



UNIVERSIDAD DE JAÉN
Escuela Politécnica Superior(Jaén)

Trabajo Fin de Grado

IDENTIFICACIÓN DE DEFECTOS EN ACEITUNAS MEDIANTE PROCESAMIENTO DE IMÁGENES

**ALUMNO: FERNANDO
MAZA CASTILLO**

Tutor: Prof. D. Diego Manuel Martínez Gila

Dpto: Ingeniería de Electrónica y automática



Universidad de Jaén
Escuela Politécnica Superior de Jaén
Departamento de Ingeniería Electrónica y Automática

Don DIEGO MANUEL MARTÍNEZ GILA, tutor del Trabajo Fin de Carrera titulado: IDENTIFICAIÓN DE DEFECTOS EN ACEITUNAS MEDIANTE PROCESAMIENTO DE IMÁGENES, que presenta FERNANDO MAZA CASTILLO, autoriza su presentación para defensa y evaluación en la Escuela Politécnica Superior de Jaén.

Jaén, SEPTIEMBRE de 2019

El alumno:

FERNANADO MAZA CASTILLO

Los tutores:

DIEGO MANUEL MARTÍNEZ GILA

RESUMEN

La calidad del aceite de oliva depende de muchos factores, uno de ellos es el estado de la materia prima, si el fruto es defectuoso el aceite pierde calidad; por el tamaño y cantidad de la materia prima, clasificar los frutos de forma manual es casi imposible. En este informe se recoge el estudio del desarrollo de una herramienta capaz de clasificar estos frutos defectuosos mediante el procesamiento de imágenes. Este proceso se realiza con la ayuda de un set up experimental, para adquirir las imágenes que contienen frutos con diferentes defectos; y el entorno de programación MATLAB, para el desarrollo de los algoritmos que identificarán los defectos en los frutos. También se han desarrollado diferentes interfaces gráficas, cuya función es la obtención de características de los defectos necesaria para el entrenamiento de redes neuronales, con el objetivo de clasificar los defectos

ABSTRACT

The quality of the olive oil depends on many factors. One of them is the state of the raw material, if the fruit is defective the olive oil loses its quality; to classify the fruit the manual way according to the size and the quantity of the raw material is almost impossible. This report compiles the study of the development of a tool which is able to sort out these defective fruits through image processing. This process is possible with the help of a experimental set up, to get the images to containing different defective fruits and the programming environment Matlab to develop algorithms that will identify the defects on the fruits. Besides, different graphic interfaces have been developed to identify the characteristics of the defects which are necessary for the training of neural network, with the goal of classifying the defects of the olives.

Índice

1. INTRODUCCIÓN	8
1.1. Descripción del proceso de extracción de aceite de oliva virgen (PEAOV).....	8
1.1.1. Proceso de recolección en el campo.....	8
1.1.2. Recepción en almazara.....	8
1.1.3. Fabricación de aceite	9
1.1.4. Análisis de calidad del aceite a nivel físico-químico y organoléptico.....	10
1.2. Motivación.....	14
1.2.1. Efecto negativo en el aceite debido a los defectos en el fruto	14
1.2.2. influencia del tipo de aceite en el ámbito comercial	18
1.3. Objetivos	19
1.3.1. Objetivos generales.....	19
1.3.2. Objetivos específicos	19
1.4. Antecedentes	20
1.4.1. Antecedentes relacionados con el aceite.	20
1.4.2. Antecedentes relacionados con la detección de defectos en diferentes frutos	21
1.4.3. Estudios previos desarrollados por el alumno	22
2. Metodología	23
2.1. Descripción del setup	23
2.1.1. Hardware	23
2.1.1.1. Plataforma General y sistemas de sujeción	23
2.1.1.2. Sistemas de visión.....	24
2.1.1.3. Sistemas de Iluminación.....	26
2.1.1.4. Conexión al PC.....	27
2.1.2. Software.....	27
2.1.3. Material	32
2.2. Muestras experimentales	33
2.3. Proceso de adquisición de imágenes	36
2.3.1. Estudio de posicionamiento de aceitunas.....	37
2.3.2. Adquisición de imágenes	39
2.4. Algoritmos para el espectro visible	40
2.4.1. Fase de desarrollo	41
2.4.1.1. Preprocesamiento.....	41
2.4.1.2. Procesamiento.....	45
2.4.1.2.1. Segmentación.....	45
2.4.1.2.2. Extracción de características	48

2.4.1.3.	Clasificación	51
2.4.2.	Fase de validación	59
2.5.	Algoritmos para el espectro infrarrojo	59
2.5.1.	Fase de desarrollo	60
2.5.1.1.	Preprocesado	60
2.5.1.2.	Procesamiento.....	62
2.5.1.2.1.	Segmentación.....	62
2.5.1.2.2.	Extracción de características	64
2.5.1.3.	Clasificación	64
3.	Resultados	66
3.1.	Resultados en el espectro visible	66
3.1.1.	Resultados en picadura de mosca	66
3.1.2.	Resultados en escudete	70
3.1.3.	Resultados en manchas fitosanitarias	73
3.1.4.	Resultados en frutos deshidratados	76
3.1.5.	Resultados en frutos helados	77
3.2.	Resultados en el espectro cercano al infrarrojo.....	78
3.2.1.	Comparación banda red edge con NIR	78
3.2.2.	Resultados escudete.....	79
3.3.	Comparación resultados entre espectro visible e infrarrojo	81
4.	Conclusiones y trabajos futuros.....	81
4.1.	Conclusiones.....	81
4.2.	Trabajos futuros	83
Referencias		84

Ilustración 1 Tabla de las principales características del aceite(https://www.boe.es/buscar/doc.php?id=DOUE-L-2016-82301)	11
Ilustración 2 hoja de ensayo organoléptico (https://www.boe.es/buscar/doc.php?id=DOUE-L-2013-82809).....	13
Ilustración 3 Diversos estados del ciclo biológico de la mosca del olivo [3]	14
Ilustración 4 Imagen de escudete a la izquierda e imagen a nivel microscópico del hongo a la derecha [http://tecnisol-agricola.es/]	15
Ilustración 5 muestras de aceitunas manchadas de productos fitosanitarios	16
Ilustración 6 Grafica de contenido de grasa sobre materia seca en pulpa [5].	17
Ilustración 7 conjunto de aceitunas heladas	17
Ilustración 8 Tabla de relación de precios del aceite de oliva en función de la calidad	18
Ilustración 9 grafica representativa de tabla de precios	18
Ilustración 10 Vista general del setup	23
Ilustración 11 brazo articulado usado para la cámara Mako	24
Ilustración 12 Fuente de alimentación	25
Ilustración 13 Cámara Mako G223C.....	25
Ilustración 14 cámara multiespectral Ilustración 15 focal de la cámara multiespectral	26
Ilustración 16 Perfil del foco instalado en el setup	27
Ilustración 17 intensidad lumínica en campo de visión	27
Ilustración 18 Conexión de datos al PC.....	27
Ilustración 19 vista general de Sopera cam	28
Ilustración 20 zona izquierda del software Sopera cam	29
Ilustración 21 zona derecha del software Sopera cam.....	29
Ilustración 22 vista general del software Matlab	30
Ilustración 23 barra de herramientas de Matlab.....	31
Ilustración 24 Editor de código de Matlab	31
Ilustración 25 venta de comandos y de variables de Matlab	32
Ilustración 26 campo de visión de los sensores..... Ilustración 27 soporte de aceitunas	32
Ilustración 28 Ubicación de la finca http://sigpac.mapa.es/fega/visor/	33
Ilustración 29 Diferentes pruebas de envasado al vacío.....	34
Ilustración 30 diferentes perspectivas de una misma aceituna	37
Ilustración 31 imagen de conjunto de aceitunas en el espectro visible	38
Ilustración 32 imagen de conjunto de aceitunas en el espectro infrarrojo	38
Ilustración 33 esquema de adquisición de imágenes.....	39
Ilustración 34 Proceso de la fase de desarrollo	41
Ilustración 35 ejemplo de la imagen de una muestra individual	42
Ilustración 36 proceso de separar el fruto del fondo	43
Ilustración 37 Diferentes espacios de color con sus correspondientes canales	44
Ilustración 38 estructura de segmentación	45
Ilustración 39 datos para umbralización en picadura de mosca. <u>Imagen izquierda</u> : histograma del canal a*. <u>Imagen derecha</u> : ponderación de un pixel en el defecto con otro en fruto.....	46
Ilustración 40 datos para umbralización en escudete. <u>Imagen izquierda</u> : histograma del canal a*. <u>Imagen derecha</u> : ponderación de un pixel en el defecto con otro en fruto.....	46

Ilustración 41 datos para umbralización de la mancha fitosanitaria. <u>Imagen izquierda:</u> histograma del canal a*. <u>Imagen derecha:</u> ponderación de un pixel en el defecto con otro en fruto.....	47
Ilustración 42 aplicación de los elementos morfológicos.....	48
Ilustración 43 excentricidad de una elipse	49
Ilustración 44 <u>imagen izquierda:</u> aceituna con macha fitosanitaria sin señalar sombras, <u>imagen derecha:</u> aceituna con escudete y zonas de sombra señaladas.....	51
Ilustración 45 esquema red neuronal.....	52
Ilustración 46 Vista general del interfaz para los defectos de picadura, escudete y mancha fitosanitaria.....	53
Ilustración 47 botonera de la zona derecha de la interfaz.....	54
Ilustración 48 tablas de características de la parte izquierda de la interfaz.....	55
Ilustración 49 Los tres niveles de deshidratación estipulados.....	56
Ilustración 50 Vista general del interfaz para los defectos de deshidratación y fruto helado.....	56
Ilustración 51:ejemplo de estructura de red neuronal	57
Ilustración 52 Flujoograma del algoritmo con la red de neuronas implementada	58
Ilustración 53 Ejemplo de tabla con resultados de validación del algoritmos de escudete en imágenes de conjunto de frutos.....	59
Ilustración 54 Zoom a imagen multiespectral.....	60
Ilustración 55 Bandas del red Edge y NIR	61
Ilustración 56 datos para umbralización de escudete. <u>Imagen de abajo:</u> histograma de banda NIR. <u>Imagen de arriba:</u> ponderación de un pixel en el defecto con otro en fruto.....	62
Ilustración 57 datos para umbralización de picadura. <u>Imagen de abajo:</u> histograma de banda NIR. <u>Imagen de arriba:</u> ponderación de un pixel en el defecto con otro en fruto.....	63
Ilustración 58 vista general de la interfaz para imágenes multiespectrales	64
Ilustración 59 Estructura de la red de neuronas para las imágenes multiespectrales	65
Ilustración 60 Resultados del algoritmo en picadura de mosca con umbral 0.6	67
Ilustración 61 Resultados del algoritmo en picadura de mosca con umbral 0.7	67
Ilustración 62 Resultados del algoritmo en picadura de mosca con red de neuronas	68
Ilustración 63 Resultados del algoritmo en picadura de mosca en lotes de aceituna en conjunto.....	68
Ilustración 64 Matriz de confusiones de la red de neuronas entrenada con picaduras de mosca	69
Ilustración 65 Resultado de la aplicación del algoritmo a un conjunto de aceitunas con picadura de mosca	70
Ilustración 66 Resultados del algoritmo en escudete con umbral 0.6.....	70
Ilustración 67 Resultados del algoritmo en escudete con umbral 0.7.....	71
Ilustración 68 Resultados del algoritmos con red neuronal en escudete.....	71
Ilustración 69 Resultados del algoritmo con red neuronal en muestras de conjunto de aceitunas con escudete.....	72
Ilustración 70 Matriz de confusión de la red de neuronas para escudete.....	72
Ilustración 71 Resultado de la aplicación del algoritmo a un conjunto de aceitunas con escudete.....	73
Ilustración 72 Resultado del algoritmo en la capa 'b' del RGB y umbral 0.4 para manchas fitosanitarias en imágenes de frutos individuales.....	74
Ilustración 73 Resultado del algoritmo en la capa 'a' del CIE l*a*b* y umbral 0.4 para manchas fitosanitarias en imágenes de frutos individuales.....	74

Ilustración 74 Resultado del algoritmo en la capa 'a' del CIE $l^*a^*b^*$ y umbral 0.4 para manchas fitosanitarias en imágenes de conjunto de frutos.....	75
Ilustración 75 resultado de aplicar el algoritmo a una imagen con un conjunto de aceitunas que tienen manchas fitosanitarias	75
Ilustración 76 Matriz de confusión obtenida en el entrenamiento de la red neuronal para clasificar grados de deshidratación.....	76
Ilustración 77 Matriz de confusión obtenida en el entrenamiento de la red neuronal para clasificar como de helado está el fruto.....	77
Ilustración 78 Banda Red Edge picadura de mosca	78
Ilustración 79 banda NIR picadura de mosca	78
Ilustración 80 Banda NIR escudete	79
Ilustración 81 Banda Red Edge escudete.....	79
Ilustración 82 matriz de confusión de red de neuronas para escudete en espectro infrarrojo	79
Ilustración 83 Resultados de escudete en espectro infrarrojo muestras individuales.....	80
Ilustración 84 Resultados de escudete en espectro infrarrojo muestras de conjunto de frutos	80
Ilustración 85 Resultado de la aplicación del algoritmo en espectro infrarrojo en una imagen del conjunto de frutos	81

1. INTRODUCCIÓN

En este primer apartado se hablará del PEAOV para ver el entorno al que está orientado el estudio, se mencionará estado del arte, contexto en el que se ha desarrollado, la motivación y los objetivos generales y específicos del proyecto.

