



**Universidad de Jaén**

*Escuela Politécnica Superior de Jaén*

# DETECCIÓN DE DAÑOS EN ACEITUNAS DE MESA MEDIANTE TÉCNICAS NO INVASIVAS

**Autor: Manuel Garrido Martos**

**Grado: Ingeniería de Organización Industrial**

**Director: Silvia María Satorres Martínez  
Diego Manuel Martínez Gila**

**Departamento del director: Ingeniería Electrónica y Automática**

**Fecha: 24/06/2024**

Licencia CC



CREA



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

Doña Silvia Satorres Martínez y Don Diego Manuel Martínez Gila, tutores del Proyecto Fin de Carrera titulado: Detección de daños en aceitunas de mesa mediante técnicas no invasivas, que presenta Manuel Garrido Martos, autorizan su presentación para defensa y evaluación en la Escuela Politécnica Superior de Jaén.

Jaén, Junio de 2024

El alumno:

Los tutores:

Manuel Garrido Martos

Silvia Satorres Martínez

Diego Manuel Martínez Gila

## Resumen

En la industria agroalimentaria, la evaluación de la calidad y detección de daños en los productos es fundamental para asegurar su idoneidad para el consumo. Tradicionalmente, la inspección visual y el uso de cámaras RGB han sido las técnicas predominantes para este fin. Sin embargo, estas metodologías presentan limitaciones significativas, especialmente en productos donde los daños no son fácilmente perceptibles a simple vista o mediante el espectro visible, como es el caso de las aceitunas de mesa. Este trabajo de fin de grado se centra en la implementación de la visión hiperespectral como herramienta avanzada para la detección de daños en aceitunas de mesa, destacando su superioridad sobre las cámaras tradicionales y estudiando su viabilidad.

Esta tecnología es capaz de capturar información a lo largo de un amplio rango de longitudes de onda, incluyendo el espectro visible e invisible al ojo humano, permitiendo identificar características intrínsecas de los productos que no son detectables con cámaras convencionales. Esto es particularmente relevante en el caso de las aceitunas molestadas, donde los daños internos o sutiles alteraciones en la superficie pueden no modificar significativamente el color percibido en el espectro visible, pero sí alteran la respuesta espectral en longitudes de onda específicas.

Durante el desarrollo del proyecto, se diseñó y montó un setup experimental empleando una cámara hiperespectral para analizar muestras en forma de hipercubos, buscando patrones espectrales asociados a diferentes tipos de daños en lo que al molestado concierne. A través de un enfoque metodológico riguroso, se recopilaron y procesaron los datos espectrales, y mediante el uso de técnicas avanzadas de procesamiento de imágenes y análisis de datos con MATLAB, se logró identificar indicadores espectrales clave para la detección efectiva de los daños y desarrollar un modelo entrenado que permita parametrizar y evaluar los mismos.

**Palabras clave:** visión hiperespectral, inspección de calidad, aceitunas de mesa, tecnologías no invasivas, análisis de imagen.

## Abstract

In the agri-food industry, the assessment of quality and detection of damage in products is crucial to ensure their suitability for consumption. Traditionally, visual inspection and the use of RGB cameras have been the predominant techniques for this purpose. However, these methodologies have significant limitations, especially for products where damage is not easily perceptible to the naked eye or through the visible spectrum, such as table olives. This final degree project focuses on the implementation of hyperspectral vision as an advanced tool for detecting damage in table olives, highlighting its superiority over traditional cameras and studying its viability.

This technology is capable of capturing information across a wide range of wavelengths, including the visible and invisible spectrum to the human eye, allowing the identification of intrinsic characteristics of the products that are not detectable with conventional cameras. This is particularly relevant in the case of bruised olives, where internal damages or subtle surface alterations may not significantly modify the perceived color in the visible spectrum, but do alter the spectral response at specific wavelengths.

During the development of the project, an experimental setup was designed and assembled using a hyperspectral camera to analyze samples in the form of hypercubes. This setup aimed to search for spectral patterns associated with different types of damage, specifically bruising. Through a rigorous methodological approach, spectral data were collected and processed. By employing advanced image processing and data analysis techniques in MATLAB, key spectral indicators for effective damage detection were identified. Consequently, a trained model was developed to enable the parameterization and evaluation of damages.

**Keywords:** hyperspectral vision, quality inspection, table olives, non-invasive technologies, image analysis.

## **Agradecimientos**

Quisiera agradecer personalmente a Silvia y Diego por darme la oportunidad de trabajar codo con codo con ellos, abrirme las puertas del laboratorio y confiar en alguien de una rama totalmente diferente a la que concerniría este proyecto.

Gracias también a Alejandro Sánchez García, Sergio Illana Rico y Javier Auñón del Barco por toda la ayuda que me han brindado.

Esto es tan mío como vuestro.

