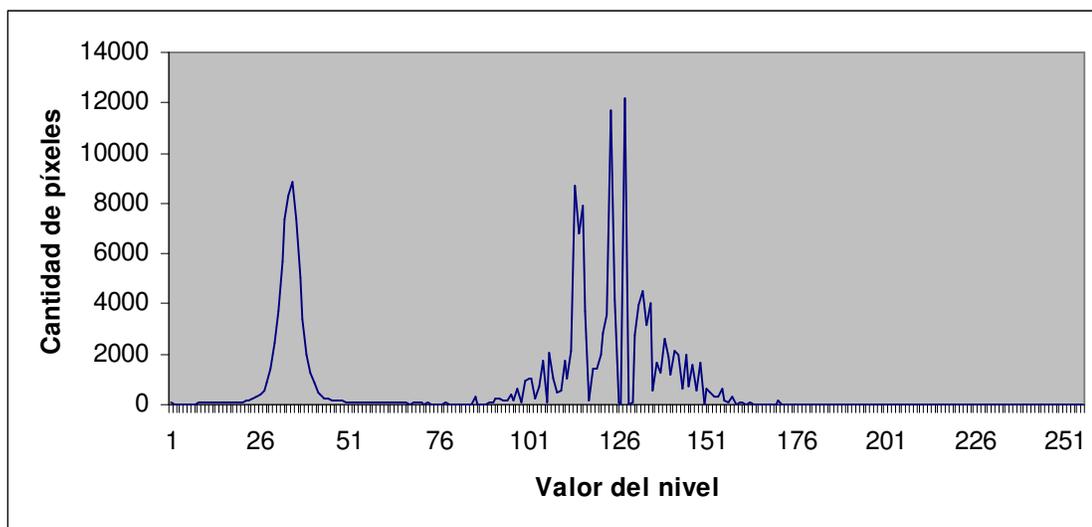


Figura 22. Histograma para el canal de tono de la imagen

Es muy notable que la imagen no presente contenido cromático intermedio entre el rojo y el verde ya que la fruta ha venido experimentando una transición entre estos colores durante el proceso de maduración.

La figura 23 es el histograma para el canal de saturación en el espacio HSI. Claramente hay dos picos dominantes, a la izquierda hay una gran variedad de colores insaturados que, por su cantidad y distribución ensanchada, pertenecen al fondo, el pico de la derecha represente los colores puros que tiene la imagen y obviamente representa el contenido de colores saturados de la piel de la fruta.

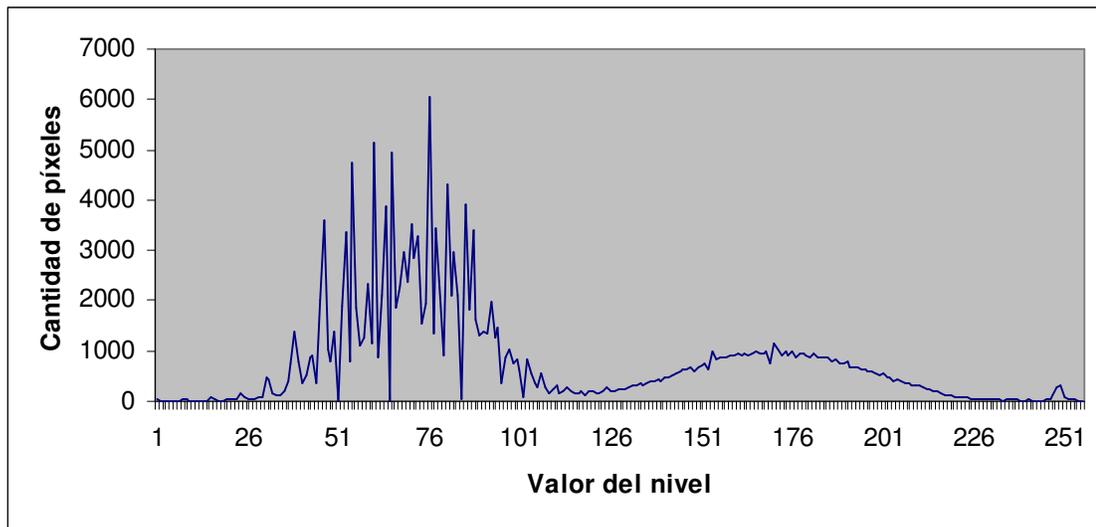


Figura 23. Histograma para el canal de saturación de la imagen

Finalmente, la figura 24 presenta el histograma para la intensidad de la imagen, no agrega mucha información si ya se han analizado los canales R y G, puesto que tienen la misma tendencia. Como se vió, a excepción del canal azul, todos los canales permiten discriminar claramente entre el fondo y el área correspondiente a la fruta. Esto especialmente importante porque simplifica el proceso inicial de segmentación y mejora los resultados de las mediciones posteriores.

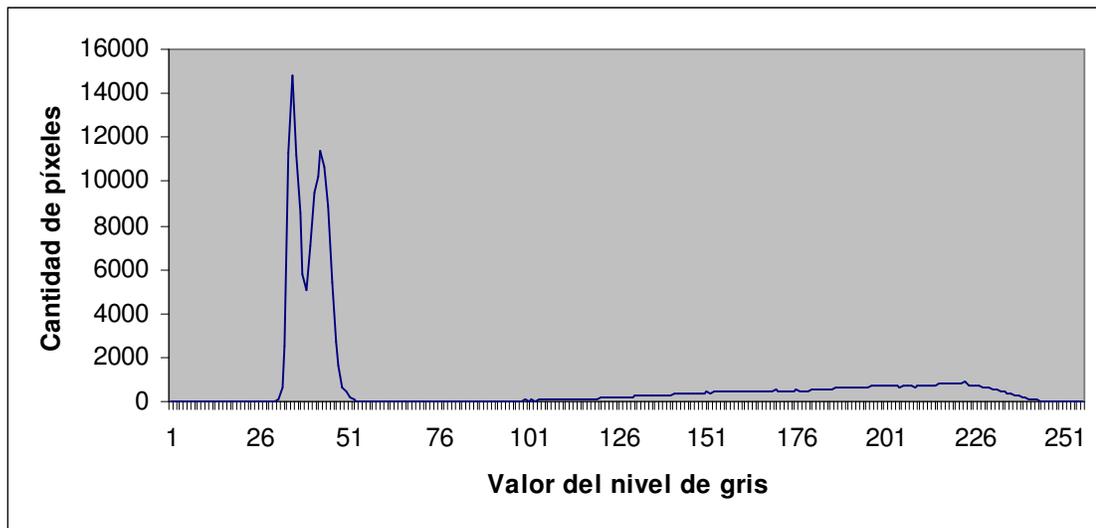


Figura 24. Histograma para el canal de intensidad de la imagen

Los histogramas confirman el hecho de que la distribución de los niveles de gris es altamente uniforme en todos los canales. Es posible que el canal del azul presente un ligero aglutinamiento hacia la parte baja, pero en general este comportamiento es debido principalmente al correcto establecimiento del sistema de iluminación.