1.1. Descripción del proceso de extracción de aceite de oliva virgen (PEAOV).

Proceso de recolección en el campo

Para la recolección de la materia prima hay que tener en cuenta que las aceitunas de árbol con respecto las de suelo tiene efectos diferentes en la calidad del producto final, así como el tiempo transcurrido desde la recogida del fruto hasta el comienzo del proceso de fabricación del aceite y sin olvidar los defectos en la aceituna debidos a plagas o maltrato en la recolección, por lo tanto, el agricultor que es el encargado de este proceso, debe de recolectar las aceitunas teniendo en cuenta estas consideraciones.

Según el autor del libro ‘Obtención de aceite de oliva virgen’ [1], “El agricultor debe de ser consciente de que tiene que llevar separadamente a la almazara partidas de aceituna diferentes en razón a los ataques de plagas y enfermedades, a la maduración, a los sistemas de recolección, a variedades predominantes, etc. Es la forma de que se pueda clasificar en la almazara las partidas que pueden dar un buen aceite, distinguiéndolas de otras que llevan potencialmente aceites defectuosos. Sin embargo, este proceso es muy costoso para el agricultor y casi imposible de llevar a cabo, por esta razón es necesario un sistema que sea capaz de separar las aceitunas en base a estos criterios y que esté instalado en la recepción de la almazara.

Recepción en almazara

La almazara para esta parte del proceso debe contar con un gran patio con sistemas de tolvas, de forma que se agiliza la recepción, reduciendo el tiempo hasta el inicio de fabricación y disminuyendo el riesgo de maltrato del producto.

Tras la recepción tendríamos un sistema de clasificación capaz de separar las aceitunas según el proceso de limpieza que necesitan; si las aceitunas son de árbol

por lo general la suciedad será simplemente las hojas y ramas pequeñas caídas del árbol en la cosecha, por lo que solo necesitara un limpiado; si por lo contrario el fruto es del suelo y además está mezclado con barro y piedras del suelo, es necesario un lavado tras el limpiado.

El proceso de limpiado se hace efectivo gracias a unos ventiladores y un sistema de cribado, los ventiladores crean una contracorriente de aire que separa las hojas y ramas de la materia prima aprovechando la caída de la cinta transportadora a la criba, por último, la criba separa pequeños terrones de tierra o huesos que caen al tener menor tamaño que las aceitunas.

El proceso de lavado se realiza con una corriente de agua que arrastra a las aceitunas de tal forma que estas flotan, y por tanto el barro y las piedras más grandes que no se eliminan en el proceso de limpieza se decanta y separan del fruto. A la salida de la maquina debe existir algún dispositivo para escurrir y secar las aceitunas para evitar emulsiones a la hora de la molienda [2].

El último paso antes de la fabricación de aceite es obtener el peso del producto limpio y la obtención de la muestra para saber el porcentaje de aceite que aportara el lote de materia prima.

El sistema en el que se implantaría este estudio estaría situado entre el proceso de limpieza y el pesaje, que serían las condiciones más óptimas para adquirir imágenes de las aceitunas y poder clasificarlas según sus defectos o características.

Fabricación de aceite

Tras recolectar y recibir el fruto en la almazara comienza el proceso de extracción del aceite, que se divide en diferentes fases:

- La molienda: Tiene por objeto la rotura de los tejidos de la aceituna donde se aloja la materia oleosa, proceso que se realiza mediante molinos trituradores que producen una pasta.
- El batido: En este proceso se pretende separar las diferentes fases que constituyen la pasta, y debe llevarse a cabo de forma que permita el

mayor contacto de las gotas de aceite sin producir emulsiones que dificulten el proceso de extracción.

- Extracción: se trata de separar el aceite del resto de residuos como el orujo y el alpechín, para este proceso hay dos métodos, el método por presión, que era el más usado antiguamente y el método de centrifugado que es el más extendido hoy en día por ser un sistema continuo.
- Almacenamiento: Por ultimo al ser un producto que tiene demanda durante todo el año y la producción es en una temporada determinada, se necesita almacenar para su utilización gradual, como producto natural necesitas condiciones estrictas para que no se deteriore, teniendo en cuenta la temperatura y humedad entre otras condiciones [1].

Análisis de calidad del aceite a nivel físico-químico y organoléptico.

Antes de desarrollar el proceso de análisis de calidad hay que explicar unos conceptos previos.

- Definición del Aceite de oliva: El Convenio Internacional de Aceite de Oliva de 1986 reserva la denominación de ‘aceite de oliva’ únicamente al aceite procedente del fruto del olivo, con la exclusión de los obtenidos por disolventes, por mezclas con aceites de otra naturaleza y los obtenidos del orujo de aceituna.
- Componentes de los Aceites de oliva: el 98-99% son triglicéridos, esteres de ácidos grasos con la molécula de glicerol, el 2-1% restante son los denominados componentes menores, son los más importantes ya que son los portadores del aroma, el sabor, la estabilidad frente a la oxidación y las muchas sustancias beneficiosas para la salud del aceite de oliva.
- Clasificación de los aceites de oliva: dentro de los aceites de oliva (según la normativa oficial vigente en 2016) el de mayor calidad es el Aceite de Oliva Virgen, que es aquel aceite obtenido exclusivamente por procedimientos mecánicos o por otros medios físicos en condiciones, especialmente térmicas, que no produzcan la alteración del aceite, que no haya tenido más tratamiento que el lavado, la decantación, la centrifugación y el filtrado. En la Ilustración 1 se puede ver la

clasificación a partir de unas propiedades determinadas que se explican a continuación.

CARACTERÍSTICAS DE LOS ACEITES DE OLIVA

Características de calidad

Categoría	Acidez (%) (*)	Índice de peróxido mEq O ₂ /kg (*)	K ₂₃₂ (*)	K ₂₆₄ o K ₂₇₀ (*)	Delta-K (*)	Evaluación organoléptica		Ésteres etílicos de los ácidos grasos mg/kg (*)
						Mediana del defecto (Md) (*)	Mediana del frutado (Mf) (*)	
1. Aceite de oliva virgen extra	≤ 0,8	≤ 20	≤ 2,50	≤ 0,22	≤ 0,01	Md = 0	Mf > 0	≤ 35
2. Aceite de oliva virgen	≤ 2,0	≤ 20	≤ 2,60	≤ 0,25	≤ 0,01	Md ≤ 3,5	Mf > 0	—
3. Aceite de oliva lampante	> 2,0	—	—	—	—	Md > 3,5 (*)	—	—
4. Aceite de oliva refinado	≤ 0,3	≤ 5	—	≤ 1,25	≤ 0,16	—	—	—
5. Aceite de oliva compuesto de aceites de oliva refinados y de aceites de oliva vírgenes	≤ 1,0	≤ 15	—	≤ 1,15	≤ 0,15	—	—	—
6. Aceite de orujo de oliva crudo	—	—	—	—	—	—	—	—
7. Aceite de orujo de oliva refinado	≤ 0,3	≤ 5	—	≤ 2,00	≤ 0,20	—	—	—
8. Aceite de orujo de oliva	≤ 1,0	≤ 15	—	≤ 1,70	≤ 0,18	—	—	—

(*) La mediana del defecto puede ser inferior o igual a 3,5 cuando la mediana del frutado es igual a 0.

Ilustración 1 Tabla de las principales características del aceite(<https://www.boe.es/buscar/doc.php?id=DOUE-L-2016-82301>)

Una vez explicado la forma de clasificar la calidad del aceite a continuación se explicará las diferentes características en las que se basa esta clasificación y los métodos de obtención de estas características que se realizan mediante análisis en laboratorio.

- Determinación del grado de acidez:

La acidez consiste en la aparición de los ácidos grasos libre (AGL de ahora en adelante) como consecuencia del hidrólisis parcial de los triglicéridos, lo que supone una pérdida de grasa y una pérdida de calidad. Esta característica se mide con la siguiente formula:

$$^{\circ}\text{Acidez} = \left(\frac{g\text{AGL}}{100g \text{ de aceite}} \right)$$

El método para la obtención de estos datos se llama volumetría ácido-base que consiste en reaccionar los AGL con una base fuerte (Hidróxido potásico).

- Determinación del índice de peróxidos y radiación ultra violeta:

La oxidación del aceite de oliva se debe a la incorporación de oxígeno a los ácidos grasos insaturados. Este proceso tiene dos etapas, la primera es la de aumento lento de oxidación y la segunda se produce un aumento exponencial de la misma y además es la responsable de la pérdida de las propiedades organolépticas.

Esta evolución se estudia en una curva de oxidación frente al tiempo en la que se diferencia ambas etapas. Una forma de ver la oxidación del aceite es analizar la cantidad de luz ultra violeta que es absorbida por el fluido. Si el aceite se encuentra en la primera etapa de oxidación absorberá la luz ultravioleta a 232 nm (k_{232}) y en el caso de que el aceite se encuentre en la segunda etapa absorbe a 270 nm (k_{270}); todo esto considerando que la muestra se puede encontrar en las dos etapas simultáneamente.

El índice de peróxidos es la cantidad (expresada en miliequivalentes de oxígeno activo por kg de grasa) de peróxidos en la muestra que ocasionan la oxidación del yoduro potásico, su fórmula es la siguiente:

$$IP = \frac{V N 1000}{P}$$

Dónde: V son ml de solución valorada de tiosulfato sódico. N es la normalidad exacta de la solución y P es el peso en gramos de la muestra objeto de estudio.

- Características organolépticas:

También llamada cata es el conjunto de sensaciones detectables por los sentidos: olor, sabor y color correspondientes a los diversos estímulos sensoriales que posee dicha sustancia, en el caso del aceite estos caracteres están relacionados con el flavor y solo cuando supera valores límites se consideran decisivos. Este método se limita a clasificar el aceite en una escala numérica relacionada con el estímulo de su flavor según el juicio de un grupo de 8 a 12 catadores entrenados y seleccionados, y las muestras de cata deben contenerse en

copas de 15ml a una temperatura de $28^{\circ}\text{C} \pm 2^{\circ}\text{C}$ [2]. En la Ilustración 2 se puede apreciar la tabla que deben rellenar los catadores.

FICHA DE CATA DEL ACEITE DE OLIVA VIRGEN

Intensidad de percepción de los defectos		
Atrojado/borras (*)		
Mohoso/húmedo/terroso (*)		
Avinado/avinagrado ácido/agrio (*)		
Aceitunas congeladas (madera húmeda)		
Rancio		
Otros atributos negativos:		
Descriptor:	Metálico ☐ Heno ☐ Gusano ☐ Basto Salmuera ☐ Cocido o quemado ☐ Alpechín Esparto ☐ Pepino ☐ Lubricante	
(*) Bórrese lo que proceda		
Intensidad de percepción de los atributos positivos		
Frutado		
	Verde ☐	Maduro ☐
Amargo		
Picante		
Nombre del catador:		Código del catador:
Código de la muestra:	Firma:	

Ilustración 2 hoja de ensayo organoléptico (<https://www.boe.es/buscar/doc.php?id=DOUE-L-2013-82809>)

1.2. Motivación.

Para explicar la motivación del presente trabajo de fin de grado, es necesario explicar los efectos negativos de los defectos del fruto.

Efecto negativo en el aceite debido a los defectos en el fruto

- **Picadura de mosca del olivo (*Bactrocera oleae*) [3]:**

Se trata de una plaga del olivo, es la más extendida, es un insecto específico del olivo y se encuentra preferentemente en el área del Mediterráneo, en Asia Occidental y en muchas zonas de África.

Una vez que las aceitunas han cuajado, la hembra pone los huevos en los frutos sanos y más desarrollados, para lo que realiza una picadura que es muy característica. Las larvas se desarrollan en el interior de una galería que hacen en la pulpa de la aceituna. Esta galería es estrecha al principio, pero se va ensanchando hasta ocupar una parte considerable del fruto. (ver Ilustración 3)



Ilustración 3 Diversos estados del ciclo biológico de la mosca del olivo [3]

La influencia de la mosca en la calidad del aceite es indirecta, el aumento de la acidez y el deterioro de las características organolépticas no se debe al propio ataque de la mosca [1], sino a la rotura que provoca en la epidermis del fruto, favoreciendo la implantación de un complejo de microorganismos patógenos. Por lo tanto, para obtener aceites de calidad, las aceitunas deben estar exentas de ataques de la mosca del olivo.

- **El escudete de la aceituna:**

Se trata de una enfermedad que afecta exclusivamente al fruto y está causada por el hongo 'Camarosporium dalmaticum', aparece en varios países mediterráneos. Esta enfermedad es originada por la picadura de la mosca del olivo, que provoca una rotura en la epidermis y da pie a que este hongo se desarrolle en dicha rotura. El síntoma más característico y al que hace referencia a su nombre es la aparición en el fruto de una zona de podredumbre de hasta 1 cm de diámetro, de color parado con el centro deprimido y los bordes más oscuros (ver Ilustración 4).




Ilustración 4 Imagen de escudete a la izquierda e imagen a nivel microscópico del hongo a la derecha
[<http://tecnisol-agricola.es/>]

Desde el punto de vista de la calidad del aceite, los daños son los típicos de todas aquellas alteraciones que afectan a la pulpa o provocan caída de fruto, que siempre se traduce en acidez elevada, sabores extraños lo que afecta negativamente a sus propiedades organolépticas. Al igual que pasa con la picadura de mosca, para tener aceite de calidad es imprescindible que el fruto carezca de este defecto.