## Índice

|  |    |
|--|----|
| 1. Introducción .....  | 13 |
| 1.1. Contexto .....  | 13 |
| 1.2. Antecedentes y estado del arte .....                              | 14 |
| 1.3. Objetivos .....   | 16 |
| 1.4. Estructura del documento .....                                    | 16 |
| 2. Diseño y desarrollo del setup experimental .....                    | 19 |
| 2.1. Descripción del setup experimental .....                          | 19 |
| 2.2. Selección de materiales y componentes .....                       | 20 |
| 2.3. Diseño y fabricación de prototipos 3D .....                       | 26 |
| 2.4. Piezas .....  | 27 |
| 2.4.1. Soporte para aceituna .....                                     | 28 |
| 2.4.2. Soporte para motor .....  | 29 |
| 2.4.3. Soporte del eje vertical para módulo lineal .....               | 30 |
| 2.4.4. Soporte del eje horizontal para módulo lineal .....             | 32 |
| 2.4.5. Soporte para cámara .....                                       | 34 |
| 2.4.6. Estructura para motor/carro .....                               | 35 |
| 2.4.7. Soporte para placa y microcontrolador .....                     | 39 |
| 2.4.8. Bandeja para aceitunas .....                                    | 41 |
| 2.4.9. Caja y tapa para Arduino Uno .....                              | 42 |
| 2.5. Montaje de la estructura .....                                    | 42 |
| 2.5.1. Montaje preliminar .....  | 43 |
| 2.5.2. Montaje final .....   | 45 |
| 2.6. Configuración y programación del Arduino y microcontrolador ..... | 53 |
| 2.6.1. Interacción entre componentes .....                             | 53 |
| 2.6.2. Conexiones del hardware .....                                   | 55 |
| 2.6.3. Programación y control .....                                    | 56 |
| 2.7. Implementación de la cinta transportadora .....                   | 57 |
| 3. Diseño y desarrollo software .....                                  | 59 |
| 3.1. Software de captura .....   | 60 |
| 3.1.1. Enfoque .....   | 60 |
| 3.1.2. Calibración .....   | 62 |
| 3.1.3. Captura experimental .....                                      | 63 |
| 3.1.4. Interfaz .....  | 64 |
| 3.2. Técnicas de adquisición de imágenes .....                         | 67 |

|        |  |     |
|--------|--|-----|
| 3.2.1. | Rotación de la aceituna .....                                      | 67  |
| 3.2.2. | Traslación de la aceituna.....                                     | 69  |
| 3.3.   | Procesamiento y análisis de datos.....                             | 72  |
| 3.3.1. | Toolboxes utilizadas .....   | 72  |
| 3.3.2. | Muestras de aceituna empleadas en la experimentación.....          | 74  |
| 3.4.   | Entrenamiento de los modelos .....                                 | 79  |
| 3.4.1. | Entorno: Pequeña escala .....                                      | 79  |
| 3.4.2. | Entorno: Gran escala.....  | 86  |
| 4.     | Resultados .....   | 103 |
| 4.1.   | Análisis de los datos obtenidos.....                               | 103 |
| 4.2.   | Evaluación de técnicas no invasivas en la detección de daños ..... | 104 |
| 4.3.   | Discusión de resultados.....                                       | 105 |
| 5.     | Conclusiones.....  | 107 |
|        | Referencias.....   | 108 |
|        | Anexo .....  | 110 |
|        | Anexo I: Protocolo de impresión 3D .....                           | 110 |
|        | Anexo II: Modelos 3D de comprobación.....                          | 113 |
|        | Anexo III: Protocolo de control de cinta transportadora.....       | 115 |
|        | Anexo IV: Instalación de paquetes y librerías.....                 | 117 |
|        | Anexo V: Presupuesto total.....                                    | 119 |

## Índice de ilustraciones

|  |    |
|--|----|
| <b>Ilustración 1:</b> Diagrama de fases del proyecto. Elaboración propia.....                                    | 14 |
| <b>Ilustración 2:</b> Cámara hiperespectral Pika L. Elaboración propia. ....                                     | 21 |
| <b>Ilustración 3:</b> Ordenador. Elaboración propia.....   | 21 |
| <b>Ilustración 4:</b> Especificaciones del ordenador. Elaboración propia.....                                    | 22 |
| <b>Ilustración 5:</b> Cinta transportadora. Elaboración propia.....  | 22 |
| <b>Ilustración 6:</b> Impresora en funcionamiento. Elaboración propia. ....                                      | 23 |
| <b>Ilustración 7:</b> Ejemplo de piezas descartadas. Elaboración propia.....                                     | 24 |
| <b>Ilustración 8:</b> Focos halógenos apuntando al rango de visión de la lente. Elaboración propia. ....         | 24 |
| <b>Ilustración 9:</b> Motor paso a paso. Elaboración propia. ....  | 25 |
| <b>Ilustración 10:</b> Arduino y microcontrolador. Elaboración propia.....                                       | 25 |
| <b>Ilustración 11:</b> Combinación vertical de módulos lineales. Elaboración propia.....                         | 26 |
| <b>Ilustración 12:</b> Modelo y planos del soporte para la aceituna. Elaboración propia.....                     | 28 |
| <b>Ilustración 13:</b> Planos del soporte para aceituna con el clip cortado. Elaboración propia.....             | 28 |
| <b>Ilustración 14:</b> Modelo del soporte para motor. Elaboración propia.....                                    | 29 |
| <b>Ilustración 15:</b> Planos del soporte para motor. Elaboración propia.....                                    | 29 |
| <b>Ilustración 16:</b> Comprobación pieza primeriza/motor. Elaboración propia.....                               | 30 |
| <b>Ilustración 17:</b> Modelo del soporte del eje vertical para módulo lineal. Elaboración propia. ....          | 30 |
| <b>Ilustración 18:</b> Planos del soporte del eje vertical para módulo lineal. Elaboración propia. ....          | 31 |
| <b>Ilustración 19:</b> Combinación de los ejes pegados. Elaboración propia.....                                  | 31 |
| <b>Ilustración 20:</b> Comprobación placa con carro del módulo lineal vertical. Elaboración propia. ....         | 32 |
| <b>Ilustración 21:</b> Modelo del soporte del eje horizontal para módulo lineal. Elaboración propia. ....        | 32 |
| <b>Ilustración 22:</b> Planos del soporte del eje horizontal para módulo lineal. Elaboración propia. ....        | 33 |
| <b>Ilustración 23:</b> Comprobación placa con carro del módulo lineal horizontal. Elaboración propia. .          | 33 |
| <b>Ilustración 24:</b> Modelo del soporte para cámara. Elaboración propia. ....                                  | 34 |
| <b>Ilustración 25:</b> Planos del soporte para cámara. Elaboración propia.....                                   | 34 |
| <b>Ilustración 26:</b> Comprobación soporte cámara con módulo lineal horizontal. Elaboración propia.             | 35 |
| <b>Ilustración 27:</b> Modelo de la pieza para el carro. Elaboración propia. ....                                | 36 |
| <b>Ilustración 28:</b> Planos de la pieza para el carro. Elaboración propia. ....                                | 36 |
| <b>Ilustración 29:</b> Modelo de la pieza para el motor. Elaboración propia. ....                                | 37 |
| <b>Ilustración 30:</b> Planos de la pieza para el motor. Elaboración propia. ....                                | 37 |
| <b>Ilustración 31:</b> Modelo de la estructura final motor/carro. Elaboración propia. ....                       | 38 |
| <b>Ilustración 32:</b> Comprobación de la estructura horizontal completa del setup. Elaboración propia.<br>..... | 38 |
| <b>Ilustración 33:</b> Modelo del soporte para placa y microcontrolador. Elaboración propia. ....                | 39 |
| <b>Ilustración 34:</b> Planos del soporte para placa y microcontrolador. Elaboración propia. ....                | 39 |
| <b>Ilustración 35:</b> Comprobación soporte con Arduino. Elaboración propia. ....                                | 40 |