Como se vió, en la parte izquierda de los canales R, G, B, S e I se observan claramente unos picos predominantes que indican un gran área de niveles de gris bajos e insaturados en la imagen, esto corresponde principalmente al fondo. Esta característica se usa para establecer la ROI (Región de interés, por sus siglas en inglés) que define el área exacta ocupada por la fruta. La imagen de la figura 25 resulta de establecer la umbralización con los parámetros indicados por los histogramas.

Como se ve, debido a la escogencia de un fondo casi negro, la operación no umbralizó los píxeles oscuros de la fruta, por lo que en este caso es posible diferenciarlos, tanto de la piel sana como del fondo, con otro operador de umbralización. En la figura 25 se observa que el umbralizado permite conservar los bordes reales de la fruta, así, la siguiente operación es la detección de bordes para determinar las características geométricas de esta.



Figura 25. Resultado obtenido al umbralizar

Para esto se hace uso de la imagen binaria obtenida para establecer la ROI, en este caso se realiza la detección de bordes con ayuda de los operadores morfológicos, la razón para esto es que se necesitan bordes enlazados para la cuantificación de las características. Los operadores de Laplace, Roberto, Prewitt o Sobel arrojan bordes segmentados, con lo que se deben enlazar para la cuantificación. La morfología matemática permite obtener el borde enlazado directamente mediante una operación de erosión o dilatación, con un elemento estructurante adecuado y un operador XOR. En la figura 26 se observa el borde detectado superpuesto a la imagen de la fruta.

El borde mostrado tiene un grosor notable solo con propósitos de visualización, la extracción de las características se hace con un borde sencillo. La figura 27 muestra el borde en cuestión a partir del cual se determinará el correspondiente código de cadena para determinar los parámetros geométricos de la fruta.



Figura 26. Detección de bordes de la fruta

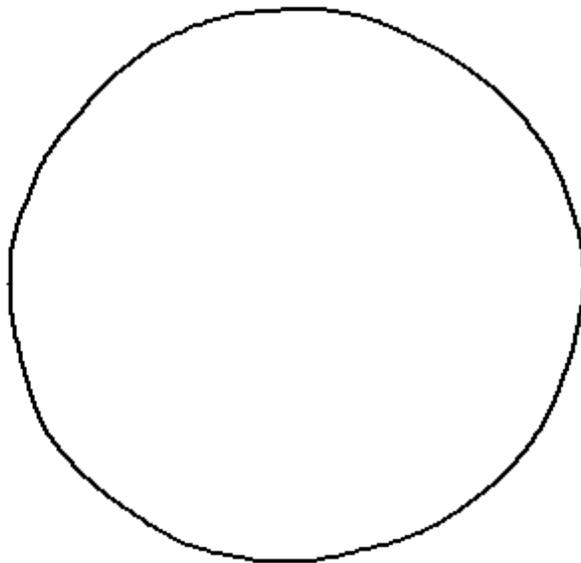


Figura 27. Borde detectado para cuantificación del perímetro y área

Otros parámetros importantes son los que dan los operadores para medida de características, con estos se pueden obtener datos más específicos para establecer la situación geométrica de la fruta. Entre estos se encuentra una característica muy importante para tener un estimativo de la forma que es la redondez.

Para el establecimiento de los colores dominantes, con el fin de estimar el grado de madurez de la fruta, se hace una medida de los componentes de color presentes en el área de piel sana de la fruta. Para esta labor se debe aislar esta región del resto de zonas de la imagen, con lo que se umbralizan los defectos con el operador de detección por umbralizado en los niveles de gris de los canales RGB o en el canal I del espacio HSI. El resultado obtenido se ilustra en la figura 28.

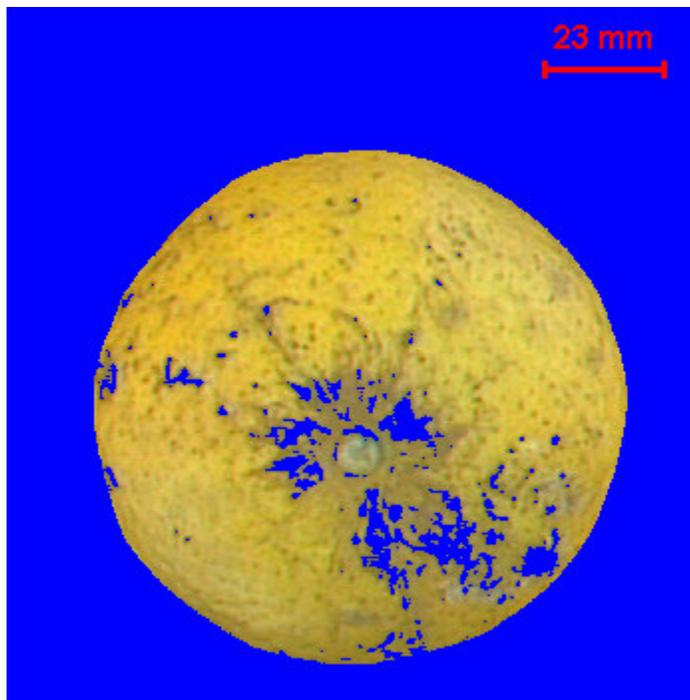


Figura 28. Imagen utilizada para la medida de color de la piel sana

Como los colores que permiten diferenciar claramente entre una naranja verde o madura se encuentran básicamente en los canales R y G, se hace una medición de las medias y desviaciones en estos canales. En el caso de que el examen se realice para

establecer únicamente la maduración, el promedio de los niveles en estos canales es suficiente para hacer un juicio objetivo. También es posible hacer esta discriminación con ayuda del canal de tono (H) del espacio HSI.

En cuanto a los defectos externos, se deben tomar en cuenta los efectos de curvatura en la imagen de un objeto esférico, tal como se describió en la sección 4.1.3.3. En este caso se debe tener en cuenta la posición del píxel a partir del centro de la imagen de la fruta para establecer su área efectiva. Como el cálculo píxel por píxel consumiría muchos recursos, se establecen unas zonas radiales para ponderar, de acuerdo a la posición, los resultados obtenidos para cada una de las detecciones. Los valores para el cálculo del área efectiva se dan por la tabla 6. El centro de las zonas se ha obtenido durante la medida de las características, así que es posible establecer estas zonas fácilmente, como se observa en la figura 29.