- **Manchas fitosanitarias**

Con el objetivo de intentar contrarrestar plagas y enfermedades como las dos mencionadas anteriormente, se aplican productos fitosanitarios con plaguicidas y fungicidas que en ocasiones se quedan impregnados en la superficie del fruto, estos productos por norma general al lavar el fruto se pueden eliminar, pero hay veces en que el producto persiste por razones de mal uso de los fitosanitarios o la mala calidad de los mismos.(véase Ilustración 5)



Ilustración 5 muestras de aceitunas manchadas de productos fitosanitarios

Según la autora de la ponencia 'El uso de productos fitosanitarios y sus efectos sobre el hombre y el medio ambiente' y responsable del área urbano-industrial de la F.A.T. en 'el uso de productos fitosanitarios y sus efectos sobre el hombre y el medio ambiente' [4], La toxicidad individual de cada sustancia venenosa de los pesticidas es variable y depende de muchos factores.

Por esta razón es imprescindible, no solo para la buena calidad de aceite, si no para la propia salud del consumidor, descartar este tipo de frutos en los que persiste las sustancias venenosas es imprescindible.

- **Deshidratación en el fruto**

Esta consecuencia en el fruto viene dada por las condiciones de estrés hídrico en determinados momentos del ciclo bianual, a principios de verano, coincidiendo con la fase de engrosamiento de las células de la pulpa y de endurecimiento del hueso, el olivo es muy sensible a las condiciones de sequía; y en caso de que se prolongue la sequía los frutos pueden sufrir graves pérdidas de humedad, lo que hace que el metabolismo del fruto se haga más lento y con ello la producción de aceite disminuye.

También a principios de otoño es importante el estrés hídrico en la planta, ya que el fruto está en fase de crecimiento máximo y la formación de aceite se produce a mayor velocidad, por lo que una sequía en esta etapa puede reducir los contenidos grasos del fruto y en consecuencia en el producto final.




Ilustración 6 Grafica de contenido de grasa sobre materia seca en pulpa [5].

Como se puede apreciar en la Ilustración 6 una aceituna con síntomas de deshidratación durante su desarrollo puede contener menos materia grasa que un fruto sin indicios de deshidratación.

- **Aceitunas heladas**

Este tipo de aceitunas son producidas por las condiciones de frio extremo que se dan en la temporada de recolección del fruto; cuando este temporal se prolonga en el tiempo el fruto adquiere una tonalidad más oscura y aceitosa (ver Ilustración 7).



Ilustración 7 conjunto de aceitunas heladas

Según Beltran et al.,(2000) [6] hay definido dos tipos diferentes de connotaciones sensoriales, dependiendo de la intensidad y tipo de helada; así una helada poco severa y que no se repite en el tiempo, parece dar lugar a notas aromáticas que recuerdan a la fresa sobremadura, mientras que heladas más intensas y sucesivas importantes dan lugar a las típicas notas de madera húmeda que es la que más fácilmente los catadores traducen como aceitunas heladas. Por esta razón la producción de frutos helados puede suponer la pérdida de categoría en el producto final.

influencia del tipo de aceite en el ámbito comercial

Como ya hemos visto en apartados anteriores la calidad del aceite depende de la materia prima que llega a la almazara, y el precio de este también varía respecto a la calidad. Como podemos ver la Ilustración 8 e Ilustración 9 el precio del aceite virgen extra en los últimos 5 años siempre es superior a los otros tipos entre 0.40 y 0.20 céntimos de euro por kilogramo de aceite [7]

	ACEITES DE OLIVA VÍRGENES LAMPANTE (1 g)	ACEITES DE OLIVA VÍRGENES VIRGEN	ACEITES DE OLIVA VÍRGENES VIRGEN-EXTRA
Campaña 2015/16	2,96	3,03	3,19
Campaña 2016/17	3,55	3,62	3,74
Campaña 2017/18	2,73	2,86	3,16
Campaña 2018/19	2,20	2,38	2,77

Ilustración 8 Tabla de relación de precios del aceite de oliva en función de la calidad




Ilustración 9 grafica representativa de tabla de precios

Estos datos demuestran que nos encontramos en una sociedad en la que se premia la calidad, por lo que con el fin de conseguir un aceite de muy alta calidad es esencial tener un sistema capaz de clasificar aceitunas de forma continua, mejorando el proceso de recepción de materia prima en la almazara, con el objetivo final de separar las aceitunas en perfecto estado para obtener aceite virgen extra de alta calidad y diferenciarlas de aceitunas con defectos como la picadura de mosca o el escudete.

Por otro lado, las aceitunas con defectos pueden ser destinadas para otros aceites de menos calidad que sean destinados para otros fines, como por ejemplo geles, cremas, etc. Ya que el aceite de oliva tiene gran cantidad de propiedades beneficiosas.

1.3. Objetivos

Objetivos generales

A la vista de la motivación de este proyecto el objetivo general es diseñar una herramienta para poder estudiar y clasificar los defectos en aceitunas mediante la adquisición y procesamiento de imágenes de diferentes muestras con ayuda de cámaras de espectro visible y multiespectrales cercano al infrarrojo. Los defectos a tener en cuenta de las aceitunas serán en general picadura de mosca, escudete, mancha de productos fitosanitarios, así como el estudio de deshidratación y estado de congelación de las aceitunas mediante su textura.

Objetivos específicos

Los objetivos concretos del proyecto son:

- Diseñar un Setup para la adquisición de imágenes.
- Adquirir suficientes imágenes con el Setup de diferentes muestras de aceitunas tanto defectuosas o no, y con diferentes grados de madurez.
- Desarrollar algoritmos de procesamiento de imágenes en Matlab para detectar cada tipo de defecto, así como el grado de deshidratación o congelación.
- Aplicar los algoritmos a las diferentes muestras para comprobar los resultados que dan los algoritmos en cuestión.

- Comparar las dos tecnologías de visión (espectro visible e infrarrojo).

1.4. Antecedentes

Antecedentes relacionados con el aceite.

En la escuela politécnica de la universidad de Jaén, y más concretamente en el grupo de Robótica, automática y visión por computador, se han realizado y se están realizando estudios como TFG, tesis e incluso colaboraciones con cooperativas de aceite, orientados a automatizar del proceso de obtención de aceite virgen extra, tanto en el ámbito de la producción de la materia prima, como en el ámbito de la almazara. Algunos de ellos se mencionan a continuación:

- “Novel technologies for monitoring the in-line quality of virgin olive oil during manufacturing and storage” (nuevas tecnologías para monitorizar la línea de calidad del aceite de oliva virgen durante la producción y el almacenamiento). [8]

Este artículo publicado en 2016 y realizado por los profesores Julio Beltrán Ortega, Diego M Martínez Gila, Daniel Aguilera Puerto, Javier Gámez García y Juan Gómez Ortega, habla del estado del arte en la monitorización del proceso de obtención del aceite; algunas de las tecnologías mencionadas son la espectroscopia infrarroja aplicada al fruto, que nos puede predecir las características que tendrá el futuro aceite y nos da la posibilidad de tratar el fruto en consecuencia para obtener mejor aceite aplicando tratamiento antes de la recolección del fruto o mezclando con otras variedades del fruto.

Otra tecnología mencionada es la visión por computador, que nos permite la mejor estimación de la fecha de recolección del fruto, la inspección de entrada o clasificación del fruto e incluso detectar la calidad del aceite mediante procesamiento de imágenes; además de la posibilidad de monitorizar el proceso de embotellamiento y clasificación de posibles botellas defectuosas.

También mencionan la nariz electrónica o la lengua electrónica, donde ambas pueden tener las mismas funciones tales como la monitorización de las condiciones de almacenamiento del aceite o determinar la calidad del aceite.

Por ultimo mencionan la espectroscopia dieléctrica que sirve para la predicción de los ácidos grasos, característica de la que depende también la calidad del aceite.

Antecedentes relacionados con la detección de defectos en diferentes frutos

Respecto a este ámbito, también hay proyectos realizados en la universidad de Jaén; el más reciente, que además es en el que más se basa este TFG, es el artículo de detección de picadura de mosca en aceitunas, del que se habla a continuación, así como de otros dos estudios relacionados con defectos en otro tipo de frutos:

- Olive fly sting detection based on computer vision. (Detección de picadura de mosca de oliva basada en visión por ordenador) [9]

Este artículo realizado por Abdulah Beyaz, Diego Martínez Gila, Juan Gómez Ortega y Javier Gámez García, en el grupo de robótica, automatización y visión por computador de la universidad de Jaén, tiene como objetivo estudiar la posibilidad de detectar las picaduras de mosca en aceitunas y diferenciarla de otros posibles defectos.

El estudio se lleva a cabo con el montaje de un setup experimental con el que se toman las imágenes de aceitunas con defectos, para su posterior procesamiento. Como primer objetivo se plantean identificar formas no convencionales en la piel del fruto, y posteriormente clasificar estas formas en picadura de mosca u otro defecto. Se han basado en la utilización de diferentes grupos de colores como el HSV o el CIE $L^*a^*b^*$ para la binarización de las imágenes y detección de defectos, y como clasificadores han usado características morfológicas de los defectos como área, ejes, excentricidad y perímetro; así como las características de las diferentes capas de colores en los grupos anteriormente mencionados.

- “Selector de fruta y simulación de una aplicación real”

Este estudio con formato de TFG lo ha realizado la alumna Miriam Fernández Ribot en la Universidad Politécnica de Cataluña en el año 2006. El objetivo de este proyecto es crear un sistema de detección de fruta en mal estado mediante técnicas simples de procesamiento de imagen tales como histogramas, uso de operadores

morfológicos y cambios a otros espacios de color como HSV; el fruto objeto de estudio es el melocotón.

- “Embedded vision detection of defective orange by fast adaptive lightness correction algorithm” (Sistema de visión integrado para detectar defectos de naranjas mediante un rápido algoritmo corrector de luminosidad) [10]

Se trata de un estudio reflejado en un artículo publicado en abril de 2017 por Dian Rong, Yibin Ying y Xiuqin Rao del colegio de ingenieros de biosistemas y ciencias de los alimentos en la universidad de Zhejiang en china.

Mediante un setup no comercial hecho por los autores del estudio que consta de 6 tubos de leds con diferentes difusores de luz, una cámara industrial de resolución 1288x964 y una cinta transportadora; y con la ayuda de un algoritmo capaz de corregir la luminosidad pretenden eliminar los inconvenientes de la reflectancia irregular que tienen los frutos, que es la causante de errores en la detección de defectos en los frutos; también comparan otros algoritmos de corrección de luminosidad de recientes trabajos de investigación.

Estudios previos desarrollados por el alumno

Como consecuencia del desarrollo de este trabajo fin de grado, se han cursado asignaturas de la índole de Percepción industrial, asignatura que basa su materia en el campo de procesamiento de imágenes, ya que es un punto importante de este proyecto.

También se ha tenido la oportunidad de participar en proyectos desarrollados en el grupo de robótica, automática y visión por computador de la universidad de Jaén, en calidad de prácticas curriculares, el en que se realizaron proyectos relacionados con el ámbito del aceite de oliva y la visión por computador, tales como un estudio para clasificar aceitunas por variedades, y proyectos relacionados con estanterías inteligentes basados en sistemas de visión por computador.

2. Metodología

Antes de proceder a la descripción del estudio es necesario tener en cuenta una serie de consideraciones, tales como el Hardware, software y material en general usados. También es remarcable que los procedimientos que se aplican para el procesado digital de imagen son diversos y un gran número de veces el escoger uno u otro se hace de forma subjetiva. Sin embargo, en el punto de descripción del algoritmo se expondrán las diversas opciones y las decisiones tomadas durante el estudio.

2.1. Descripción del setup

En los siguientes sub-apartados se describirá el setup por partes a destacar como hardware, software y materiales necesarios para completar el correcto funcionamiento del setup y obtención optima de las imágenes.



Ilustración 10 Vista general del setup

En la Ilustración 10 se puede ver el conjunto del setup que más tarde se describirá cada componente por separado, hablando de las características y la razón por la que se ha utilizado este material en concreto, desde los sistemas de visión y sus conexionado, hasta los componentes de sujeción de cámaras o los recipientes de contendrán las muestras de aceitunas para la captura de imagen.

Hardware

2.1.1.1. Plataforma General y sistemas de sujeción

En la Ilustración 10 se puede ver la plataforma general que consta de una base amplia donde se encuentra el campo de visión de las cámaras, además consta de un mástil negro con una especie de brazo regulable en altura, lugar donde van sujetos los sistemas de visión e iluminación, con ayuda de enganches que contiene el propio brazo y con brazos articulados (véase Ilustración 11), que se instalaron adicionalmente, ya que en el brazo principal no hay sujeciones

suficientes para todos los sistemas.



Ilustración 11 brazo articulado usado para la cámara Mako

Cabe destacar que el sistema de iluminación está sujeto con una especie de pinzas con tuerca directamente al mástil, por debajo de brazo donde están sujetas las cámaras, de forma que obtengamos una iluminación óptima y que el foco no aparezca en el campo de visión de las cámaras.

2.1.1.2. Sistemas de visión

- Cámara Mako G223C PoE

Es un dispositivo de carga acoplada (CCD) que es capaz de captar imagen en el espectro visible (RGB), el sensor tiene una resolución de 2048x1088 de píxeles (2.2 Megapíxeles) y un tamaño de píxel de 5.5x5.5 μm con un tiempo de exposición regulable entre 21 μs y 153s y con un Frame Rate de 49.5(fps).

Como se puede ver en la Ilustración 13 la conexión de datos al pc se hizo mediante cable Ethernet gigabit, y la alimentación de la cámara se realizó mediante una fuente de tensión de 12V como la de la Ilustración 12

En la Ilustración 13 también se puede apreciar que la cámara tiene instalada una focal de 35 mm.