|   |    |
|---|----|
| <b>Ilustración 36:</b> Modelo y planos de la bandeja para aceitunas. Elaboración propia.....                                      | 41 |
| <b>Ilustración 37:</b> Modelo de la caja y tapa del Arduino. (Cults 3D, 2021) .....   | 42 |
| <b>Ilustración 38:</b> Montaje preliminar. Elaboración propia.....  | 43 |
| <b>Ilustración 39:</b> Manchas de grasa en la pieza. Elaboración propia.....  | 44 |
| <b>Ilustración 40:</b> Estructura base. Elaboración propia. ....  | 45 |
| <b>Ilustración 41:</b> Perfil de aluminio de ranurado en T. Elaboración propia.....   | 45 |
| <b>Ilustración 42:</b> Distancia máxima de la pieza al perfil. Elaboración propia.....  | 47 |
| <b>Ilustración 43:</b> Unión pieza-módulo. Elaboración propia. ....   | 47 |
| <b>Ilustración 44:</b> Escuadras de unión sosteniendo el perfil de aluminio. Elaboración propia. ....                             | 48 |
| <b>Ilustración 45:</b> Módulo vertical anclado al perfil mediante conectores. Elaboración propia.....                             | 48 |
| <b>Ilustración 46:</b> Conexión real entre las piezas de cada módulo. Elaboración propia. ....                                    | 49 |
| <b>Ilustración 47:</b> Vista cenital de la estructura de sujeción de la cámara. Elaboración propia. ....                          | 49 |
| <b>Ilustración 48:</b> Cámara anclada al módulo. Elaboración propia.....  | 50 |
| <b>Ilustración 49:</b> Estructura vertical del setup. Elaboración propia. ....  | 50 |
| <b>Ilustración 50:</b> Perfil de aluminio con soporte de Arduino y microcontrolador. Elaboración propia.<br>.....                 | 51 |
| <b>Ilustración 51:</b> Montaje final del Arduino y el microcontrolador en la estructura vertical.<br>Elaboración propia. ....     | 51 |
| <b>Ilustración 52:</b> Vista trasera de la estructura horizontal. Elaboración propia. ....  | 52 |
| <b>Ilustración 53:</b> Instalación de guía y carro en el perfil horizontal inicial. Elaboración propia. ....                      | 52 |
| <b>Ilustración 54:</b> Estructura horizontal del setup. Elaboración propia. ....  | 53 |
| <b>Ilustración 55:</b> Ajuste manual en las pestañas del microcontrolador. Elaboración propia.....                                | 54 |
| <b>Ilustración 56:</b> Conexiones del motor con el hardware. Elaboración propia. ....   | 55 |
| <b>Ilustración 57:</b> Interfaz de Somove. Elaboración propia. ....   | 58 |
| <b>Ilustración 58:</b> Panel de control de la cinta. Elaboración propia. ....   | 58 |
| <b>Ilustración 59:</b> Función Auto Update de Spectronon. Elaboración propia.....   | 61 |
| <b>Ilustración 60:</b> Enfoque de la cámara. Elaboración propia. ....   | 62 |
| <b>Ilustración 61:</b> Calibración para referencia oscura. Elaboración propia.....  | 63 |
| <b>Ilustración 62:</b> Calibración para referencia blanca. Elaboración propia. ....   | 63 |
| <b>Ilustración 63:</b> Configuración de la cámara. Elaboración propia.....  | 64 |
| <b>Ilustración 64:</b> Interfaz principal de Spectronon. Elaboración propia. ....   | 65 |
| <b>Ilustración 65:</b> Función Mean Spectrum. Elaboración propia. ....  | 65 |
| <b>Ilustración 66:</b> Gráfica espectral de la zona estudiada. Elaboración propia.....  | 66 |
| <b>Ilustración 67:</b> Captura experimental de aceitunas en lote por rotación, proyecto Espectrolive.<br>Elaboración propia. .... | 68 |
| <b>Ilustración 68:</b> Diagrama de fases para la captura mediante rotación. Elaboración propia.....                               | 68 |
| <b>Ilustración 69:</b> Captura de lotes de aceitunas con la bandeja. Elaboración propia.....                                      | 70 |
| <b>Ilustración 70:</b> Diagrama de fases para la captura mediante traslación. Elaboración propia. ....                            | 71 |