Se ha encontrado que cinco zonas son suficientes para realizar medidas confiables. El anillo más periférico está un poco fuera de la circunferencia real de la fruta, ya que este no se tendrá en cuenta durante las mediciones, en esta zona la perspectiva que se obtiene impide que las mediciones puedan ser precisas, además la iluminación periférica es un poco débil, por lo que es más fácil que el sistema se confunda si se le permite evaluar la periferia de la fruta.

La zona central señalada en la figura 29, por lo general va a contener la parte peduncular o, en su defecto, el cáliz de la fruta, por lo que si se desean hacer mediciones con respecto a esto, este siempre se ubica en una zona muy pequeña, por lo que se facilitará el análisis para las detecciones.

Una vez establecidas las zonas nombradas, que particularmente son ROIs específicas, se puede realizar la detección de los defectos. La figura 30 muestra el resultado de esta operación, el proceso se ha realizado relativamente bien, por lo que se han distinguido correctamente las zonas defectuosas de las sanas. La detección se realizó con ayuda de la umbralización en el canal de intensidad del espacio HSI.

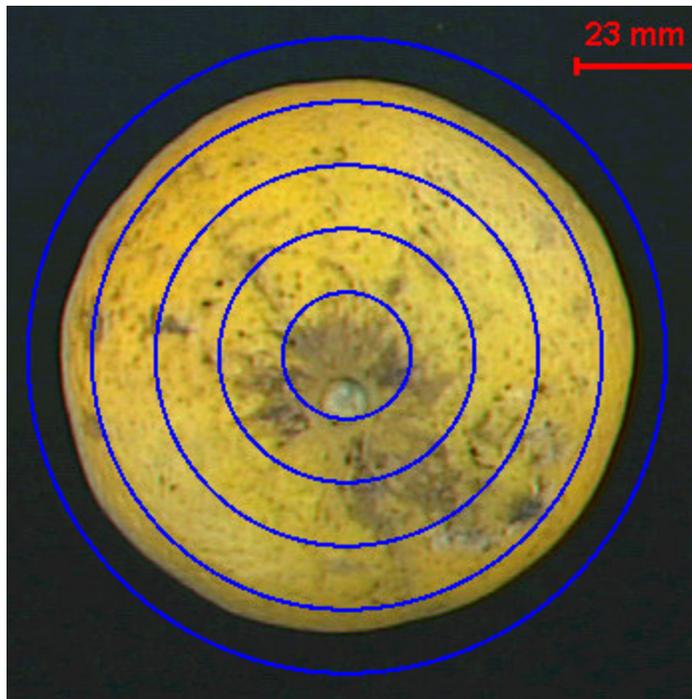


Figura 29. Zonificación para establecer las regiones de análisis

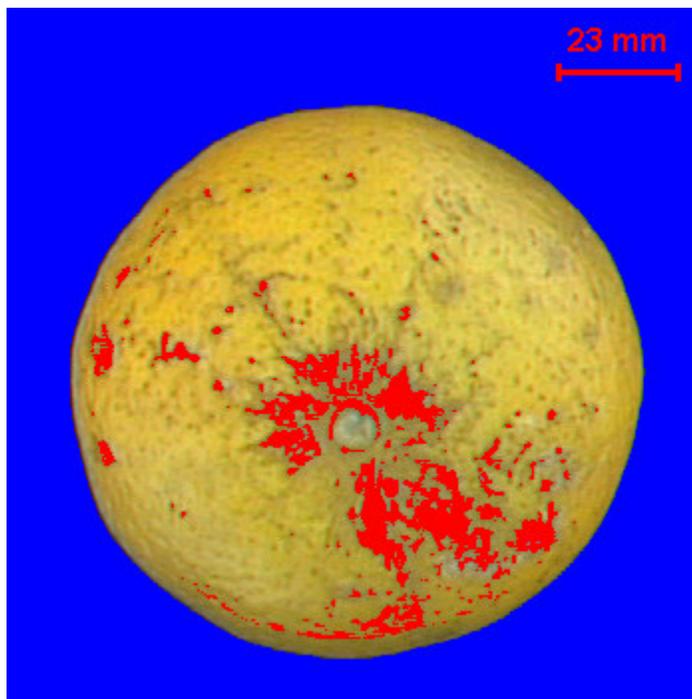


Figura 30. Detección de defectos por umbralización

En este momento se deben establecer los parámetros que caracterizan los zonas defectuosas que contiene la fruta. Para esto se usan las mediciones de características que posee QWin. Los parámetros que principalmente se pueden seleccionar son los geométricos y las estadísticas de los niveles de gris. Una utilidad importante es la posibilidad de establecer parámetros personalizados mediante la combinación entre otros parámetros.

Los parámetros se escogen principalmente para que permitan establecer la cantidad y distribución de los defectos sobre la superficie de la fruta. Para esto se obtienen medidas sobre el área, las proyecciones verticales y horizontales, y las variaciones en los centroides de los defectos, tal como se ve en la figura.

Con propósitos de visualización de la zona afectada por los daños, se puede realizar la detección de bordes de los defectos. La figura 31 presenta la fruta que se ha analizado con los defectos resaltados. Esto es principalmente útil en la fase de desarrollo del sistema, ya que permite establecer qué tan bien está el sistema realizando las detecciones, tal como se vió en la sección 3.3.1, para poder establecer los correctivos en los parámetros de operación.

El algoritmo que se ha establecido desde la figura 16, genera un código en QUIPS que puede ser reutilizado para analizar otras naranjas cuyas imágenes se hayan adquirido en condiciones semejantes. QUIPS cuenta con rutinas de control que permiten realizar rutinas que no necesariamente tienen que ser exclusivamente secuenciales, el problema es que son muy básicas por lo que no es posible realizar programas eficientes que involucren metodologías modernas para la programación de los algoritmos.