Ilustración 13 Cámara Mako G223C



Ilustración 12 Fuente de alimentación

- Photon Focus (Cámara multiespectral)

Se trata de un sensor de imagen CMV IMEC CMV2K-LS100-NIR con resolución de 2048 x 1088 píxeles y un tamaño de pixel de 5.5x5.5 μm , hasta 42fps a resolución completa, actúa en 25 bandas de paso de 600nm a 975nm e interfaz GigEVision, con un tiempo de exposición regulable de 13 μs a 349ms. Con una focal de 35mm que se puede ver en la Ilustración 15, y de igual forma que la cámara Mako, está conectada mediante Ethernet gigabit al pc como conexión de datos, y como alimentación está conecta a la misma fuente que la cámara Mako, se pueden ver ambas conexiones en la Ilustración 14



Ilustración 14 cámara multispectral



Ilustración 15 focal de la cámara multispectral

2.1.1.3. Sistemas de Iluminación

Como sistema de iluminación se ha utilizado un foco alógeno de 500W (ver Ilustración 16) conectado directamente a la red eléctrica, como se ha comentado anteriormente está sujeto al mástil con unas pinzas y orientado hacia la base de la plataforma del setup de tal forma que la luz incida en el campo de visión lo más perpendicular posible, para crear la menor cantidad de sombras con los frutos y teniendo en cuenta que no aparezca el foco en el campo de visión de ninguno de los sensores. Por último según esta disposición el foco nos aportaba en la zona de visión una intensidad lumínica de 3.76 klux que se puede apreciar en la Ilustración 17.




Ilustración 17 intensidad lumínica en campo de visión



Ilustración 16 Perfil del foco instalado en el setup

2.1.1.4. Conexionado al PC

La conexión de datos con el computador se realiza mediante una tarjeta de red con diversos puertos de conexión que se puede observar en la Ilustración 18




Ilustración 18 Conexionado de
datos al PC

El puerto señalado en la imagen con el número 1 corresponde a la cámara Mako y el puerto con el número 2 corresponde a la conexión de la cámara multiespectral.

Software

Se han usado diferentes softwares en los distintos procesos de desarrollo del estudio, entre los que se destaca el proceso de adquisición de la imagen y el procesamiento de las imágenes y por último la recopilación y estudio de datos:

- **Sapera cam**

Este software se ha usado tanto para configurar las cámaras como para adquirir la batería de imágenes que posteriormente se procesaron con otro software; a continuación, se explica con ayuda de una captura de pantalla el funcionamiento de Sapera cam y las funciones usadas en este proyecto.




Ilustración 19 vista general de Sapera cam

En la Ilustración 19 se puede apreciar una vista general de la interfaz del programa, se divide en dos zonas fundaméntales, en la mitad izquierda se encuentra la elección y configuración de las cámaras; y en la mitad derecha se recibe la señal de la cámara.

La zona de la izquierda, que se aprecia mejor en la Ilustración 20, se divide a su vez en otras dos zonas, en la zona 1 encontramos dos menús emergentes y dos botones, el primer menú emergente (Device) es donde seleccionaremos la cámara con la que queremos adquirir la imagen, en este proyecto se usaba en cada muestra ya que la misma muestra se capturaba tanto con el dispositivo RGB como con el multispectral; el segundo menú (configuration) te da la opción de cargar una configuración de la cámara previamente realizada.




Ilustración 20 zona izquierda del software Spera cam

Por ultimo en la zona 2, aparecían los parámetros de configuración de la cámara, tales como la ganancia, el tiempo de exposición del sensor, etc.




Ilustración 21 zona derecha del software Spera cam

En la Ilustración 21 se puede apreciar la zona de la derecha de la interfaz, que consta de una serie de botones para las opciones de la adquisición de las imágenes y una zona amplia donde aparece la señal del sensor en tiempo real, los botones usados en este proyecto son los señalados en la imagen, el botón 1 permite la opción de iniciar o parar la recepción de imagen y botón 2 nos permite hacer la

adquisición de imagen. Con el resto de botones se puede hacer zoom en la imagen u obtener el histograma de la imagen congelada.

- **Matlab®**

Para realizar el algoritmo que detecte los posibles defectos en el fruto es necesario escoger antes un entorno de trabajo cómodo y que ofrezca las herramientas necesarias para programar. Es por este motivo que se ha escogido como software Matlab®, ya que junto con Image Processing Toolbox de Matlab® facilitan mucho el procesamiento de imágenes y con ello el desarrollo de los algoritmos necesarios.

Una vista general de la interfaz de Matlab® se puede apreciar en la Ilustración 22, donde destacan 4 zonas principales, la barra de herramientas, el editor de código, la ventana de variables y la ventana de comandos.




Ilustración 22 vista general del software Matlab

En la barra de herramientas (Ilustración 23) se pueden encontrar los típicos ítems de crear, abrir y guardar un script o función, además de algunas funciones para editar el código, poner putos de ruptura o correr el código para poder depurarlo.




Ilustración 23 barra de herramientas de Matlab

El editor de código es el entorno donde se desarrollan los algoritmos y funciones, donde cada línea de código esta numerada para identificar errores fácilmente; todo esto se puede ver en la Ilustración 24.




Ilustración 24 Editor de código de Matlab

Por ultimo tenemos las ventanas de comandos y de variables (Ilustración 25), en la primera se pueden ir ejecutando los algoritmos o haciendo operaciones básicas al mismo tiempo que recibimos la información que nos ofrece el algoritmo; también en caso de existir algún error sintáctico o evolutivo en la ejecución de un algoritmo se manifestara por la venta de comandas; la ventana de variables por otro lado nos muestra los valores y formatos de las variables que se crean al ejecutar los algoritmos.




Ilustración 25 venta de comandos y de variables de Matlab

Material

El material adicional usado en el setup está dedicado sobre todo al posicionamiento de las muestras de frutos dentro del campo de visión de las cámaras, como se puede ver en la Ilustración 26 se usaba una cartulina blanca para que el fondo de la imagen fuese lo más simple posible y de este modo facilitar el reprocesado de las imágenes, además en este fondo blanco hay unas señales con cinta adhesiva para posicionar siempre el contenedor de las aceitunas en la misma posición; este recipiente de metacrilato se usaba para contener el fruto dentro del campo de visión y así poder controlar mejor la posición de las muestras en conjunto, también se usa un soporte realizado por impresora 3D para las muestras individuales, este soporte facilita la posición adecuada de cada aceituna, pudiendo hacer capturas de diferentes perfiles del fruto sin que se rodara o se moviese justo en el momento de la adquisición de la imagen, este objeto se puede ver en la

Ilustración 27.




Ilustración 26 campo de visión de los sensores




Ilustración 27 soporte de aceitunas

2.2. Muestras experimentales

La recolección de muestras se realizó a lo largo de la campaña de 2017-2018; como el objetivo principal del proyecto es el estudio de la viabilidad en detectar diferentes defectos en aceitunas, es necesario tener los posibles casos en que se presenten estos defectos en los frutos y a su vez tener representados los diferentes estados de madurez de los frutos.

El lugar donde se recolectó las muestras de aceitunas es una parcela situada en el término del municipio de Castillo de Locubín, en la provincia de Jaén, con una superficie de 0.6687 hectáreas dedicadas a la explotación del olivar de secano, con N° de polígono 20 y N° de parcela 336. En la Ilustración 28 se puede ver una vista desde el cielo de la ubicación de la finca.



Ilustración 28 Ubicación de la finca <http://sigpac.mapa.es/feqa/visor/>

También hay que mencionar que a causa del desconocimiento de adquisición de imágenes y ausencia de setup al principio del periodo de recolección de

muestras, hubo que estudiar una forma adecuada de almacenar las primeras muestras, para más tarde poder hacer la adquisición de imágenes; a continuación, se explica dicho proceso de almacenamiento y posteriormente se detallará el proceso de recolección:

- **Estudio de almacenamiento**

Inicialmente se pensó que un buen método de conservación de las muestras sería envasar los frutos al vacío en bolsas de plástico transparente como algunos embutidos y guardarlas en el frigorífico, sin embargo, esto no era suficiente, al cabo de unos días las bolsas perdían el vacío y las aceitunas seguían el proceso de descomposición.

El siguiente paso fue además de envasarlas al vacío congelar las muestras; al mismo tiempo surgió otro problema, y es que las muestras que tenían un estado de madurez más avanzado se machacaban con el sistema de vacío y cuando se descongelaban perdían todas las propiedades visibles que tenían antes del proceso, por lo que este método de conservación no era efectivo para todas las muestras, consecuentemente se hicieron diversas pruebas para ver que método de conservación era el más adecuado para todas las muestras, en la siguiente Ilustración 29 se puede ver dos de las muestras concluyentes para decidir cuál sería el método más eficaz.



Ilustración 29 Diferentes pruebas de envasado al vacío

Las imágenes a) y b) son de una muestra en basada al 100% de vacío que tras descongelarla los frutos han perdido por completo las propiedades visuales, en las imágenes c) y d) se ve una muestra al 80% de vacío que tras descongelarse conservan muy bien sus propiedades visuales. Por esta razón deducimos que el mejor método para conservar las muestras es haciendo un envasado no muy agresivo (al 80-85%) para no dañar el fruto y congelando las muestras para que conserven todas sus propiedades visuales.

- **Proceso de recolección**

-3 de octubre (1ª grupo de muestras), se recolecta muestras de aceitunas verdes con los defectos de picadura de mosca y escudete y algunas muestras de aceitunas sanas.

Los demás defectos como manchas fitosanitarias o aceitunas heladas o deshidratadas para estas fechas no se han dado condiciones climatológicas para que se produzcan dichos defectos ni tampoco ha comenzado la temporada en la que se ha sulfatado la planta del fruto.

-7 de octubre (2ª grupo de muestras), se recolectan más muestras de aceitunas verdes con defectos de picadura de mosca y escudete.

Estos dos primeros grupos son muestras que se guardaron en frigorífico y perdieron el vacío, por lo que se volvieron a envasar al vacío y esta vez se congelaron, finalmente solo se pudo aprovechar el primer grupo de muestras ya que el segundo al descongelarlo perdió todas sus propiedades visuales.

-27 de octubre, se envasaron de nuevo el primer y segundo grupo de muestras y se congelaron.

-30 de octubre (3º grupo de muestras), se recolectaron aceitunas en proceso de maduración con defectos de picadura de mosca y escudete y algunas muestras de aceitunas sanas.

-25 de noviembre (4º grupo de muestras), se recolectaron muestras con manchas fitosanitarias y con un grado de madurez elevado.

A partir de este periodo de recolección ya se disponía de setup, por lo tanto, no era necesario envasar las muestras, ya que se realizaba la adquisición al mismo tiempo que la recolección.

-4 de diciembre (5º grupo de muestras), se recolectaron muestras de frutos verdes y helados, así como de aceitunas con un nivel de maduración más elevado y defectos de picadura de mosca y escudete.

En este tiempo de recolección plantas que están cerca de riachuelos o barrancos tienen el riesgo de que se congelen las aceitunas con las bajas temperaturas.

-13 de diciembre (6º grupo de muestras), se adquirió muestras de frutos deshidratados y algunas más heladas.

Cuando el proceso de maduración del fruto se completa y la planta necesita nutrientes esta los obtiene de vuelta del fruto, por lo que el fruto se arruga y pierde porcentaje de agua, pero no de aceite, también es efecto de deshidratación cuando el fruto cae al suelo por el viento y la madurez y por el paso del tiempo pierde de nuevo porcentaje de agua.

-2 de febrero (7º grupo de muestras), se recolecto con un alto grado de madurez muestras con todos los tipos de defectos objeto de estudio en este proyecto.

2.3. Proceso de adquisición de imágenes

Antes de explicar el proceso de adquisición de imágenes de las diferentes muestras hay que mencionar la orientación que llevaría el desarrollo de todos los algoritmos. La idea general es desarrollar los algoritmos para los diferentes defectos, primero en aceitunas individuales y después extrapolar y aplicar los mismos algoritmos a muestras de conjuntos de aceitunas, a esto hay que sumar que en paralelo se adquirirían imágenes en el espectro visible y en el espectro cercano al infrarrojo para poder realizar la comparativa de las dos tecnologías de visión. Y por esta razón era necesario obtener parejas de imágenes (espectro visible y cercano al

infrarrojo) con frutos individuales e imágenes con conjuntos de frutos en cada una de las muestras recolectadas.

Estudio de posicionamiento de aceitunas

Para la optimización en la adquisición de las imágenes de los frutos con los defectos se realizó un estudio de cuáles eran las vistas más adecuadas de los perfiles del fruto; este estudio se aplicó primero a las muestras de frutos individuales, y consistió en adquirir de cada fruto al menos 4 imágenes con vistas diferentes del fruto, que con ayuda de la pieza de plástico impresa en 3D (Ilustración 26) se fueron realizando, estas vistas se pueden ver en el ejemplo de la Ilustración 30, las dos primeras vistas son del perfil del fruto, la siguientes se puede ver el pericarpio y el pedúnculo.



Ilustración 30 diferentes perspectivas de una misma aceituna

Con estas 4 vistas tenemos todas las perspectivas del fruto y de los posibles lugares donde se aloje el defecto.

Cabe mencionar que el número de vista varía de forma subjetiva, ya que premia más tener las diferentes vistas de un defecto que cubrir la vista de todo el fruto, por esta razón el número de vistas de un fruto pueden variar de 4 a 6.