|  |    |
|--|----|
| <b>Ilustración 71:</b> Aceituna rotada, vista en Spectronon. Elaboración propia. ....  | 75 |
| <b>Ilustración 72:</b> Información innecesaria en imagen rotada. Elaboración propia. ....  | 76 |
| <b>Ilustración 73:</b> Selección de la región de interés con ginput. Elaboración propia. ....                                    | 78 |
| <b>Ilustración 74:</b> Entrenamiento OK vs KO. Elaboración propia. ....  | 79 |
| <b>Ilustración 75:</b> ROI seleccionada. Elaboración propia. ....  | 81 |
| <b>Ilustración 76:</b> Etiquetado manual OK vs KO. Elaboración propia. ....  | 81 |
| <b>Ilustración 77:</b> Pregunta al usuario si quiere continuar. Elaboración propia. ....   | 81 |
| <b>Ilustración 78:</b> Representación de parte de los datos consolidados. Elaboración propia. ....                               | 82 |
| <b>Ilustración 79:</b> Inputs del primer entrenamiento. Elaboración propia. ....   | 82 |
| <b>Ilustración 80:</b> Precisión del 98.3% con Fine Tree. Elaboración propia. ....   | 83 |
| <b>Ilustración 81:</b> Selección de la región de interés con drawrectangle. Elaboración propia. ....                             | 85 |
| <b>Ilustración 82:</b> Mapa de clasificación visualizada para rotación. Elaboración propia. ....                                 | 86 |
| <b>Ilustración 83:</b> Resultados predictivos del modelo. Elaboración propia. ....   | 86 |
| <b>Ilustración 84:</b> Captura de bandeja con aceitunas. Elaboración propia. ....  | 87 |
| <b>Ilustración 85:</b> Hipótesis para nuevos datos consolidados. Elaboración propia. ....  | 87 |
| <b>Ilustración 86:</b> Precisión del 98.8% con Fine Tree. Elaboración propia. ....   | 88 |
| <b>Ilustración 87:</b> Mapa de clasificación visualizada fallida. Elaboración propia. ....                                       | 88 |
| <b>Ilustración 88:</b> Selección de ROI en bandeja con drawrectangle. Elaboración propia. ....                                   | 89 |
| <b>Ilustración 89:</b> Etiquetado manual OK, KO y Tray. Elaboración propia. ....   | 90 |
| <b>Ilustración 90:</b> Matriz de datos consolidados de entrenamiento con imágenes de bandeja.<br>Elaboración propia. ....        | 90 |
| <b>Ilustración 91:</b> Precisión del 99.9% con Fine Tree. Elaboración propia. ....   | 90 |
| <b>Ilustración 92:</b> Mapa de clasificación visualizada para bandeja. Elaboración propia. ....                                  | 91 |
| <b>Ilustración 93:</b> Máscara posprocesada, primera iteración. Elaboración propia. ....   | 93 |
| <b>Ilustración 94:</b> Criterio de etiquetación para porcentaje de molestado. Elaboración propia. ....                           | 93 |
| <b>Ilustración 95:</b> Zonas de detección de molestado y clasificación del fruto, primera iteración.<br>Elaboración propia. .... | 94 |
| <b>Ilustración 96:</b> Porcentaje de molestado mostrado por pantalla, primera iteración. Elaboración<br>propia. ....             | 94 |
| <b>Ilustración 97:</b> Gráfico de control de calidad, primera iteración. Elaboración propia. ....                                | 95 |
| <b>Ilustración 98:</b> Máscara posprocesada, segunda iteración. Elaboración propia. ....   | 95 |
| <b>Ilustración 99:</b> Zonas de detección de molestado y clasificación del fruto, segunda iteración.<br>Elaboración propia. .... | 96 |
| <b>Ilustración 100:</b> Porcentaje de molestado mostrado por pantalla, segunda iteración. Elaboración<br>propia. ....            | 96 |
| <b>Ilustración 101:</b> Gráfico de control de calidad, segunda iteración. Elaboración propia. ....                               | 97 |
| <b>Ilustración 102:</b> Máscara posprocesada, tercera iteración. Elaboración propia. ....  | 97 |
| <b>Ilustración 103:</b> Zonas de detección de molestado y clasificación del fruto, tercera iteración.                            |    |

|   |     |
|---|-----|
| Elaboración propia. ....  | 98  |
| <b>Ilustración 104:</b> Porcentaje de molestado mostrado por pantalla, tercera iteración. Elaboración propia. ....            | 98  |
| <b>Ilustración 105:</b> Gráfico de control de calidad, tercera iteración. Elaboración propia.....                             | 99  |
| <b>Ilustración 106:</b> Máscara posprocesada, cuarta iteración. Elaboración propia. ....                                      | 99  |
| <b>Ilustración 107:</b> Zonas de detección de molestado y clasificación del fruto, cuarta iteración. Elaboración propia. .... | 100 |
| <b>Ilustración 108:</b> Porcentaje de molestado mostrado por pantalla, cuarta iteración. Elaboración propia. ....             | 100 |
| <b>Ilustración 109:</b> Gráfico de control de calidad, cuarta iteración. Elaboración propia.....                              | 101 |
| <b>Ilustración 110:</b> Histograma para porcentajes de molestado. Elaboración propia. ....                                    | 101 |
| <b>Ilustración 111:</b> Gráfico de barras para porcentajes de molestado. Elaboración propia. ....                             | 102 |
| <b>Ilustración 112:</b> Exportar a Formato de CAD. Elaboración propia. ....   | 110 |
| <b>Ilustración 113:</b> Guardar en formato ".stl". Elaboración propia. ....   | 110 |
| <b>Ilustración 114:</b> Añadir proyecto en PrusaSlicer. Elaboración propia. ....  | 110 |
| <b>Ilustración 115:</b> Guardar en formato ".stl". Elaboración propia. ....   | 110 |
| <b>Ilustración 116:</b> Interfaz de PrusaSlicer. Elaboración propia. ....   | 111 |
| <b>Ilustración 117:</b> Laminar objeto en PrusaSlicer. Elaboración propia.....  | 111 |
| <b>Ilustración 118:</b> Guardar en formato ".gcode". Elaboración propia. ....   | 111 |
| <b>Ilustración 119:</b> Configuración de filamento y temperatura en PrusaSlicer. Elaboración propia. ....                     | 112 |
| <b>Ilustración 120:</b> Clip cortado. (Avila, 2022).....  | 113 |
| <b>Ilustración 121:</b> Motor Nema 17. (Libano, 2022). ....   | 113 |
| <b>Ilustración 122:</b> Módulo lineal drylin® SLW-1040. (Iigus Motion Plastics, 2024) ....                                    | 113 |
| <b>Ilustración 123:</b> Guía drylin® W L:500mm y carro drylin® W con freno manual. (Iigus Motion Plastics, 2024).....         | 114 |
| <b>Ilustración 124:</b> Protocolo de conexión con cinta I. Elaboración propia.....  | 115 |
| <b>Ilustración 125:</b> Protocolo de conexión con cinta II. Elaboración propia.....   | 116 |
| <b>Ilustración 126:</b> Protocolo de control de cinta. Elaboración propia. ....   | 116 |
| <b>Ilustración 127:</b> Instalación de Accelstepper. Elaboración propia.....  | 117 |
| <b>Ilustración 128:</b> Pestaña "Add-Ons". Elaboración propia. ....   | 117 |
| <b>Ilustración 129:</b> Add-Ons explorer. Elaboración propia. ....  | 118 |
| <b>Ilustración 130:</b> Add-Ons Manager. Elaboración propia. ....   | 118 |