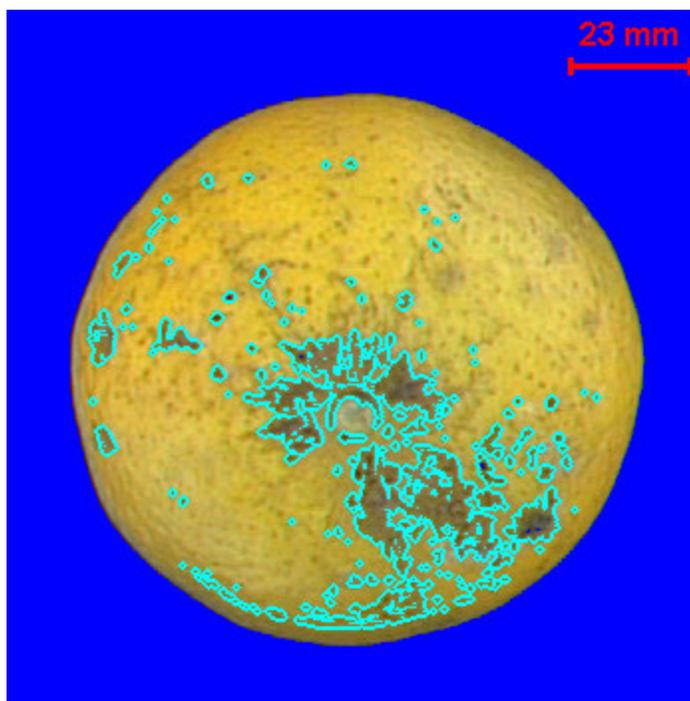


Figura 31. Detección de bordes de los defectos para visualización

El umbralizado orientado a regiones básicamente es útil para estimar superficialmente el contenido de defectos y la forma como se encuentran distribuidos, pero si se desea una medición exacta de las propiedades de los defectos, es más adecuado el umbralizado orientado a píxeles, tal como se ha realizado en este caso. Con este se hicieron algunas pruebas para la segmentación pero no fueron lo suficientemente eficientes para implementarlas en este trabajo.

En las figuras 32 a 36 se muestran los ejemplos de la aplicación del proceso sobre otros frutos para ilustrar la forma como opera el sistema. En la parte izquierda se encuentra la imagen digitalizada y en la derecha la imagen procesada con los defectos resaltados.