Por último este estudio se extrapoló a las posiciones del fruto en muestras de conjunto de aceitunas que, si bien tenían un orden aleatorio, se controlaba que el máximo número de defectos estuviese visible en cada imagen, un ejemplo de imagen de conjunto se puede ver en la Ilustración 31.



Ilustración 31 imagen de conjunto de aceitunas en el espectro visible



Ilustración 32 imagen de conjunto de aceitunas en el espectro infrarrojo

Como se ha mencionado anterior mente simultáneamente se adquirirían imágenes multiespectrales por lo que en la Ilustración 31 e Ilustración 32 se puede apreciar el ejemplo de una misma muestra capturada en las dos tecnologías de visión.


Adquisición de imágenes

Ilustración 33 esquema de adquisición de imágenes

En cada muestra recolectada, separadas por defectos, se realizaba un orden en la adquisición de las imágenes que se puede ver en el esquema superior, primero dentro del lote de frutos se escogían entre 5 y 10 frutos en los que existiese defecto, y se adquiría una imagen por cada vista y por cada sensor(espectro), y tras obtener las imágenes de muestras individuales, se pasaba a adquirir las imágenes de conjunto de frutos, para este tipo de imágenes los frutos se movían aleatoriamente al menos 5 veces para obtener diferentes muestras y de nuevo se realizaban una captura con el espectro visible(RGB) y otra con el espectro cercano al infrarrojo(NIR).(ver Ilustración 33)

El orden cronológico de las muestras es el siguiente:

-25 de noviembre, se inició el proceso de adquisición de imagen con el grupo de muestras 4, que son frutos con manchas fitosanitarias.

-4 de diciembre, se adquirió las imágenes de muestras del grupo 5, compuesto por imágenes de frutos helados, maduros con escudete, maduras y verdes con picadura de mosca, y un grupo de frutos sanos.

-13 de diciembre, este día se realizaron capturas de muestras heladas y deshidratadas que componen el grupo 6.

-19 de diciembre, se hace la adquisición de una parte del grupo 1 de muestras que estaba previamente congelado, solo hizo con las aceitunas picadas por mosca.

-1 de febrero, se realiza la captura de imágenes del resto del grupo 1, que fueron aceitunas con escudete y algunas aceitunas sanas.

-2 de febrero, se adquirió las imágenes del grupo 7 de muestras, con los cinco tipos de defectos.

-9 de febrero, adquisición de imagen del grupo 3 que fue congelado el 30 de octubre, y contenía frutos con picadura y escudete.

2.4. Algoritmos para el espectro visible

El objetivo de los algoritmos es detectar cada tipo de defecto por separado con la mayor eficiencia posible y el menor porcentaje de error, este proceso se ha realizado en dos fases subdivididas en tantos grupos como defectos hay, las dos etapas principales son desarrollo de algoritmos y validación, y los grupos serían la repetición de las etapas en cada defecto, siendo algunos de los grupos muy parecidos entre ellos, sobre todo los procesos de desarrollo de los algoritmos de los defectos de picadura, escudete y manchas, teniendo desarrollos diferentes los algoritmos de las aceitunas deshidratadas y las heladas.

La primera fase abarca todos los pasos realizados en el desarrollo de un algoritmo adecuado para la detección del defecto, desde el proceso de diseño del algoritmo hasta la toma de decisión del diseño elegido. Por otro lado, la segunda etapa es una aplicación multitudinaria del algoritmo para verificar el correcto funcionamiento. Las imágenes de las aceitunas individuales se usarán para la primera etapa, y para la segunda etapa se usarán imágenes de aceitunas

individuales y en conjunto para comprobar en cuales hay mejor resultado y poder dar una mejor conclusión.

Fase de desarrollo




Ilustración 34 Proceso de la fase de desarrollo

En la Ilustración 34 se puede apreciar los diferentes grupos que componen la fase del desarrollo, se pueden apreciar tres grupos diferentes, preprocesamiento (grupo azul), procesamiento (grupo naranja), y clasificación (grupo verde). A continuación, se explican cada grupo en detalle.

2.4.1.1. Preprocesamiento

Una parte fundamental en la visión por computador es el tratamiento de las imágenes previo a la segmentación denominado preprocesamiento que consiste en preparar la imagen para facilitar el resto de pasos que con lleva procesar una imagen. En este proyecto el preprocesamiento se basa en tres acciones distintas.

- **Separar el fruto del fondo.**

El motivo de esta acción es sencillo, como se puede observar en la Ilustración 35, a pesar de ser un fondo blanco y casi uniforme, gracias a saturación de la

imagen en el equilibrio entre quitar mucho ruido y no perder la información del fruto variando el tiempo de exposición del sensor y la ganancia) se ven claramente zonas de sombra provenientes del soporte de la aceituna y del propio fruto que en el momento de detectar regiones de interés se manifiestan como ruido.




Ilustración 35 ejemplo de la imagen de una muestra individual

Este proceso se realiza mediante una función que se ha denominado 'nonbackground' y los pasos que realiza esta función se pueden apreciar en la Ilustración 36, en la sección 'a' se observa la adquisición de la imagen RGB, de la que pasamos a la imagen 'b' que muestra el canal G proporcionando una imagen a niveles de grises que indican la cantidad de color verde que hay en la imagen original, al binarizar esta imagen con un umbral adecuado se obtiene la imagen 'c', en esta se puede observar que el fruto está en valor 0 (píxeles negros) por lo que hay que invertir los valores de los píxeles para obtener el caso 'd', ahora que el fruto está como región de interés se puede apreciar el ruido anteriormente mencionado, al no ser mayor que el área en píxeles de la aceituna es posible filtrar la imagen con la función 'bwareaopen' que se encarga de eliminar las zonas menores al parámetro que se indique como entrada, en este caso con un parámetro de 10000 píxeles es suficiente; cuando solo queda como región el fruto recortamos las imágenes (original y binarizada) mediante las propiedades de 'BoundingBox' que la proporciona la función 'regionsprop', esta proporciona como resultado las imágenes 'f' y 'g'; finalmente con las propiedades 'FilledImage' (contorno de la región de interés) y 'SubarrayIdx' (similar a 'BoundingBox') obtenemos el fruto separado del fondo.




Ilustración 36 proceso de separar el fruto del fondo


- **Convertir a espacio de color hsv y CIE L*a*b* y separación por canales.**

El desarrollo de esta fase del algoritmo se fundamenta en los diferentes espacios de colores; un modelo de color es un modelo matemático abstracto que describe la forma en la que los colores pueden representarse.

El modelo RGB es un modelo de color basado en la síntesis aditiva, con el que es posible representar un color mediante la mezcla por adición de los tres colores de luz primarios, lo que significa que en este proyecto puede ser interesante este grupo de color para obtener el contraste entre defecto y superficie del fruto, pero tras probar la fase de binarización en los canales de este grupo de colores el defecto no se diferencia demasiado bien, por lo que se decidió transformar a los grupos de colores hsv y CIE L*a*b*.


Modelo hsv

Este modelo Define el color en términos de sus componentes en coordenadas cilíndricas. Se presenta como un grado de ángulo cuyos valores posibles van de 0 a 360° y cada valor corresponde a un color. Las siglas en ingles Hue, Saturation, Value – Matiz, Saturación, Valor.



Modelo CIE $L^*a^*b^*$

En este caso el propósito del modelo CIE $L^*a^*b^*$, más estrictamente llamado CIE 1976 $L^*a^*b^*$, es producir un espacio de color que sea más 'perceptiblemente lineal' que otros espacios de color, esto significa que un cambio de la misma cantidad en valor de color debe producir un cambio casi de la misma importancia visual. Lo que se traduce en el presente proyecto en un contraste más claro entre el defecto y la superficie del fruto.



En la siguiente Ilustración 37 se pueden apreciar un ejemplo del fruto en los diferentes espacios de color.




Ilustración 37 Diferentes espacios de color con sus correspondientes canales

A primera vista que el canal con mayor contraste entre superficie de fruto y defecto se encuentra en el grupo de colores CIE $L^*a^*b^*$ en el canal a^* , y este es el motivo por el que se elige este canal para seguir el proceso del algoritmo, sin embargo, también se usaran la información del resto de canales para obtener

características del defecto y las sombras con el objetivo de entrenar una red de neuronas, proceso que se explica más adelante.

2.4.1.2. Procesamiento

2.4.1.2.1. Segmentación

La segmentación es el procedimiento que subdivide en la imagen en las partes que la constituyen, el nivel en que se realiza la subdivisión depende del problema a resolver, es decir, la segmentación debería pararse cuando las regiones de interés en una aplicación han sido aisladas. [11][Gonzalez,Woods,1993]. En este caso la segmentación se divide en tres niveles, umbralización, binarización, y uso de estructuras morfológicas, el orden de estos niveles se puede ver en la Ilustración 38.

Segmentación



Ilustración 38 estructura de segmentación

- **Umbralización y binarización**

Los niveles de umbralización y binarización se consiguen barriendo la imagen pixel a pixel para etiquetar cada pixel como ‘defecto’ o ‘superficie del fruto’, según si el valor del pixel es mayor o inferior que un cierto valor llamado umbral. La selección de este umbral es un aspecto fundamental, ya que determina en gran medida la calidad del resultado final de la segmentación. De este modo el umbral no es elegido al azar, si no que se realizó un estudio previo de los histogramas del canal a* en los diferentes defectos que se puede apreciar en las siguientes ilustraciones (Ilustración 39, Ilustración 40 e Ilustración 41).




Ilustración 39 datos para umbralización en picadura de mosca. Imagen izquierda: histograma del canal a*. Imagen derecha: ponderación de un pixel en el defecto con otro en fruto.




Ilustración 40 datos para umbralización en escudete. Imagen izquierda: histograma del canal a*. Imagen derecha: ponderación de un pixel en el defecto con otro en fruto.




Ilustración 41 datos para umbralización de la mancha fitosanitaria. Imagen izquierda: histograma del canal a*. Imagen derecha: ponderación de un pixel en el defecto con otro en fruto.

Observando los histogramas y los niveles de grises en los píxeles de defecto se llega a la conclusión de que en caso de los defectos de picadura y escudete un umbral de 0.6 es adecuado para binarizar la imagen y obtener las regiones de interés necesarias, en cambio en el caso de las manchas fitosanitarias el umbral sería 0.5, teniendo en cuenta que el valor de pixel en defecto es inferior al umbral, lo que significa que el pixel de defecto quedara como 0 (región negra) y el valor del pixel de la superficie del fruto quedara como 1 (blanco), en este caso habría que añadir otro proceso a la segmentación que consistiría en invertir la imagen binaria para tener el defecto con valores de 1 y poder detectarlo.

- **Estructuras morfológicas**

Tras binarizar la imagen con los correspondientes umbrales, y aunque los resultados de la binarización sean aceptables es necesario eliminar el ruido de la imagen y rellenar huecos en el objeto a segmentar.

La forma de los defectos es aproximadamente redonda, tanto en la picadura de mosca como el escudete he incluso las manchas fitosanitarias predomina la forma redonda, que siendo gotas de agua impregnadas en la piel del fruto suele tener esta forma, por lo tanto, teniendo en cuenta la morfología de los defectos es conveniente usar un elemento estructurante con la forma de disco.

Este disco es un círculo en blanco que barre la imagen y realiza las modificaciones según la operación morfológica asignadas. En la siguiente Ilustración 42 se aprecia un ejemplo de la aplicación de una erosión seguida de una dilatación.

Se puede ver en el proceso como la erosión elimina ruido pequeño perteneciente al contorno del fruto y la sombra, y tras la erosión la dilatación acentúa las zonas de defecto para que sea más fácil detectar dichas regiones de interés.




Ilustración 42 aplicación de los elementos morfológicos

2.4.1.2.2. Extracción de características

Una vez identificadas de forma clara las regiones de interés, se procede a extraer características de las zonas de defecto con dos propósitos principales, el primero es conseguir señalar el defecto para etiquetar el fruto como defectuoso o en caso contrario de no existir defecto se etiquetaría como fruto sano, el segundo propósito sería para obtener datos con los que entrenar una red de neuronas en el caso de que sea necesario, que por diversos motivos que se explican más adelante en este proyecto es necesario hacer uso de redes neuronales.

Dependiendo del tipo de defecto se han extraído diferentes grupos de características, y podemos identificar dos grupos, características para la picadura, escudete y manchas fitosanitarias; y por otro lado características para los frutos helados y deshidratados. La separación en estos dos grupos es sencilla, desde un principio se pensó en aplicar algoritmos que extrajeran información de la textura en el caso del segundo grupo, y para el caso de del primer grupo se podían usar

características morfológicas además de obtener las intensidades medias de cada canal de color, cada característica se explica adecuadamente a continuación.

- **Grupo de características para las picaduras, el escudete y las manchas fitosanitarias**

Para este grupo de defectos se extraen 11 características en total, dos de ellas nos la proporciona la función 'regionprops' que está incorporada en la toolbox de procesamiento de imágenes de Matlab, son el área y la excentricidad; las otras nueve características se obtienen haciendo la media de intensidad de los diferentes canales de color mencionados anteriormente.

-Área: Esta característica proporciona el número real de píxeles en la región de interés y la función lo devuelve como un número escalar.

-Excentricidad: Es la relación entre la distancia de los focos de una elipse y la longitud del eje principal, esta característica devuelve un escalar de valores comprendidos entre 0 y 1, estos extremos no representarían una elipse ya que si el valor es 0 significa que la distancia entre focos es nula y estaría en el caso de un círculo, y si el valor es 1 significaría que estamos ante una línea recta es decir que la distancia entre focos sería igual que la distancia del eje principal(véase Ilustración 43).