## Índice de tablas

|  |     |
|--|-----|
| <b>Tabla 1:</b> Ventajas y desventajas de la captura por rotación. Elaboración propia. ....                    | 69  |
| <b>Tabla 2:</b> Ventajas y desventajas de la captura por traslación. Elaboración propia.....                   | 71  |
| <b>Tabla 3:</b> Porcentaje promedio de molestado para cada iteración. Elaboración propia.....                  | 103 |
| <b>Tabla 4:</b> Comparación de ambos métodos para posibles aplicaciones industriales. Elaboración propia. .... | 105 |
| <b>Tabla 5:</b> Presupuesto total del montaje. Elaboración propia.....   | 119 |

## Índice de códigos

|  |    |
|--|----|
| <b>Código 1:</b> Control arduino y microcontrolador. Elaboración propia. ....  | 56 |
| <b>Código 2:</b> Análisis y media de grises de las aceitunas dopadas rotadas. Elaboración propia. ....                     | 77 |
| <b>Código 3:</b> Procesamiento y etiquetado de aceitunas rotadas para machine learning. Elaboración propia. ....           | 80 |
| <b>Código 4:</b> Validación de predicciones del modelo clasificador para aceitunas rotadas. Elaboración propia. ....       | 84 |
| <b>Código 5:</b> Mejora para el nuevo mapa de clasificación visualizada en aceitunas trasladadas. Elaboración propia. .... | 89 |
| <b>Código 6:</b> Validación de predicciones del modelo clasificador para aceitunas trasladadas. Elaboración propia. ....   | 92 |

## 1. Introducción

El propósito principal de este proyecto es demostrar la viabilidad de la tecnología hiperespectral para la detección de daños en las aceitunas de mesa. Para ello, será necesario aprender a trabajar e interpretar los datos obtenidos con el software para localizar dichos daños, así como construir un setup físico que permita capturar las imágenes de forma precisa.

Se inicia contextualizando el trabajo dentro del marco del proyecto Espectrolive, una iniciativa centrada en la aplicación de técnicas hiperespectrales para mejorar la detección de fitosanitarios en aceitunas. A continuación, se exploran los hitos y avances más relevantes en estudios previos relacionados con la tecnología hiperespectral en la agricultura, subrayando su eficacia y precisión en la detección de daños en productos agrícolas.

Finalmente, se desglosa la estructura del documento, proporcionando una visión general de las secciones que abarcan desde el diseño experimental y montaje del equipo hasta los métodos de procesamiento de datos, presentación de resultados y conclusiones del estudio.

### 1.1. Contexto

Este trabajo se desarrolla bajo el marco del proyecto Espectrolive, una iniciativa impulsada por INOLEO y secpho, centrada en la aplicación de técnicas de visión hiperespectral para la detección de fitosanitarios en aceitunas (INOLEO, 2024). El proyecto se enfoca en las dos primeras fases del proyecto: la adquisición de imágenes y el preprocesado de las mismas para eliminar zonas con molestado. Estas fases primerizas son críticas para establecer un método efectivo y no invasivo que permita la detección temprana y precisa de residuos fitosanitarios, asegurando así la calidad de las aceitunas antes de su procesamiento.

La relevancia de esta investigación radica en su potencial para mejorar los métodos de control de calidad en la industria oleícola, promoviendo una agricultura más sostenible mediante la reducción del uso de fitosanitarios y la minimización de su impacto ambiental. Al asegurar que las aceitunas estén libres de químicos nocivos, se contribuye directamente a la producción de aceite de oliva de alta calidad y a la protección de la salud de los consumidores.

Las técnicas no invasivas aprovechan la capacidad de capturar información espectral y espacial detallada sin alterar el producto, lo que permite una evaluación exhaustiva de las propiedades químicas y físicas de los alimentos. Este estudio pretende, por tanto, explorar y validar la eficacia de la tecnología hiperespectral en la fase de recepción de las aceitunas en la almazara. A través de un enfoque metodológico riguroso, se busca desarrollar un modelo físico experimental que facilite la captura de imágenes y posterior identificación de zonas afectadas por molestado.

Para facilitar la comprensión del proceso y la metodología empleados, se incluirá un diagrama de bloques que detalle las etapas de adquisición de imágenes y preprocesado, ilustrando cómo estos métodos se integran en un sistema de control de calidad efectivo.