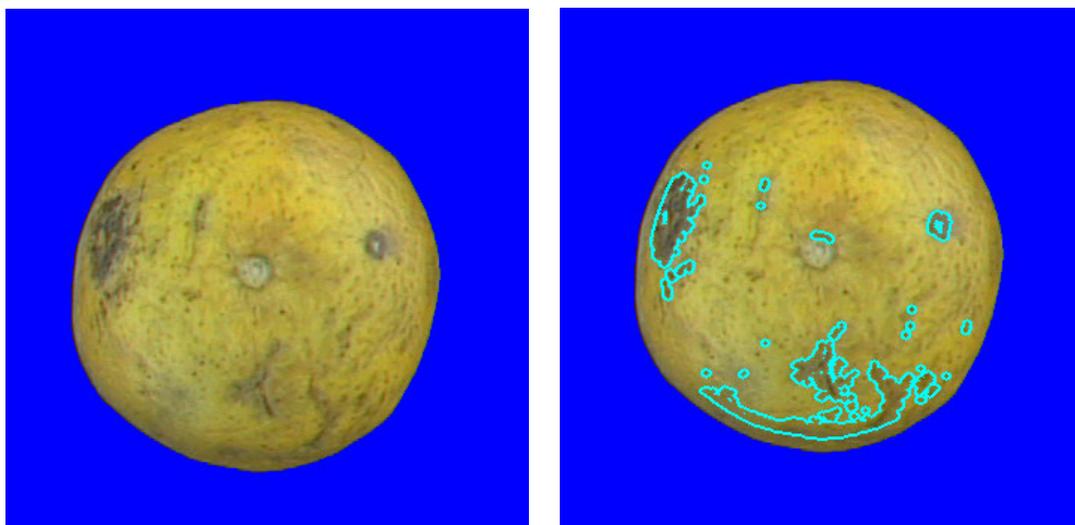


Figura 32. Otros resultados obtenidos para la detección de defectos

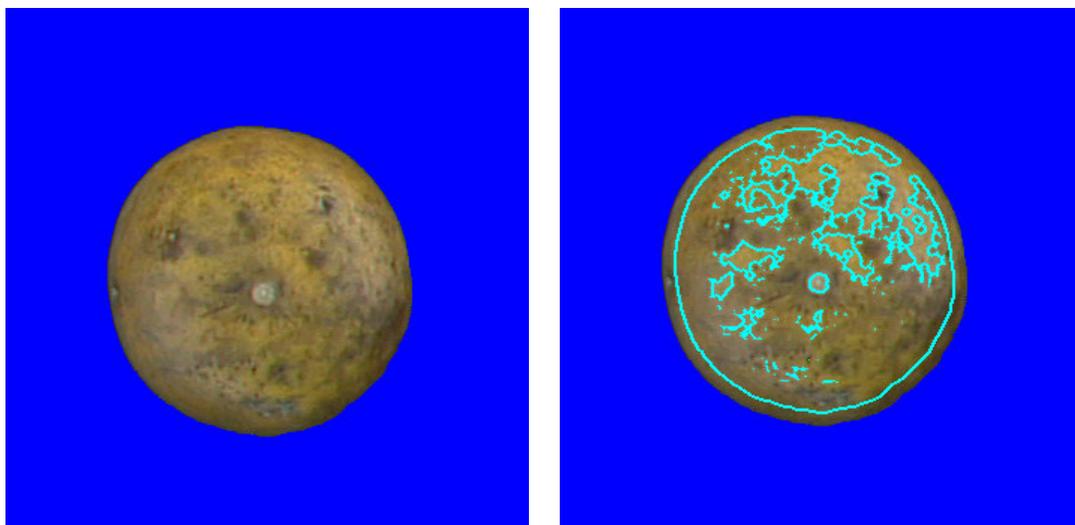


Figura 33. Otros resultados obtenidos para la detección de defectos

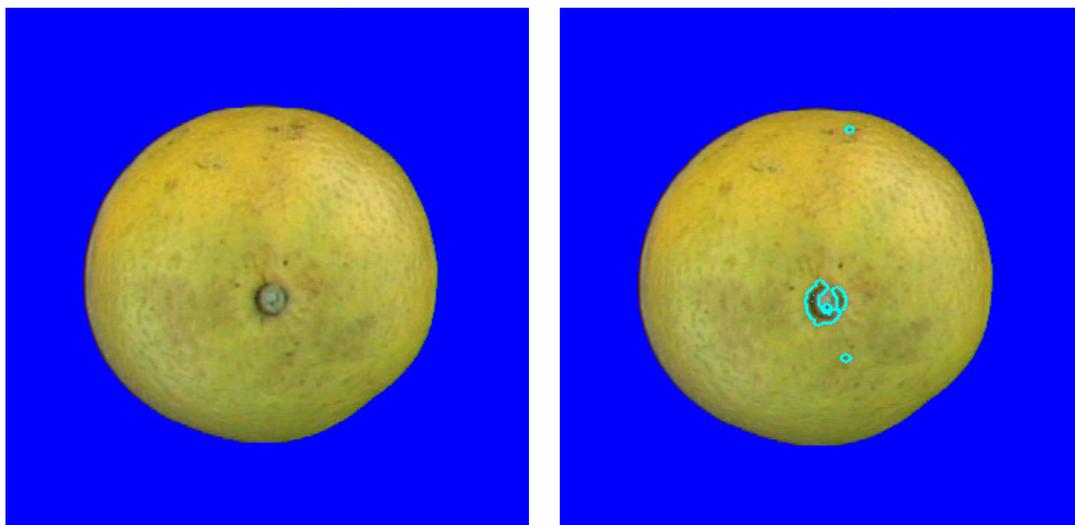


Figura 34. Otros resultados obtenidos para la detección de defectos

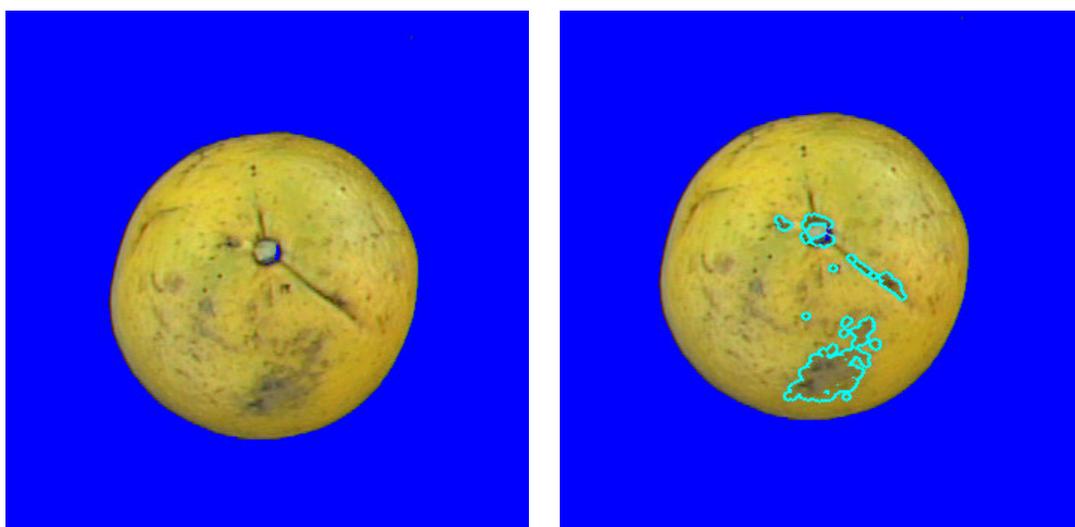


Figura 35. Otros resultados obtenidos para la detección de defectos

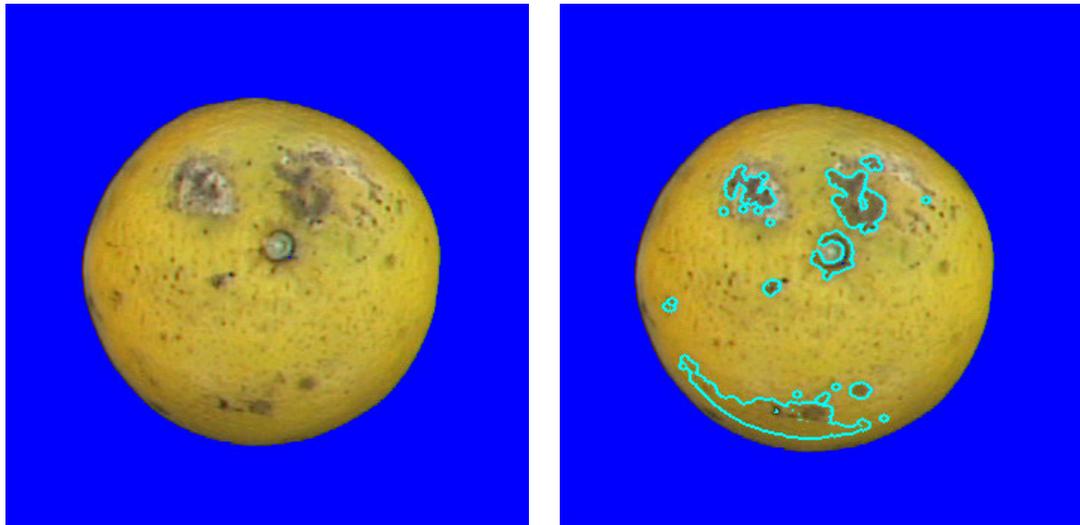


Figura 36. Otros resultados obtenidos para la detección de defectos

Como se ve, en la mayoría de las veces el detector de defectos operó adecuadamente, salvo la última imagen en la que se observa una sobredetección en la parte inferior, pero este es un problema debido a una deficiencia en la iluminación, la imagen se ve con algo de sombreado, pero es un problema que se presentó solo para algunos elementos y es algo relativamente simple de solucionar.

Tal como se explicó, las características obtenidas se entregan a un clasificador, que en este caso es una red neuronal. La red opera como un clasificador estadístico no-paramétrico y el entrenamiento es supervisado. Se hicieron las pruebas de validación cruzada con 330 imágenes de 165 naranjas obtenidas. Los conjuntos de entrenamiento consisten en 45 naranjas, tratando de obtener en estos la mayor variedad posible en tamaños, colores y contenido y distribución de defectos superficiales, tal como se puntualizó en la sección 4.1.1.1. El conjunto de prueba, con las 120 restantes sirve para establecer la calidad del entrenamiento de la red neuronal para clasificar las frutas.

Se establecieron cuatro clases básicas:

- **Clase Extra:** Maduras y sin contenido alguno de defectos
- **Clase I:** Maduras con un contenido de defectos muy leve

-
- **Clase II:** Considerable contenido de defectos, muy pequeñas o deformes
 - **Clase III:** Completamente sanas o con un contenido leve de defectos, pero el nivel de maduración no es adecuado
 - **Clase IV:** Desecho

Las características utilizadas para el entrenamiento y prueba del clasificador fueron:

- Diámetro
- Promedio del canal verde para la piel sana
- Promedio del canal rojo para la piel sana
- Redondez
- Área defectuosa
- Desviación estándar de la suma de las proyecciones sobre los ejes para las características de los defectos
- Desviación estándar de los centroides para los defectos

Los resultados obtenidos para la clasificación se muestran en la matriz de confusión, tal como lo ilustra la tabla 7. Cada una de las validaciones dio resultados similares. Aunque la capacidad global de acierto del sistema es superior al 92%, se deben establecer características que le permitan diferenciar mejor entre las clases, mejorar los métodos de segmentación o trabajar con otro tipo de clasificador.

Como se ve en la tabla, el sistema tiende a ser pesimista, ya que los errores cometidos en el reconocimiento de las clases son porque el sistema reconoce la fruta como una de clase inferior, esto sucedió principalmente para las clases extra, I y II, en el caso de las frutas verdes el reconocimiento fue casi perfecto debido a la buena discriminación que proporciona la información sobre el color. Para reconocer una fruta de desecho tampoco se presentó problema, excepto por alguna que presentaba tonos claros que le hicieron creer que se trataba de una naranja de clase II.