Ilustración 43 excentricidad de una elipse

El resto de características se obtiene haciendo la media de los valores de intensidad del histograma que proporciona la región de interés (defecto) en cada uno de los canales de color, esto se realiza aplicando la máscara que contiene las

regiones de interés a cada una de las imágenes obtenidas de cada canal de color, de forma que solo se realiza la media de intensidad del histograma de las regiones que ocupan las partes blancas de la máscara (regiones de potencial defecto).

Todos estos datos se guardan en una matriz de n filas y 11 columnas, las filas corresponde al número total de regiones que contiene la máscara, y las 11 columnas son las características que se están extrayendo,

- **Grupo de características para los defectos de deshidratación y fruto helado**

Para este grupo se extraen 20 características en total que proporcionan dos funciones:

-**La función 'Statxure'** calcula 6 medidas de estadística de textura en una imagen y las devuelve como un vector de escalares, las medidas que realiza son las siguiente:

T (1) = La media del histograma

T (2) = Desviación estándar a partir de la varianza del histograma

T (3) = Medida de suavidad; primero se normaliza la varianza entre 0 y 1 con la fórmula $\text{varn} = \text{varianza} / (L - 1)^2$ y después se calcula la suavidad con esta otra fórmula $t(3) = 1 - 1/(1 + \text{varn})$;

T (4) = Tercer momento; se trata del tercer momento central estadístico de un histograma. También se normaliza: $t(4) = \text{tercer momento} / (L - 1)^2$.

T (5) = Medida de uniformidad, que es la sumatoria de los valores del histograma normalizado, $t(5) = \sum (\text{histograma normalizado})^2$;

T (6) = Entropía, que se calcula con la fórmula: $t(6) = -\sum(p \cdot \log_2(p))$, donde 'p' es el histograma normalizado.

-**La función 'HaralickTextureFeatures'** esta función calcula las 14 medidas de textura que el profesor Robert M Haralick recoge y desarrolla en su trabajo [12]

'Texture Feature for Image Classification' en el año 1973, y las devuelve como un vector de escalares.

Por lo que como resultado obtenemos por cada fruto procesado un vector de 20 características.

2.4.1.3. Clasificación

En el proceso de desarrollo de la segmentación de los defectos de picadura y escudete se pensó que con la segmentación sería suficiente para detectar los defectos en cuestión, sin embargo, con la prueba de este algoritmo primario y los resultados obtenidos se observó que, a pesar de tener un porcentaje de acierto razonable, los falsos positivos eran demasiado altos ya que en ocasiones las sombras del fruto se incorporaban como regiones de interés, esto es debido a que ciertas zonas de la sombra tenían el mismo nivel de intensidad de los del defecto, por esta razón se implanto la idea de desarrollar redes neuronales que clasificara las regiones de defecto y las regiones que no son defecto, es necesario remarcar que en el caso de los defectos de machas fitosanitarias este problema se da en muy raras ocasiones, por lo que no se podían obtener datos de regiones que no sean defecto, por esta razón para este tipo de defectos no se implementó red neuronal, en la Ilustración 44 se puede apreciar lo explicado.




Ilustración 44 imagen izquierda: aceituna con macha fitosanitaria sin señalar sombras, imagen derecha: aceituna con escudete y zonas de sombra señaladas.

Para los defectos de deshidratación y aceituna helada desde un principio se consideró usar redes neuronales para clasificar los niveles de deshidratación y fruto helado.

- **Red neuronal**

Una red neuronal está formada por una serie de unidades de procesamiento muy simples que están conectadas entre sí y cuyas salidas dependen de la entrada y de las conexiones entre las unidades de procesamiento (véase Ilustración 45). Cada nodo tiene asociado un nivel de activación, cuyos pasos se aprenden durante el proceso de entrenamiento.




Ilustración 45 esquema red neuronal

Matlab aporta una toolbox adecuada para desarrollar una red de neuronas. Con el comando 'nprtool'; al inicio del proceso de entrenamiento se debe insertar una matriz de datos de entrada, que se correspondería con las matrices de características anteriormente expuestas, y una matriz de salida (target) que nos indica la distribución de salida.

Para que la obtención de una gran cantidad de datos necesarios para entrenar las diferentes redes neuronales y que esta tarea no sea demasiado tediosa, se desarrollan interfaces gráficas, una para los defectos de picadura, escudete y mancha fitosanitaria, y otra interfaz diferente para las características de textura

obtenidas de los defectos de deshidratación y congelación, a continuación, se procede a la exposición de ambas y explicación de su funcionamiento. Cabe mencionar que estas interfaces se han desarrollado con la toolbox de Matlab.

- **Interfaz gráfica para los defectos de picadura y escudete**

Es necesario señalar que para esta fase del proyecto la segmentación del defecto es mucho menos restrictiva para las zonas de interés, ya que el objetivo es detectar lo mejor posible la sección del defecto aun que esto signifique tener mucho ruido. Al fin y al cabo, con ayuda de la interfaz se podrán extraer datos de los dos tipos de región (defecto y no defecto) de forma objetiva.




Ilustración 46 Vista general del interfaz para los defectos de picadura, escudete y mancha fitosanitaria.

En esta interfaz se puede diferenciar dos grandes zonas (véase Ilustración 46), la zona de la izquierda donde se hace la adquisición, el procesamiento de la imagen y la clasificación visual de las regiones de interés; y la zona de la derecha donde se van representando las características de las regiones de interés.




Ilustración 47 botonera de la zona derecha de la interfaz

En la Ilustración 47 muestra los primeros 4 botones, cuyo funcionamiento es elegir la carteta donde se encuentra las muestras de imágenes, pasar las imágenes fácilmente hacia adelante y atrás; y conforme pasemos de imagen tenemos el botón de procesar, que tiene la función de ejecutar la parte de segmentación y obtención de características de algoritmo. Los tres editores de texto modifican los parámetros de umbralización, erosión y dilatación, ya que el mismo interfaz es usado para tres defectos diferentes, hay que tener en cuenta que cada clase de defecto necesita unos parámetros diferentes.

También es destacable la parte inferior de esta región del interfaz, aquí se encuentra los botones con los que elegimos que tipo de característica estamos guardando y que numero de región estamos eligiendo, de modo que se hace fácil la clasificación de las regiones denominadas defectos con respecto a las regiones que no son defectos.

La zona de la izquierda del interfaz se puede apreciar en la Ilustración 48, se trata de una serie de matrices que representan numéricamente los vectores de características de las regiones de interés, en la primera tabla se plasman los datos

de las imágenes que se van procesando, en las siguientes dos tablas se va guardando las características dependiendo de si es región de defecto o región de no defecto, por ultimo cuando ya estén todas las muestras procesadas y las características guardas en su correspondiente matriz, se procede a combinar las matrices en el formato necesario para importar a un archivo Excel y que posterior mente esos datos se puedan usar para entrenar una red neuronal, en el archivo Excel aparecerán dos hojas, en la primera estará la matriz de datos de entrada a la red de neuronas y en la segunda hoja aparecerá la matriz target que representa la distribución de salida de la red de neuronas que es necesaria también para dicho entrenamiento y aun que no se muestra en ninguna matriz de la interfaz este cálculo se realiza simultáneamente con la función del botón combinar matriz.

Características de la imagen					
	Area	Exc.	hist R	hist G	hist B
1	577	0.9911	182.0858	148.5455	88.8851
2	13	0	190.3077	153.3846	94
3	13	0	196.1538	160.0769	94.3077
4	18	0.3873	201.5000	165.1111	98.0556
5	42	0.6902	156.9762	128.0714	69.6190
6	65	0.8858	216.0615	179.7846	109.8769
7	31	0.8493	127.9677	103.9032	57.8065
...	...	...	...	...	...

Caract. defecto			Caract. no defecto		
	Area	Exc.		Area	Exc.
1	53	0.5794	1	216	0.9153
2	433	0.4942	2	68	0.6772
3	155	0.9574	3	35	0.7994
4	249	0.6905	4	1544	0.8335
5	2406	0.8283	5	31	0.5937
6	608	0.5715	6	13	0
...	...	...	7	42	0.9325
...	...	...	8	909	0.9384
...	...	...	9	18	0.6936
...	...	...	10	411	0.9926
...	...	...	11	132	0.7880
...	...	...	12	258	0.8838

Matriz Combinada			
	1	2	
Area			
Exc.			
hist R			
hist G			
hist B			
hist H			
hist S			

Ilustración 48 tablas de características de la parte izquierda de la interfaz

- **Interfaz gráfica para los defectos** de deshidratación y fruto helado.

Antes de describir este interfaz es necesario aclarar que en caso de este tipo de defectos se van a identificar tres niveles de gravedad del defecto, es decir, en el caso del fruto deshidratado se acotaran tres niveles de deshidratación, nivel bajo (fruto turgente), nivel medio (fruto con principios de deshidratación); y nivel alto (fruto deshidratado). En la Ilustración 49 se pueden apreciar tres imágenes que pueden representar estos niveles de deshidratación.



Ilustración 49 Los tres niveles de deshidratación estipulados

Esta interfaz es muy parecida a la anterior, pero como en este caso tenemos que seleccionar entre tres grupos diferentes de características, cambia gráfica y funcionalmente (véase Ilustración 50).




Ilustración 50 Vista general del interfaz para los defectos de deshidratación y fruto helado

Como en la anterior se pueden diferenciar dos partes, el lado derecho se encuentra el 'axes' que nos muestra la imagen a procesar, las botoneras de abrir carpeta, siguiente y anterior imagen que tienen las mismas funciones que en la anterior interfaz, el botón de procesar que en este caso ejecuta el procesamiento para extraer las 20 características de textura; la primera diferencia estaría en el grupo de 'radio button' que tienen la función de elegir, de entre los tres tipos, en que matriz guardar los datos de procesado y por último los botones de combinar matriz y exportar datos a Excel, que crean las dos matrices necesarias para entrenar una red neuronal.

Por ultimo en la zona de la izquierda se encuentran las tablas donde se va mostrando toda la información que se ha producido y clasificado durante el proceso de extracción de datos.

- **Entrenamiento red neuronal**

Los datos necesarios para entrenar las diferentes redes de neuronas son las matrices obtenidas gracias a la ayuda de las interfaces explicadas anteriormente (datos de entrada) y un vector de muestras que indica la clase a la que pertenece cada muestra (target de salida) que también proporciona la misma interfaz.

Este proceso se realiza con la herramienta de Matlab 'nprtool', es una aplicación sencilla que permite configurar diferentes propiedades de la red de neuronas, comienza introduciendo los vectores de características y de target, después se da la opción de configuración de la estructura interna de la red, es decir cuántas capas ocultas va a tener la red neuronal, para calcular este parámetro en todos los casos de este proyecto se ha usado la siguiente formula que depende del número de características de entrada y clases en la salida:

$$\text{capas internas} = (N^{\circ} \text{ características de entrada} + N^{\circ} \text{ de salidas})/2$$

Por ejemplo, en el caso de picadura de mosca tenemos 11 características y 2 clases a la salida, por lo tanto, el número de capas ocultas es 7 redondeando, ya que no se puede poner media capa(Ver Ilustración 51).




Ilustración 51:ejemplo de estructura de red neuronal

Tras esto te da la opción de elegir los porcentajes de características que se usan para el entrenamiento, la validación y el test, en el caso de este proyecto se configuró con un 70% de entrenamiento, un 15% de validación y un 15% de test,

final mente al entrenar la red neuronal, la aplicación te proporciona una función con el clasificador y un conjunto de datos estadísticos que se expondrán en el apartado de resutados.

- **Implementación de la red neuronal**

Una vez entrenada la red de neuronas, se procede a la implementación de esta en el algoritmo principal, continuación se puede apreciar en la Ilustración 52 un flujograma que indica de qué forma se implementa la red neuronal.




Ilustración 52 Flujograma del algoritmo con la red de neuronas implementada

Fase de validación

El objetivo de esta fase es comprobar el correcto funcionamiento de todos los algoritmos desarrollados en la fase anterior, la misma herramienta para entrenar las redes neuronales lleva implícita esta fase, es decir, proporciona estadística de la validación que realiza a cierta cantidad de datos que se introducen en la matriz de entrada, sin embargo, en este proyecto para obtener más resultados y hacer comparativas con los que proporciona dicha herramienta se realiza este fase aplicando el algoritmo a imágenes de frutos individuales e imágenes con conjuntos de frutos. Este proceso genera tablas de resultados como la que se puede apreciar en Ilustración 53:

Nº de muestra	escudete	detecta escudete	Nº aceitunas	falso positivo
1	13	12	24	2
2	11	11	24	1
3	7	6	21	2
4	15	13	23	2
5	13	11	24	3
6	8	6	24	0
7	9	8	24	1
8	11	10	12	1
9	12	11	12	0
10	6	5	12	2
suma	105	93	200	14

Ilustración 53 Ejemplo de tabla con resultados de validación del algoritmos de escudete en imágenes de conjunto de frutos

2.5. Algoritmos para el espectro infrarrojo

Con el objetivo de comparar dos tecnologías de visión, en paralelo al desarrollo de los algoritmos para el espectro visible, se trabajó en algoritmos para el espectro infrarrojo. Cabe destacar que esta tecnología no se ha usado en todos los defectos por razones que se explicarán en el apartado de resultados; se aplican a defectos de picadura y escudete.

Fase de desarrollo**2.5.1.1. Preprocesado**

El sensor que proporciona este tipo de imágenes tiene un rango espectral de 600 a 975 nm, que se divide entre 25 bandas, la imagen se compone de matrices de 5 x 5 pixel que se van repitiendo hasta reproducir 25 veces la misma imagen, en la Ilustración 54 se aprecia dichas matrices.