**Diagrama de fases para el procesamiento de imágenes hiperespectrales**



*Ilustración 1: Diagrama de fases del proyecto. Elaboración propia.*

## 1.2. Antecedentes y estado del arte

La identificación de defectos en aceitunas mediante tecnologías de visión hiperespectral representa un campo de estudio relevante dentro de la producción agrícola, especialmente en la industria del aceite de oliva. Dicha tecnología ha demostrado ser una herramienta eficaz para identificar y clasificar defectos en productos agrícolas debido a su capacidad para capturar información detallada del espectro de luz reflejado por los frutos.

En el ámbito de la detección de daños específicos causados por la mosca del olivo en aceitunas, la implementación de técnicas hiperespectrales y de visión por computador ha facilitado el desarrollo de métodos automáticos notablemente más eficaces que las inspecciones visuales tradicionales. Estos métodos avanzados logran identificar con precisión hasta el 93% de las áreas afectadas, y los algoritmos empleados para la clasificación de los daños alcanzan una efectividad de aproximadamente el 80%. Esta capacidad de discriminación es crucial para diferenciar entre diversos tipos de imperfecciones en la superficie de las aceitunas,

como picaduras y otros tipos de marcas o deformaciones (Abdullah Beyaz, 2019). Además, el estudio validó su metodología en un entorno de producción real, demostrando la aplicabilidad y la eficacia de la tecnología en condiciones operativas dinámicas.

Un estudio se centró en la determinación de parámetros de calidad del aceite de oliva utilizando visión hiperespectral. Este trabajo utilizó técnicas de análisis discriminante de mínimos cuadrados parciales (PLS-DA) y máquinas de vectores de soporte (LS-SVM) para clasificar y cuantificar la adulteración del aceite de oliva virgen extra con aceites comestibles más baratos. Los modelos predictivos desarrollados demostraron una alta precisión en la autenticación del aceite de oliva, con modelos de regresión PLS logrando una baja raíz cuadrada del error de predicción (RMSEP) del 1.1% y un alto coeficiente de determinación ( $R^2$ ) de 0.97. Estos resultados sugieren que la tecnología hiperespectral es una técnica rápida y no destructiva para controlar el fraude en la industria del aceite de oliva (Diego Martínez Gila, 2012).

Otra investigación realizada por Javiera Navarro Soto, Silvia Satorres Martínez y colaboradores, se enfocó en la determinación rápida y confiable de la calidad del aceite de oliva virgen mediante la inspección de frutas utilizando visión por computador. Este estudio correlacionó las características de color y textura de las imágenes de las aceitunas con parámetros químicos del aceite producido. Se utilizaron modelos de regresión de mínimos cuadrados parciales (PLS) para predecir parámetros de calidad como el índice de acidez, los valores de peróxidos, ésteres etílicos, polifenoles, clorofilas y carotenoides. Los resultados mostraron una alta correlación entre las características visuales de las aceitunas y la calidad del aceite de oliva, destacando la viabilidad de implementar este sistema en línea para clasificar los lotes de aceitunas al inicio del proceso industrial, mejorando así la calidad del aceite producido (Javiera Navarro Soto, 2018).

Para finalizar, se ha desarrollado un sistema inteligente para la evaluación automática de la calidad visual de aceitunas verdes en el campo. Este sistema emplea técnicas de visión por computador para analizar parámetros como el calibre, la madurez y el índice de magulladuras de las aceitunas. El dispositivo, denominado SAEOQ, es portátil y utiliza una cámara digital convencional para adquirir imágenes de las aceitunas en un entorno controlado de iluminación.

Los algoritmos implementados en el software del dispositivo permiten la segmentación y análisis de las imágenes para evaluar la calidad de las aceitunas en tiempo real. La evaluación del índice de magulladuras también ha sido eficiente, aunque con mayor precisión en aceitunas menos maduras (MI0) en comparación con aquellas en etapas de madurez avanzada (MI1) (Rafael R. Sola-Guirado, 2020).

### 1.3. Objetivos

El objetivo general de este proyecto es conseguir detectar de forma precisa daños en aceitunas de mesa mediante una tecnología no invasiva. Para ello, definiremos los siguientes objetivos específicos.

- Desarrollar un sistema experimental para la adquisición de datos espectrales de aceitunas bajo diferentes condiciones de daño.
- Estudiar la viabilidad de las diferentes formas de adquisición de hipercubos sobre aceitunas.
- Procesar y analizar los datos espectrales recopilados para identificar patrones y características que diferencien aceitunas dañadas de las no dañadas.
- Crear y validar un modelo predictivo basado en el análisis de datos espectrales que pueda ser utilizado para la detección rápida y eficaz de daños durante la producción y el control de calidad de las aceitunas.
- Diseño y desarrollo de un software de etiquetado que permita distinguir el fruto sano del contaminado.

### 1.4. Estructura del documento

**Resumen:** breve explicación sobre lo realizado en este trabajo.

**Abstract:** breve explicación sobre lo realizado en este trabajo, pero en inglés.

**Introducción:** pone en contexto el proyecto que se va a desarrollar.

- Contextualización y relevancia del estudio: se presenta la importancia y motivaciones de llevar a cabo el estudio.

- Antecedentes y estado del arte: revisión de trabajos previos y el estado actual de la tecnología hiperespectral en productos agrícolas.
- Objetivos: los objetivos finales del trabajo.

**Diseño y desarrollo del setup experimental:** elementos y ensamblaje operativo.

- Descripción del setup experimental: se definen las características del setup.
- Selección de materiales y componentes: descripción de cada componente usado en el proceso.
- Diseño y fabricación de prototipos 3D: descripción el proceso de impresión.
- Piezas: modelo y planos de cada elemento diseñado e impreso.
- Montaje de la estructura: configuración paso al paso del proceso de la construcción.
- Configuración y programación del Arduino y microcontrolador: procedimiento para la conexión y programación del Arduino y el microcontrolador.
- Implementación de la cinta y el motor: integración de la cinta transportadora y el motor en el sistema.