Tabla 8. Matriz de confusión para los resultados con el conjunto de prueba

		Resultado del Reconocimiento					% de acierto
		Extra	I	II	III	IV	
Etiquetado de la fruta	Extra	23	1	1			92.0
	I	1	33	2		1	89.2
	II		1	25			96.2
	III				20	1	95.2
	IV			1		10	90.9
		% Acierto Total					92.5

Fuente: Este estudio

5. CONCLUSIONES

- En este trabajo investigativo se han desarrollado varias técnicas de tratamiento digital de imágenes y visión artificial para identificar el aspecto visual de una fruta mediante técnicas no-destructivas.
- Aunque hay pocas referencias sobre la aplicación de los sistemas de inspección visual automatizada a productos agrícolas, por la dificultad intrínseca que estos presentan, se ha demostrado que son factibles de desarrollar y que, en una primera aproximación como ésta, se pueden alcanzar niveles de efectividad superiores al 90%.
- La inspección visual brinda información muy importante y decisoria que agrega un alto valor al producto y, si se automatiza, se obtienen beneficios aún mayores, pero no representa la solución completa. La ventaja es que un sistema de visión artificial analiza el aspecto visual de forma no-destructiva y trata de clasificar un producto de la misma manera que lo haría un humano, tratando así de estar de acuerdo con las exigencias del consumidor en lo referente al aspecto visual del objeto
- Se ha realizado la descripción de los parámetros cuantificables con un sistema de visión artificial. Aunque en una fruta se pueden realizar múltiples mediciones para la determinación de su calidad, no es posible determinar todos los parámetros por medio de inspección visual, entre estos se encuentra el aroma, la textura de la pulpa, la dureza y el contenido de defectos internos y de azúcares.
- Las características geométricas de la fruta, tales como tamaño, redondez y forma, fueron establecidas con buena precisión gracias a que las imágenes tuvieron altos factores de discriminación entre el fondo y la fruta.
- La mayoría de los sistemas de inspección visual de frutas operan con el análisis de color y tamaño, pero no determinan la cantidad, heterogeneidad y distribución de los defectos como se realizó en este trabajo, obteniendo buenos resultados.

-
- El área defectuosa de la fruta se cuantificó de manera más confiable debido al establecimiento de zonas radiales para la ponderación del área efectiva de los píxeles.
 - El establecimiento de la distribución de los defectos sobre la superficie, en vez de sólo el área, fue de mucha importancia ya que, de esta forma, se tiene un criterio más preciso en la descripción del daño y es posible reconocer más conjuntos de clasificación para la frutas.
 - El uso de la correlación para la selección de variables permitió establecer una cantidad pequeña de variables que permitieron establecer correctamente la clasificación de la fruta analizada.
 - La madurez de la fruta se determinó correctamente gracias al análisis de los colores dominantes sobre la zona de piel sana.

APORTES DE ESTE TRABAJO DE INVESTIGACIÓN

- Quizá el principal aporte de este trabajo es la demostración de que es posible utilizar tecnologías avanzadas para resolver problemas locales. Durante el desarrollo de este estudio diversos sectores, como los productores de chontaduro y seda, mostraron gran interés por este tipo de sistemas para resolver sus problemas de inspección, lo que representa que este trabajo se proyecta a tener un gran impacto no solo a nivel regional sino nacional.
- Se despertó también en la comunidad estudiantil el deseo de trabajar en el desarrollo de dispositivos concernientes con la visión artificial, no solo orientada a la inspección sino a la guía de vehículos y a la seguridad, con el fin de implementar sistemas que limiten el acceso a áreas restringidas, entre otros campos.
- La Universidad del Cauca quedó muy bien representada con el trabajo de investigación, realizado durante el desarrollo de este estudio, titulado “Visión artificial para la detección de defectos externos en frutas mediante el análisis de texturas en color” y que se presentó en el VIII Encuentro Nacional de Óptica, mereciéndole el Primer Puesto como ponencia oral en la categoría de pregrado.

-
- Igualmente en la Cuarta Feria Empresarial de la Universidad del Cauca se le otorgó el premio como Mejor Proyecto en el Sector Industrial, confirmando la calidad y efectividad del diseño que se propone.
 - El laboratorio de óptica del Grupo de Óptica y Láser cuenta ahora con una excelente cámara de iluminación que complementa el equipo de visión con que se cuenta. Con esta no solo se podrán realizar trabajos orientados a la inspección de frutas sino de cualquier tipo de objeto o superficie.
 - La metodología desarrollada ayudará en la implementación de sistemas más sofisticados y complejos, con lo que se podrá continuar trabajando en el desarrollo de tecnología de punta en esta área del conocimiento.

TRABAJO FUTURO

Aunque los resultados obtenidos en este trabajo fueron muy buenos, aún quedan muchos aspectos importantes para complementarlo y ampliar, de esta manera, sus aplicaciones y mejorar su desempeño global. Se pueden enumerar:

- Iluminación IR para distinguir mas fácilmente las zonas defectuosas y podredumbres subsuperficiales.
- Iluminación UV para visualizar daños que no son visibles debido a temprano estado de evolución, como golpes, oleocelosis o podredumbres, aprovechando el fenómeno de fluorescencia inducido que presentan los tejidos alterados.
- Optimización de los algoritmos para mejorar el tiempo de procesamiento y análisis de las imágenes digitales.
- Diseño y construcción de la banda transportadora y otros actuadores.
- Mejoramiento del sistema de adquisición para digitalizar toda la superficie de la fruta al tiempo. Se podrían utilizar juegos de espejos, bandas transportadoras donde la fruta va girando o varias cámaras desde diferentes ángulos.
- Un circuito de control para la corrección del parpadeo de las lámparas fluorescentes con el fin de evitar las variaciones en la iluminación de la imagen.
- Establecimiento de detectores de proximidad para la adquisición en el momento preciso y reduciendo la carga computacional.

-
- Integración con otros sensores, como células de carga para determinación del peso, sensores de impacto, sensores de gases, etc.
 - Establecimiento de algoritmos de entrenamiento no supervisados para evitar un etiquetado subjetivo y propenso a errores.
 - Aplicación en otras ramas de la industria para resolver problemas de inspección de la industria nacional.