Ilustración 54 Zoom a imagen multispectral

Por esta razón el primer paso para el preprocesamiento es separar esta imagen por capas, esta operación es posible realizarla mediante librerías, sin embargo, en este caso se han utilizado bucles 'for' para barrer la imagen de 5 en 5 píxeles.

Para la elección de la banda que mejores resultados se podría obtener, se escogieron dos bandas para hacer pruebas que concluyeran la elección, se tuvo en cuenta el rango de la red edge (rojo lejano) entre 675 y 700 nm, que se usa en teledetección para obtener índices de vegetación, y ya que se trata del fruto de tendría sentido usar este espectro, la segunda banda se eligió el rango near to infrared (cercano al infrarrojo) entre 900 y 925 nm; ambas bandas se pueden apreciar en la Ilustración 55.




Ilustración 55 Bandas del red Edge y NIR

A simple vista se puede apreciar que la banda cercana al infrarrojo es más clara que la imagen del Red Edge, esto puede significar que se tendrá más precisión a la hora de señalar el defecto como región de interés, ya que también se puede apreciar que la zona del defecto tendrá un valor cercano a 0 con respecto al resto de la superficie del fruto, lo que proporciona un margen amplio para la elección del umbral de segmentación, aun así, para fundamentar mejor la decisión entre una banda u otra se realizó una prueba de segmentación con ambas bandas, tras los resultados que se representaran en el apartado de resultados, la decisión se decantó por la banda cercana al infrarrojo.

En este caso el preprocesamiento terminaría en este punto, ya que el sensor aporta una imagen en escala de grises y no es necesario separar la imagen por canales de color.

2.5.1.2. Procesamiento

2.5.1.2.1. Segmentación

Al igual que en la tecnología del espectro visible, la elección del umbral para binarizar la imagen se basa en el estudio del histograma y la diferencia de los niveles de gris que se encuentra entre la zona del defecto y la superficie del fruto.




Ilustración 56 datos para umbralización de escudete. [Imagen de abajo](#): histograma de banda NIR. [Imagen de arriba](#): ponderación de un pixel en el defecto con otro en fruto.




Ilustración 57 datos para umbralización de picadura. [Imagen de abajo](#): histograma de banda NIR. [Imagen de arriba](#): ponderación de un pixel en el defecto con otro en fruto.

En la Ilustración 56 se puede apreciar que el margen de valores entre defecto y superficie del fruto es considerable, por lo que un umbral de 0.4 sería suficiente para discriminar el defecto, aunque en ocasiones aparezca ruido de las sombras del fruto, que se descartaran gracias al entrenamiento de la red neuronal.

Sin embargo en la Ilustración 57 se puede ver que el margen no es tan considerable lo que se traduce en que la elección de un umbral es complicada y en muchas ocasiones no se detectara el defecto como se puede observar en el apartado de resultados, por esta razón también se excluye este defecto para esta parte del proyecto. Por lo tanto, de ahora en adelante todo lo realizado con esta tecnología es exclusivamente para el defecto de escudete.

Las etapas de binarización y aplicación de estructuras morfológicas es la misma que en las imágenes de espectro visible, binarizando con el umbral

seleccionado anteriormente y aplicando estructuras de forma de disco, erosionando y dilatando en ese orden respectivamente.

2.5.1.2.2. Extracción de características

En esta fase cambia el tipo de características que se extraen de las regiones de interés, teniendo en cuenta que estas imágenes no tienen más que un canal en niveles de gris, solo se puede extraer una intensidad media, por lo que además de esta característica se extraen los 6 datos de textura que aporta la función 'Statxure'.

2.5.1.3. Clasificación

A pesar de que parezca a simple vista que hay mucho más contraste entre defecto y el resto de fruto a comparación de la tecnología de espectro visible, en este caso también hay existe muchos casos en los que los falsos positivos estaban presentes, por lo que es necesario hacer una clasificación entre defecto y no defecto, y como en casos anteriores, se utilizan redes neuronales para esta tarea.

Como en casos anteriores obtener los datos de entrenamiento de la red se vuelve a utilizar con la ayuda de una interfaz gráfica. Esta es similar a las descritas anteriormente, pero con pequeñas diferencias para adaptarla a las necesidades de este tipo de imágenes, en la Ilustración 58 se puede ver una vista general de la interfaz.

The interface displays the following components:

- Image Preview:**
 - Imagen de Banda N°20:** A grayscale image of an olive with a defect highlighted by a red box.
 - Imagen de RGB:** A color image of the same olive.
 - Imagen de Binarizada:** A binary image showing the defect as a white shape on a black background.
- Control Buttons:**
 - Abrir Carpeta, Procesar Imagen, Siguiente Imagen, Anterior Imagen.
 - Eliminar Característica, Guardar Característica, Combinar Matriz, Importar Datos.
- Feature Extraction Tables:**
 - Características de la Imagen:**

	1	2	3
1	49.2879	76	55.7500
2	24.9877	0	32.2054
3	0.0095	0	0.0157
4	-0.3233	0	-0.5912
 - Características de Defecto:**

	1	2	3	4	5
1	32.1786	39.1667	24.6190	40.7500	35.1
2	34.6565	35.2030	34.8226	29.7115	30.5
3	0.0181	0.0187	0.0183	0.0134	0.0
 - Características de No Defecto:**

	1	2	3	4	5
1	34.2500	75	74.6000	29.3333	37.2
2	34.6582	0	0.8000	35.9493	37.2
3	0.0181	0	9.8423e-06	0.0195	0.0
 - Matriz Combinada:**

	1	2	3	4	5
1	32.1786	39.1667	24.6190	40.7500	35.1
2	34.6565	35.2030	34.8226	29.7115	30.5
3	0.0181	0.0187	0.0183	0.0134	0.0
- Classification Controls:**
 - Selecc. Tipo Defecto:** Radio buttons for Defecto (selected) and No Defecto.
 - N° característica:** A dropdown menu showing the value 5.

Ilustración 58 vista general de la interfaz para imágenes multispectrales

El funcionamiento de esta interfaz es el mismo que las anteriores, mismos botones, mismas tablas y mismo formato de importación de datos, lo que hace diferente a esta herramienta es el tercer axes que nos representa la imagen en el espectro visible, esto es debido a que en ocasiones el defecto en la imagen multiespectral no se aprecia a simple vista o se puede confundir con alguna sombra, y ya que es una extracción de características objetiva es necesario estar seguro de que regiones son defecto y cuáles no, por lo tanto ayudándose de la imagen RGB se puede definir con más seguridad el tipo de característica.

En el proceso de entrenamiento de la red de neuronas cambiaria también la estructura interna de esta, aplicando la misma fórmula anterior tendríamos en este caso 5 capas ocultas en la red.(véase Ilustración 59)




Ilustración 59 Estructura de la red de neuronas para las imágenes multiespectrales

Por último, la implementación de la red neuronal en el algoritmo tendría el mismo flujograma de la Ilustración 52. Flujograma del algoritmo con la red de neuronas implementada, el proceso de validación también se realiza con imágenes de muestras individuales y en conjunto, para poder hacer una buena comparativa de los resultados entre espectro visible e infrarrojo y de igual forma proporciona tablas de resultados como las que se ha mostrado anteriormente en la Ilustración 53.

3. Resultados

En este apartado se expondrán los resultados obtenidos en el desarrollo de los diferentes algoritmos, así como una imagen ejemplo de la aplicación de cada algoritmo. La estructura de esta exposición se divide en las dos tecnologías de visión usadas en el proyecto, primero se presentarán los resultados del espectro visible y seguidas las del espectro infrarrojo. Cabe destacar que los porcentajes de detección de defecto (acierto) se hacen respecto al número de defectos que contiene la muestra en cuestión, y el porcentaje de detección de no defecto (falsos positivos) se hace respecto al número de frutos que tiene la muestra a la que se le está aplicando el algoritmo.

A de entenderse que, según la ISO19157 de elementos de la calidad, en la categoría de compleción la cual describe los errores de omisión y comisión en los elementos, atributos y relaciones, es decir, la presencia en la base de datos de elementos que no deberían de estar presentes o la ausencia de otros que si deberían estarlo. Dentro de cada una de la categoría la ISO19157 establece unos elementos que permiten concretar el aspecto de la calidad a la que se refiere las componentes. [13]

- Comisión: Datos excedentes en el conjunto de datos (Excedentes en detección de defecto).
- Omisión: Datos ausente en el conjunto de datos (ausencia de detección de defecto).


3.1. Resultados en el espectro visible

Dentro de este sub apartado se organizarán los resultados por tipos de defectos.

3.1.1. Resultados en picadura de mosca


Los siguientes resultados se han obtenido al aplicar las diferentes variantes del algoritmo a un conjunto de imágenes con aceitunas individuales, se trata de 198 aceitunas de las cuales 81 tienen picadura de mosca. En las dos primeras ilustraciones (Ilustración 60 e Ilustración 61) se pueden ver dos pruebas de la aplicación del algoritmo en picadura de mosca, la primera con umbral 0.6 y la siguiente con umbral 0.7; puede apreciarse que en el primer caso el porcentaje de acierto es alto (84%) pero también es lato el de falso positivo (30%); y si aplicamos

el segundo caso el porcentaje de faltos positivos (7%) disminuye a costa de perder porcentaje detección de defecto (79%).



198	81	68	59
Nº de muestra	Picadura	Detecta picadura	Falso positivo

Ilustración 60 Resultados del algoritmo en picadura de mosca con umbral 0.6




198	81	64	13
Nº de muestra	Picadura	Detecta picadura	Falso positivo


Ilustración 61 Resultados del algoritmo en picadura de mosca con umbral 0.7

Para evitar esta relación directamente proporcional entre detectar defecto y falso positivo se hizo uso de red neuronal, que al aplicarla al mismo lote de frutos se puede ver como el porcentaje de acierto subió y el porcentaje de falsos positivos disminuyó considerablemente (véase Ilustración 62).

Porcentaje de detección de defecto



Porcentaje de detección de no defecto




198	81	67	9
Nº de muestra	Picadura	Detecta picadura	Falso positivo


Ilustración 62 Resultados del algoritmo en picadura de mosca con red de neuronas

También se aplicó el algoritmo a imágenes con aceitunas en conjunto que entre todas las imágenes sumaron un total de 277 frutos y 112 picaduras y como se puede apreciar en la Ilustración 63 los resultados fueron muy parecidas, de 83% a un 89% de aciertos y de 5% a un 2% de comisión (véase Ilustración 62 e Ilustración 63).

Porcentaje de detección de defecto



Porcentaje de detección de no defecto



Suma aceitunas	sum pic	sum pic detec	sum falsos pos
277	112	100	6

Ilustración 63 Resultados del algoritmo en picadura de mosca en lotes de aceituna en conjunto



Ilustración 64 Matriz de confusiones de la red de neuronas entrenada con picaduras de mosca

En la Ilustración 64 se muestra la matriz de confusión que proporciona la herramienta de Matlab al entrenar la red neuronal, se puede apreciar que se entrenó con 71 muestras de defecto de picadura y con 151 muestras de no defecto. Los resultados del test(97%) son muy parecidos a los obtenidos en la Ilustración 63 (89%) e Ilustración 62 (83%).

Por último, se muestra el resultado de aplicar el algoritmo a una muestra de frutas en conjunto con picaduras de mosca (Ilustración 65).





Ilustración 65 Resultado de la aplicación del algoritmo a un conjunto de aceitunas con picadura de mosca

3.1.2. Resultados en escudete


Para el defecto de escudete el lote de imágenes al que se le aplica el desarrollo del algoritmo estaba compuesto de 69 aceitunas entre las que había 39 defectos de escudete.



69	39	22	20
Nº de muestra	escudete	detecta escudete	falso positivo


Ilustración 66 Resultados del algoritmo en escudete con umbral 0.6

En este caso a pesar de cambiar de umbral el porcentaje de aciertos no varió demasiado, aunque los falsos positivos variaron considerablemente de un 29% a un 6%; a pesar de todo el porcentaje de aciertos no es adecuado en ningún caso. (véase Ilustración 66 e Ilustración 67).



69	39	21	4
Nº de muestra	escudete	detecta escudete	falso positivo

Ilustración 67 Resultados del algoritmo en escudete con umbral 0.7




69	39	32	2
Nº de muestra	escudete	detecta escudete	falso positivo


Ilustración 68 Resultados del algoritmos con red neuronal en escudete

Al aplicar la red neuronal se puede apreciar en la Ilustración 68 que los resultados mejoraron considerablemente con un 82% de acierto y un 3% de comisión. En la Ilustración 69 se puede apreciar resultados similares en lotes de imágenes con un total de 200 frutos que contienen 105 escudetes entre todos.

Porcentaje de detección de defecto



Porcentaje de detección de no defecto



105	93	200	14
suma escudete	suma esc. Detec	suma aceitunas	suma falsos

Ilustración 69 Resultados del algoritmo con red neuronal en muestras de conjunto de aceitunas con escudete



Ilustración 70 Matriz de confusión de la red de neuronas para escudete

Tras entrenar la red de neuronas con este defecto se obtuvo la matriz de confusión que se muestra en la Ilustración 70, se observa que se entrenó con 32 muestras de defecto y 64 muestras de no defecto, dando resultados parecidos a los

de la Ilustración 69 e Ilustración 68. Final mente en la Ilustración 71 se puede ver el resultado de la aplicación del algoritmo en una imagen con un conjunto de frutos que presentan el defecto del escudete.