**Diseño y desarrollo software:** descripción del software utilizado y los métodos de procesamiento de datos.

- Software empleado: software y lenguaje de programación utilizado en el análisis de imágenes hiperespectrales.
- Técnicas de adquisición de imágenes: metodología para la captura de imágenes hiperespectrales.

- Procesamiento y análisis de datos: procedimientos para analizar los datos obtenidos.
- Entrenamiento de los modelos: proceso de desarrollo y validación de modelos predictivos basados en datos espectrales.

**Resultados:** Presentación y discusión de los resultados obtenidos.

- Análisis de los datos obtenidos: evaluación de los datos recopilados durante el experimento.
- Evaluación de técnicas no invasivas en la detección de daños: análisis de la eficacia de la tecnología hiperespectral.
- Discusión de resultados: interpretación y discusión de los resultados obtenidos.

**Conclusión y trabajo futuro:** presentación y discusión de los resultados obtenidos.

**Bibliografía:** lista de las fuentes y referencias utilizadas en el documento.

**Anexo:** información adicional y complementaria al contenido principal.

- Anexo I: Protocolo de impresión 3D: instrucciones detalladas sobre el proceso de impresión 3D utilizado.
- Anexo II: Modelos 3D de comprobación: planos y modelos de las piezas impresas en 3D.
- Anexo III: Protocolo de control de cinta: instrucciones detalladas sobre la conexión con la cinta y manejo de la misma.
- Anexo IV: Instalación de paquetes y librerías: procedimiento para instalar todo el soporte utilizado.
- Anexo V: Presupuesto total del montaje.

## **2. Diseño y desarrollo del setup experimental**

El diseño experimental del proyecto estará basado alrededor del elemento principal: una cámara hiperespectral lineal. Este dispositivo tiene la particularidad teórica de capturar datos a lo largo de una línea única de píxeles. Para obtener una imagen completa, la aceituna (o en su defecto, la cámara) deben moverse, permitiendo que cada línea de la imagen sea adquirida sucesivamente.

Una dicotomía inicial surge al evaluar las opciones disponibles para el análisis: para un examen completo, las aceitunas deben ser escaneadas mediante rotación o traslación.

En la primera iteración, con el objetivo de obtener una imagen detallada de una aceituna con la mayor calidad posible, se optará por la rotación. Se empleará un motor paso a paso acoplado a un eje que permita rotar la aceituna 360°, proporcionando una imagen de un único fruto con la máxima resolución. Aunque una cinta transportadora permitiría estudiar lotes en masa, se priorizará la calidad y detalle de imagen sobre la cantidad.

Una vez se logre el éxito en esta fase inicial, se utilizarán los conocimientos adquiridos para aplicarlos a un escenario real. Por lo tanto, se optará por la traslación de varios frutos en cinta transportadora mediante el uso de una bandeja personalizada impresa en 3D.

### **2.1. Descripción del setup experimental**

La estructura principal estará formada por perfiles de aluminio, módulos, carros y guías lineales que permitirán mover la cámara libremente en los ejes vertical y horizontal. Esta configuración permitirá fijar la cámara para capturar imágenes desde diversas alturas y posiciones, optimizando la visibilidad según las características del objeto de estudio. De esta forma, el montaje podrá ser reutilizado en futuros proyectos.

La iluminación es un factor crítico en el setup experimental. Se emplearán focos halógenos de alta potencia, manualmente posicionados para proporcionar una iluminación uniforme y minimizar las sombras o reflejos.

Dicha iluminación ofrece un espectro continuo y amplio que se asemeja mucho a la luz solar, lo que permite capturar una gama completa de longitudes de onda, desde el visible hasta el infrarrojo cercano. Por otro lado, la alta intensidad de los focos halógenos asegura que incluso los detalles más pequeños sean visibles, lo que es fundamental para detectar características y defectos que podrían no ser evidentes bajo una iluminación menos potente (Gowen, O'Donnell, Cullen, Downey, & Frias, 2007).

La rotación de las aceitunas será controlada por un motor paso a paso, con el fin de poder capturar imágenes de toda la superficie del fruto. Este motor estará conectado a un microcontrolador y será gestionado por un Arduino, garantizando movimientos precisos y sincronizados con el software de adquisición.

Finalmente, la cinta transportadora simulará un entorno real de procesamiento, desplazando las aceitunas en una bandeja a través del campo de visión de la cámara. Esta configuración permite capturar imágenes de múltiples aceitunas de manera continua, lo que resulta particularmente eficiente para la aplicación de algoritmos predictivos y estudio de lotes.

## **2.2. Selección de materiales y componentes**

A continuación, se detallarán todos los materiales importantes utilizados en el montaje. El presupuesto total del montaje se detalla en el *Anexo V: Presupuesto total*.

**Cámara hiperespectral:** Pika L. Con un rango espectral de 400 a 1000 nm, 281 canales espectrales, una resolución espectral de 2.7 nm y 900 píxeles espaciales, siendo capaz de proporcionar datos de alta resolución. Perfecta para un estudio a pequeña escala y detallado del fruto. Ver *Ilustración 2*.

Se le añadirá una lente capaz de capturar el rango infrarrojo y de 23 mm, lo que indica la distancia entre el centro óptico de la lente y el sensor de la cámara cuando la imagen está enfocada. (Resonon, 2024)



*Ilustración 2: Cámara hiperespectral Pika L. Elaboración propia.*

**Ordenador:** este PC cumplirá con los requisitos operativos establecidos por la empresa para manejar las imágenes de nuestra cámara hiperespectral. Ver *Ilustración 3*.

Las especificaciones de 32 GB de RAM aseguran que se pueda trabajar con múltiples datacubos sin problemas de rendimiento. Windows 10 será el sistema operativo.