REFERENCIAS

1. Ruiz, L. (1999). Aplicación de técnicas de análisis de imagen y espectrometría infrarroja para la detección de daños en cítricos en la posrecolección. Tesis Doctoral. Universidad Politécnica de Valencia, España.
2. Pons, R. (2000). Evaluación de métodos No Destructivos para determinar la calidad de la fruta. Tesis Doctoral. Departamento de Mecánica Agraria, Universidad Politécnica de Valencia, España.
3. Derganc, J., Pernus, F. (2000). A machine vision system for inspecting bearings. Int. Conf. On Pattern Recognition ICPR'00, Spain.
4. Torres, F., Sebastián, J., Aracil, R., Jimenez, L., Reinoso, O. (1998). Automated real-time visual inspection system for high-resolution superimposed printings. Image and Vision Computing, Vol. 16, pp. 947-958.
5. Moganti, M., Ercal, F., Dagli, C., Tsunekawa, S. (1996). Automatic PCB inspection algorithms: A survey. Computer Vision and Image Understanding, Vol. 63, No. 2, pp. 287-313.
6. Lashkia, V. (2001). Defect detection in X-ray images using fuzzy reasoning. Image and Vision Computing, vol. 19, pp. 261-269.
7. Kim, T., Cho, T., Moon, Y., Park, S. (1999). Visual inspection system for the classification of solder joints. Pattern Recognition, vol. 32, pp. 565-575.
8. Mannan, M., Kassim, A., Jing, M. (2000). Application of image and sound analysis techniques to monitor the condition of cutting tools. Pattern Recognition Letters, vol. 21, pp. 969-979.
9. Barni, M. Cappellini, V., Mecocci, A. (1997). Colour-based detection of defects on chicken meat. Image and Vision Computing, Vol. 15, pp. 549-556.
10. Shiranita, K., Miyajima, T., Takiyama, R. (1998). Determination of meat quality by texture analysis. Pattern Recognition Letters, Vol. 19, pp. 1319-1324.

-
11. Wen, Z., Tao, Y. (1998). Fuzzy-based determination of model and parameters of dual-wavelength vision system for on-line apple sorting. *Opt. Eng.*, vol. 37, pp. 293-299.
 12. Kim, J., Mowat, A., Poole, P., Kasabov, N. (1997). Neuro-fuzzy and multivariate statistical classification of fruit population based on visible-near infrared spectrophotometry data. *Proc. of Int. Conf. on Neural Information Processing*, New Zealand.
 13. Jiménez, A., Jain, A., Ceres, R., Pons, J. (1999). Automatic fruit recognition: a survey and new results using Range/Attenuation images. *Pattern Recognition*, vol. 32, pp. 1719-1736.
 14. Jiménez, A., Ceres, R., Pons, J. (2000). A survey of computer vision methods for locating fruits on trees. *Pattern Recognition*, vol. 33.
 15. Recce, M., Taylor, J., Plebe, A., Tropiano, G. (1996). Vision and neural control for an orange harvesting robot. *Int. Workshop on Neural Networks for Identification, Control, Robotics, and Signal/Image Processing (NICROSP ' 96)*. Italy.
 16. Shapiro, L., Stockman, G. (2001). *Computer Vision*. 1st Ed. Prentice Hall.
 17. Noordam, J., Otten, G., Timmersmans, A., van Swol, B. (2000). High speed potato grading and quality inspection based on a color vision system. *Electronic Imaging 2000, Science and Technology*. San José, CA, USA.
 18. Bahlmann, C., Heidemann, G., Ritter, H. (1999). Artificial neural networks for automated quality control of textile seams. *Pattern Recognition*, vol. 32, pp. 1049-1060.
 19. Campbell, J., Fraley, C., Murtagh, F., Raftery, A. (1997). Linear flaw detection in woven textiles using model-based clustering. *Pattern Recognition Letters*, Vol. 18, pp. 1539-1548.
 20. Carvalho, P., Costa, N., Ribeiro, B., Dourado, A. (1997). Industrial visual inspection of lime balls by neural networks. *22nd Int. Conf. for Computers and Industrial Engineering C&IE'97*, Egypt, pp. 64-67.

-
21. Carvalho, P., Araújo, H., Dourado, A. (1999). An automatic optical sensor for vessels and fibbers quality inspection in pulp production. *Computers and Industrial Engineering*, vol. 37, pp. 355-358.
 22. Latif-Amet, A., Ertuzun, A., Ercil, A. (2000). An efficient method for texture defect detection: sub-band domain co-occurrence matrices. *Image and Vision Computing*, Vol. 18, pp. 543-553.
 23. Malamas, E., Petrakis, E., Zervakis, M., Petit, L., Legat J. (2002) A survey on industrial vision systems, applications and tools. *Image and Vision Computing*, vol. 20.
 24. Andeen, G. (Ed.-in-Chief) (1988). *Robot Design Book*. SRI International-McGraw-Hill.
 25. Ghosh, J. (1994). "Vision-based Inspection" in *Artificial Neural Networks for Intelligent Manufacturing* (Chapter 11), C. H. Dagli (Editor). Chapman and Hall, p. 265-298.
 26. Davies, E. (1990). *Machine Vision: Theory, Algorithms, Practicalities*. Academic Press, London.
 27. Recce, M., Taylor, J., Plebe, A., Tropiano, G. (1996). High speed vision-based quality grading of oranges. *Int. Workshop on Neural Nets. For Identification, Control, Robotics and Signal/Image Processing*, Italy. IEEE Comp. Soc. Press, pp. 136-144.
 28. Wen, W., Xia, A. (1999). Verifying edges for visual inspection purposes. *Pattern Recognition Letters*, Vol. 20, pp. 315-328.
 29. Shiranita, K. Hayashi, K., Otsubo, A., Miyajima, T., Takiyama, R. (2000). Grading meat quality by image processing. *Pattern Recognition*, vol. 33, pp. 97-104.
 30. Platero, C. (1998). *Inspección automatizada de superficies homogéneas mediante Visión Artificial*. Tesis Doctoral. DISAM, Universidad Politécnica de Madrid. España.
 31. Jaime, F. (1999). *Aplicaciones industriales de los Sistemas de Inspección Industrial Automatizados*. Proyecto de fin de carrera. GCII-FAIS, Universidad Politécnica de Madrid. España.