Ilustración 71 Resultado de la aplicación del algoritmo a un conjunto de aceitunas con escudete


3.1.3. Resultados en manchas fitosanitarias

En la Ilustración 72 se puede apreciar el resultado de aplicar el algoritmo en canal b del grupo de colores RGB a un lote de muestras individuales de 62 frutos con 84 manchas fitosanitarias en total, en este caso se obtiene un resultado bajo de acierto (68%), sin embargo el porcentaje de falsos positivos (2%) es muy interesante. Para solucionar el problema del bajo porcentaje de aciertos se cambió el algoritmo se usó el canal a^* del grupo de color CIE $l^*a^*b^*$, como se puede ver en la Ilustración 73 el porcentaje se mejoró considerablemente, de un 68% a un 88%.




62	84	57	1
Nº de muestra	hay mancha	detecta mancha	falso positivo

Ilustración 72 Resultado del algoritmo en la capa 'b' del RGB y umbral 0.4 para manchas fitosanitarias en imágenes de frutos individuales



62	84	74	1
Nº de muestra	hay mancha	detecta mancha	falso positivo

Ilustración 73 Resultado del algoritmo en la capa 'a' del CIE $L^*a^*b^*$ y umbral 0.4 para manchas fitosanitarias en imágenes de frutos individuales



438	147	119	0
Nº aceitunas	hay mancha	detecta mancha	falso positivo

Ilustración 74 Resultado del algoritmo en la capa ‘a’ del CIE l*a*b* y umbral 0.4 para manchas fitosanitarias en imágenes de conjunto de frutos

Tras aplicar la última versión del algoritmo a las imágenes de conjuntos de frutos con manchas fitosanitarias, lo que sumaba un total de 438 aceitunas con 147 manchas en total, se puede ver que tiene resultado similares a los resultados de las muestras individuales (Ilustración 74); también es necesario destacar que al no tener falsos positivos no ha sido necesario ni posible entrenar una red de neuronas capaz de clasificar entre defecto y no defecto. Por último, se puede ver en la Ilustración 75 un ejemplo del resultado de aplicar el algoritmo a una imagen con aceitunas manchadas de producto fitosanitario.




Ilustración 75 resultado de aplicar el algoritmo a una imagen con un conjunto de aceitunas que tienen manchas fitosanitarias

3.1.4. Resultados en frutos deshidratados



Ilustración 76 Matriz de confusión obtenida en el entrenamiento de la red neuronal para clasificar grados de deshidratación

En la matriz de confusión de la Ilustración 76 se puede observar que la red se entrenó con 57 muestras de nivel bajo de deshidratación, 50 de nivel medio y 48 de nivel alto, se puede apreciar que la confusión entre grupos contiguos es bastante común, pero la confusión entre grupos extremos (entre nivel bajo y alto), no es muy común, solo se ve una vez en la matriz de entrenamiento, esto es una buena noticia, pero que sea tan común la confusión entre clases contiguas no es adecuado para una aplicación correcta.

3.1.5. Resultados en frutos helados




Ilustración 77 Matriz de confusión obtenida en el entrenamiento de la red neuronal para clasificar como de helado está el fruto

Se puede ver en la Ilustración 77 que a diferencia del caso anterior no existen confusiones entre niveles altos y bajos, sin embargo sigue siendo común la confusión entre campos contiguos, aunque se puede decir que en este caso también es menos frecuente que en el anterior. Por último, es necesario indicar que el entrenamiento se realizó con 62 muestras de nivel bajo, 58 de nivel medio y 59 de nivel alto.

3.2. Resultados en el espectro cercano al infrarrojo


3.2.1. Comparación banda red edge con NIR

Como se mencionó en apartados anteriores, primero se hizo una comparativa entre la banda del Red edge y la banda del infrarrojo, para decidir con cual trabajar mejor, en las ilustraciones de a continuación se podrá ver la razón de escoger la banda del infrarrojo y la razón por la que descartar el desarrollo completo del algoritmo para el defecto de picadura.



59	59	19	59
Nº de muestra	picadura	detecta picadura	falso positivo

Ilustración 78 Banda Red Edge picadura de mosca



44	40	31	36
Nº de muestra	escudete	detecta escudete	falso positivo

Ilustración 79 banda NIR picadura de mosca

Como se puede apreciar en la Ilustración 78 y en la Ilustración 79 el defecto de picadura de mosca no es fácil de detectar con la tecnología del espectro infrarrojo, y teniendo en cuenta los porcentajes obtenidos en el espectro visible (Ilustración 64 e Ilustración 63) no merece la pena seguir con el desarrollo de este algoritmo.

En el caso del defecto de escudete es totalmente diferente, los resultados obtenidos en ambas bandas eran adecuados para seguir con el desarrollo del algoritmo para este defecto. Esta comparativa sirvió para tomar dos decisiones, la primera es que la banda con la que se seguiría trabajando sería la banda cerca al infrarrojo, ya que tiene mejores resultados de detección de defectos, sin embargo, el porcentaje de falsos positivos es tan elevado que la segunda decisión fue aplicar directamente la extracción de características para entrenar una red de neuronas que descartara todas las zonas de no defecto. (véase Ilustración 81 Banda Red Edge escudete e Ilustración 80 Banda NIR escudete).




Ilustración 81 Banda Red Edge escudete




Ilustración 80 Banda NIR escudete

3.2.2. Resultados escudete




Ilustración 82 matriz de confusión de red de neuronas para escudete en espectro infrarrojo

Tras entrenar la red de neuronas para clasificar el defecto de escudete se obtuvo la siguiente matriz de confusión (Ilustración 82), en esta se puede ver que se

usaron 63 patrones de defecto y 126 patrones de no defecto. Es destacable el porcentaje de acierto que nos indica esta matriz ya que está por encima del 90%.

Tras implementar la red en el algoritmo, se procedió a obtener resultados aplicándolo en lotes de 94 muestras de frutos individuales con 61 escudete y en lotes de conjunto de aceitunas con un total de 227 frutos y 88 escudetes. En ambos casos el porcentaje de aciertos es superior al 90% y los falsos positivos no superan el 4%. (véase Ilustración 83 e Ilustración 84).




Ilustración 83 Resultados de escudete en espectro infrarrojo muestras individuales




Ilustración 84 Resultados de escudete en espectro infrarrojo muestras de conjunto de frutos

Para terminar en la Ilustración 85 se puede ver un ejemplo de la aplicación del algoritmo a una imagen con frutos en conjunto.




Ilustración 85 Resultado de la aplicación del algoritmo en espectro infrarrojo en una imagen del conjunto de frutos

3.3. Comparación resultados entre espectro visible e infrarrojo

Finalmente, el único defecto que merece la pena comparar entre la tecnología del espectro visible y el infrarrojo es el escudete, en el caso de las matrices de confusión en cada espectro se puede ver que son resultados muy parecidos, del orden del 92%(véase Ilustración 70 (espectro visible) e Ilustración 82(espectro infrarrojo)). Para los resultados obtenidos de aplicar ambas tecnologías se puede destacar que las imágenes multispectrales tienen un porcentaje de acierto superior a las imágenes del rango visible, en las primeras el porcentaje ronda el 95% y en el visible ronda el 85%, alrededor de un 10 % de diferencia, por ultimo cabe destacar que los porcentajes de falsos positivos son similares entre sí, no superan el 5%.

4. Conclusiones y trabajos futuros

4.1. Conclusiones

A continuación, se exponen las conclusiones que se han obtenido a lo largo del desarrollo del proyecto.

- Para la adecuada adquisición de las imágenes es aconsejable evitar la fase de conservación del fruto ya que se aleja de la forma real en que se realiza el proceso de recolección del fruto y este pierde propiedades sobre todo visuales que son las importantes en este estudio. Sin embargo, en caso de necesitar el proceso de conservación, lo más adecuado es la congelación

inmediatamente después de la recolección del fruto para evitar la pérdida de propiedades visuales.

- Para el sistema de iluminación del set up sería interesante dotarlo de un difusor de luz, que facilitaría mucho el procesado de las imágenes, ya que la proyección de una luz más difuminada y equilibrada evitaría sombras y brillos tan molestos a la hora del procesado de imágenes.
- La diferencia entre aplicar el algoritmo a muestras individuales y muestras en conjunto no es significativa, quizás para la aplicación de un sistema mecánico que discrimine los frutos defectuosos sea esencial procesar los frutos individualmente, pero para el objetivo inmediato de este proyecto no es relevante.
- Respecto a la comparación entre tecnologías de visión se puede decir que la tecnología infrarroja es concluyente en defectos como el escudete, en el que existe gran contraste entre defecto y superficie del fruto y en ocasiones supera a la tecnología del espectro visible ya que en los frutos con tonalidades oscuras (maduros) la detección de defecto en el espectro visible se dificulta mientras que en el infrarrojo se identifica más fácilmente por el mencionado contraste.
- En todo caso la tecnología del espectro infrarrojo sería un buen complemento para la tecnología de espectro visible.
- Teniendo en cuenta que el sensor cercano a infrarrojo proporciona una imagen que contiene 25 bandas, al descomponer esta por capas se pierde mucha resolución por lo que es interesante disminuir la distancia entre sensor y fruto.
- Los algoritmos expuestos en este documento han dado en general buenos resultados, pero no deja de ser una primera toma de contacto con la aplicación de procesamiento de imágenes para la detección de defectos en aceitunas, lo que significa que este proyecto puede servir para la orientación e influencia en estudios futuros con técnicas y herramientas más robustas y eficaces.

Para terminar con el apartado de conclusiones cabe destacar que parte del desarrollo de este trabajo ha influido en la publicación del artículo de título 'Olive fly sting detection based on coputer vision' [9] ya que las imágenes que se han usado

en este artículo son las adquiridas en la fase de adquisición de imágenes de este trabajo de fin de grado, y de igual forma este trabajo se ha basado en las técnicas de procesamiento y extracción de características expuestas en este artículo. Se podría decir que existe una realimentación entre ambos estudios.

4.2. Trabajos futuros

Como es lógico para un futuro estudio más robusto es necesario la adquisición de un número mayor de imágenes. Pero siendo un set up en el que la captura de imagen se realiza manualmente es un proceso muy tedioso por lo que es interesante la propuesta de desarrollar un sistema que haga este proceso automático y más rápido de realizar y en consecuencia obtener más imágenes e información.

Respecto a los defectos de deshidratación y heladas, como futuro estudio con el objetivo de mejorar los resultados de este proyecto y hacerlos más robustos y fiables, cabe mencionar que se podría realizar un estudio físico-químico que verifique el estado real de deshidratación y congelación para correlacionar los datos de laboratorio con los obtenidos por el algoritmo, de forma que se mejore el criterio subjetivo que se ha usado en este proyecto.

Referencias

- [1] L. Civantos López-Villalta, «Obtención de aceite de oliva virgen,» de *Obtención de aceite de oliva virgen*, S.A. Agrícola Española, 2008, p. 264.
- [2] R. Cardenas, J. Vilar y J. Marcos, *El Manual del Maestro de Almazara*, GEA Westfalia Separator Ibérica, SA.
- [3] G. Gómez, M. González, R. A. Pérez, M. Á. Pérez, A. Lázaro y C. Lozendo, «Alteraciones y pérdidas de calidad en aceituna de mesa y aceite de oliva,» *Enciclopedia del Olivo del TDC-OLIVE*, 2004.
- [4] M. J. Hita, «<http://www.juntadeandalucia.es>,» [En línea]. Available: http://www.juntadeandalucia.es/medioambiente/consolidado/publicacionesdigitales/80-398_AGRICULTURA_SIN_VENENOS/80-398/2_EL_USO_DE_PRODUCTOS_FITOSANITARIOS_Y_SUS_EFECTOS.PDF.
- [5] D. Ortega Calderón, G. Beltrán, M. P. Aguilera y M. Uceda, «Influencia del régimen hídrico en la formación de aceite en Arbequina,» *dossierr OLIVAR*, pp. 60-64, 2004.
- [6] G. Beltrán, C. Berja, M. P. Aguilera y M. Uceda, «Influencia de la heladas en las características físico-químicas del aceite de oliva,» *foro de la tecnología oleícola y la calidad*, 2000.
- [7] j. d. andalucia, «Junta de andalucia,» [En línea]. Available: juntadeandalucia.es/agriculturaypesca/observatorio/servlet/FrontController?ec=default.
- [8] J. Beltárn ORtega, D. M. Martínez Gila, D. Aguilera Puerto, J. Gámez García y J. Gómez Ortega, «Novel technologies for monitoring the in-line quality of virgin olive oil during manufacturing and storage,» *Society of Chemical Industry*, pp. 4644-4662, 2016.
- [9] A. Beyaz, D. M. Martínez Gila, J. Gómez Ortega y J. Gámez García, «Olive fly sting detection based on coputer vision,» *elsevier*, pp. 129-136, 2019.
- [10] D. Rong, Y. Ying y X. Rao, «Embedded vision detection of defective orange by fast adaptive lightness correction algorithm,» *elsevier*, pp. 48-59, 2017.
- [11] R. Gonzalez y R. Woods, «Digital Image Processing,» *Wesley Publishing Company*, pp. 443-444, 1993.
- [12] R. M. Haralick, k. Shanmugam y I. Dinstein, «Textural Features for Image Classification,» *IEEE Transactions on Systmes, Man and Cybernetics*, Vols. %1 de %2SMC-3, nº 6, pp. 610-621, 1973.

[13] sigpac, «sigpac,» [En línea]. Available: <http://sigpac.mapa.es/fega/visor/>.