-
32. Bergasa, L., Duffy, N., Lacey, G., Mazo, M. (2000). Industrial inspection using Gaussian functions in a colour space. *Image and Vision Computing*, Vol. 18, pp. 951-957.
 33. Tsai, D., Hsieh, C. (1999). Automated surface inspection for directional textures. *Image and Vision Computing*, Vol. 18, pp. 49-62.
 34. Nilson, N. (2001). *Inteligencia Artificial. Una nueva síntesis*. McGraw-Hill. España.
 35. Bariani, M, Cucchiara, R., Mello, P., Piccardi, M. (1996). Using machine learning for defect detection. *Cibernetica e Machine Learning. Quinto Convegno Nazionale AI*IA*, Italy, pp. 171-174.
 36. Aleixos, N. (1999). *Desarrollo de técnicas de visión artificial utilizando procesadores digitales de señal. Aplicación a la detección de defectos en frutas en tiempo real*. Tesis Doctoral. Universidad Politécnica de Valencia, España.
 37. Fuentes, R., Fuentes, A., Vallejo, C. (2001). Sistema de visión artificial para el control de calidad del melón. *Inst. Tecn. de Chihuahua. Electro 2001*, pp. 131-134.
 38. Kittler, J., Marik, R., Mirmehdi, M., Petrou, M., Song, J. (1994). Detection of defects in colour texture surfaces. *IAPR Proc. of Machine Vision Applications 94*, pp. 558-567. Israel.
 39. Drimbarean, A., Whelan, P. (2001). Experiments in color texture analysis. *Pattern Recognition Letters*, vol. 22, pp. 1161-1167.
 40. Singh, M., Markou, M., Singh, S. (2002). Colour image texture analysis: dependence on colour spaces. *Proc. of 15th Int. Conf. on Pattern Recognition ICPR'02*. Canada.
 41. Cheng, H., Jiang, X., Sun, Y., Wang, J. (2001). Color image segmentation: advances and prospects. *Pattern Recognition*, vol. 34, p. 2259-2281
 42. Chen, C., Pau, L. (1998). *The Handbook of Pattern Recognition and Computer Vision*. World Scientific Publishing Co. Pp. 207-248.
 43. Castleman, K. (1996). *Digital image processing*. Prentice Hall, Englewood Cliffs. New Jersey.
 44. Breenan, J. (1980). *Las operaciones de la ingeniería de los alimentos*. Ed.

-
- Acribia. Zaragoza, España.
45. Newman, T., Jain, A. (1995). A survey of automated visual inspection. *Computer Vision and Understanding*, Vol. 61, pp. 231-262.
 46. Mintchell, G. (2001). Use sensors intelligently. *Control Engineering*, October 1, 2001, pp. 40-44.
 47. Kalleward, V. et Al. (2000). Sistemas de visión en el control de procesos de manufactura. *Scientia et Technica*, vol 3. UTP.
 48. Forsyth, D., Ponce, J. (2002). *Computer Vision. A Modern Approach*. Prentice Hall.
 49. Janesic, J., Elliot, S., Collins, A., Marsh, H., Blouke, M. y Freeman, J. (1987). Scientific Charge-Couple Devices. *Opt. Eng.*, vol. 26, pp. 692-714.
 50. Hossack, W. (1998). Digital image analysis and image processing course. Department of Physics and Astronomy. University of Edinburgh.
 51. Patrick, E., Fattu, J. (1986). *Artificial Intelligence with Statistical Pattern Recognition*. Prentice-Hall. USA.
 52. Groover, M., Weiss, M., Nagel, R., Odrey, N. (1989). *Robótica Industrial. Tecnología, programación y aplicaciones*. Mc-Graw-Hill. Madrid.
 53. Fu, K., Gonzalez, R., Lee, C. (1988). *Robotics: Control, Sensing, Vision, and Intelligence*. McGraw-Hill, New York.
 54. González, R., Woods, R. (1996). *Tratamiento digital de imágenes*. Addison-Wesley/Días de Santos. Delaware.
 55. De la Escalera, A. (2001). *Visión por Computador: Fundamentos y métodos*. Prentice Hall. Madrid, España.
 56. Ortiz, F. (2002). *Procesamiento de imágenes en color. Aplicación a reconstrucción geodésica*. Tesis de Doctorado. Departamento de Física, Ingeniería de Sistemas y Teoría de la Señal, Universidad de Alicante. España.
 57. <http://www.advancedillumination.com>
 58. Pencue, L., León, J. (2002). *Visión artificial para la detección defectos externos en frutas mediante el análisis de texturas en color*. VIII Encuentro Nacional de Óptica, Popayán, Colombia.
 59. Universidad de Antioquia · Facultad de Química Farmacéutica (2002). *Frutas*

-
- Tropicales. Web: <http://huitoto.udea.edu.co/FrutasTropicales/index.html>.
60. La Nueva Agricultura para Colombia. (2002). Página de Ingeniería Agrícola. Web: <http://www.angelfire.com/ia2/ingenieriaagricola/poscosecha.htm>.
 61. Washbur M.W. (2000) “”. Foodpro International, Inc. San Jose, California, USA.
 62. <http://www.cadenalco.com.co>
 63. <http://www.corabastos.com.co>
 64. Norma Técnica Colombiana. (2000). NTC4086. ICONTEC. Bogotá.
 65. MacKay, D. (2003). Information Theory, Inference and Learning Algorithms. Cambridge University Press. UK.
 66. Feyaerts, F., van Gool, L. (2001). Multi-spectral vision system for weed detection. Pattern Recognition Letters, Vol. 22, pp. 667-674
 67. Leica QWin User Guide. (1999). Leica Imaging Systems Ltd. Cambridge. England.
 68. Leica QWin Reference Guide. (1999). Leica Imaging Systems Ltd. Cambridge. England.
 69. Leica QUIPS User Guide. (1999). Leica Imaging Systems Ltd. Cambridge. England.
 70. Leica QUIPS Reference Guide. (1999). Leica Imaging Systems Ltd. Cambridge. England.
 71. Facon, J. (1996). Morfología matemática: Teoría e Exemplos. Curitiba, Brasil. 1996.
 72. Lee, C., Huh, S., Ketter, T., Unser, M. (2000). Automated segmentation of corpus callosum in midsagittal brain magnetic resonance images. Opt. Eng., vol. 39, pp. 924-935.
 73. Sharma, M., Markou, M., Singh, S. (2001). Evaluation of texture methods for image analysis. Proc. 7th Australian and New Zealand Intelligent Information Systems Conference, pp. 117-121. Australia.
 74. Woods, K. (1994). Automated image analysis techniques for digital mammography, Tesis doctoral. University of South Florida.
 75. Cazorla, M. (2000). Un enfoque bayesiano para la extracción de características y agrupamiento en visión artificial. Departamento de Ciencia de la Computación e

Inteligencia Artificial, Universidad de Alicante.

- 76.** Pencue, L., León, J. (2002). Reconstrucción de imágenes obtenidas en condiciones de iluminación escasa mediante una cámara CCD de operación en el rango visible del espectro. VIII Encuentro Nacional de Óptica, Popayán, Colombia.

ANEXOS

1. Artículos presentados en el VIII Encuentro Nacional de Óptica:
 - ↳ Visión artificial para la detección de defectos externos en frutas mediante el análisis de texturas en color
 - ↳ Reconstrucción de imágenes obtenidas en condiciones de iluminación escasa mediante una cámara ccd de operación en el rango visible del espectro
2. Certificado de los ganadores en el VIII Encuentro Nacional de Óptica
3. Certificado del sistema como Mejor Proyecto del Sector Industrial en la Cuarta Feria Empresarial de la Universidad del Cauca