*Ilustración 3: Ordenador. Elaboración propia.*

Aunque el soporte de Resonon recomendó personalmente un procesador Intel i7, el AMD Ryzen 5 5600 ofrece una velocidad de procesamiento adecuada para garantizar que el software Spectronon funcione de manera eficiente. Por otro lado, la placa base contará con puertos USB 3.0 por requerimiento operativo de la cámara.

| Especificaciones del dispositivo |  |
|----------------------------------|--|
| Nombre del dispositivo           | DESKTOP-TJ7TFDE  |
| Procesador                       | AMD Ryzen 5 5600 6-Core Processor 3.50 GHz                           |
| RAM instalada                    | 32,0 GB  |
| Identificador de dispositivo     | 387CA7C0-9ADF-496C-B7DB-97CE14C2D89A                                 |
| Id. del producto                 | 00329-10182-09725-AA945  |
| Tipo de sistema                  | Sistema operativo de 64 bits, procesador basado en x64               |
| Lápiz y entrada táctil           | La entrada táctil o manuscrita no está disponible para esta pantalla |

*Ilustración 4: Especificaciones del ordenador. Elaboración propia.*


**Cinta transportadora:** se trabajará con una cinta servo-controlada y gestionada mediante un driver de Schneider Electric, modelo Lexium 32M, equipada con control por Modbus TCP (Schneider Electric, 2024). Se simulará un entorno de almazara donde las aceitunas son transportadas en la misma, con 2 m de longitud total y 20 cm de anchura. Ver *Ilustración 5*.



*Ilustración 5: Cinta transportadora. Elaboración propia.*

**Impresora 3D:** Prusa i3 MK3S+ (Prusa Research, 2024). Con ella se imprimirá en 3D con filamentos PLA las piezas que se diseñen para montarlo todo, pudiendo hacer pruebas y diferentes combinaciones de forma rápida y barata. Ver *Ilustración 6*.

Esto ha permitido experimentar con diversos diseños, ajustando rápidamente cualquier fallo detectado en las piezas impresas. Este proceso de prueba y error ha sido fundamental para perfeccionar el ensamblaje final del sistema, garantizando que todas las piezas encajen y funcionen correctamente. Ver *Ilustración 7*.




*Ilustración 6: Impresora en funcionamiento. Elaboración propia.*



*Ilustración 7: Ejemplo de piezas descartadas. Elaboración propia.*

**Focos halógenos:** sujetos mediante brazos articulados. Dos focos de 1000W ajustados manualmente a 10 cm de altura para una iluminación óptima. Ver *Ilustración 8*.



*Ilustración 8: Focos halógenos apuntando al rango de visión de la lente. Elaboración propia.*


**Motor paso a paso:** Nema 17. Motor bipolar con un ángulo de paso de  $1.8^\circ$  y un voltaje nominal de 3.4 V, capaz de soportar una carga de 3.2 kg/cm. Ver *Ilustración 9*. (BricoGeek, 2024)



*Ilustración 9: Motor paso a paso. Elaboración propia.*


**Placa:** Arduino Uno. Modelo básico de control junto a un alimentador 12V/2A. Mandará las señales al motor para funcionar. Ver *Ilustración 10*. (BricoGeek, 2024)

**Microcontrolador:** TB6600. Es un controlador profesional para motores paso a paso bipolares, permitiendo hasta 3.5 A por canal. Tiene limitación de corriente ajustable, protección contra sobre corriente y 7 resoluciones diferentes de microstepping (BricoGeek, 2024). En la *Ilustración 56* se detallan las conexiones.



*Ilustración 10: Arduino y microcontrolador. Elaboración propia.*

**Guías lineales y carro:** dos módulos lineales SLW-1040 estándar (SLW-1040-100-HR y SLW-1040-300-HR) (Iigus Motion Plastics, 2024) junto a una guía lineal drylin® W L:500mm (WS-10-40-500) (Iigus Motion Plastics, 2024) y un carro drylin® W con freno manual (WW-10-40-10-HKA) (Iigus Motion Plastics, 2024). Con ellas se montará la estructura que permitirá que la cámara y motor se desplacen por los ejes de manera manual y controlada, gracias a sus husillos con cabeza autoblocante. Ver *Ilustración 11*.



*Ilustración 11: Combinación vertical de módulos lineales. Elaboración propia.*

### 2.3. Diseño y fabricación de prototipos 3D

El primer paso en la impresión 3D es la preparación del modelo digital. En Autodesk Inventor se diseñarán las piezas necesarias para el montaje del sistema. Una vez finalizado dicho boceto, se procede a exportar el modelo a formato .stl (Standard Tessellation Language). La elección de este formato radica en su capacidad para ser reconocido por la mayoría de los programas de corte (slicers) utilizados en la impresión física de la pieza. (Congress, 2020)

El siguiente paso es convertir este archivo a G-Code, el lenguaje de programación que las impresoras utilizan para fabricar las piezas. Este proceso se realiza mediante el uso de un programa de corte, en este caso, PrusaSlicer, proporcionado por la empresa de la propia impresora. Esta es una herramienta de software que convierte los modelos 3D en instrucciones específicas para la impresora, las cuales incluyen movimientos del cabezal de impresión, la velocidad, la temperatura del extrusor, entre otros parámetros. (Prusa3d, 2024)

El filamento de impresión principal será el PLA Galaxy Silver/Vanilla White, fabricado también por Prusa Research. Este material es una variante del ácido poliláctico, un bioplástico derivado de recursos renovables como el almidón de maíz o la caña de azúcar. (Prusa Research, 2024)


El proceso manual llevado a cabo para la impresión de las piezas se encuentra detallado en el *Anexo I: Protocolo de impresión 3D*.

## **2.4. Piezas**

En este apartado se detallan las piezas específicas diseñadas para resolver problemas particulares que surgieron durante el desarrollo del proyecto, garantizando la funcionalidad y eficiencia del setup experimental. Se describirán las características físicas de cada pieza y cómo contribuyen a la solución de los mismos en el contexto del estudio. Las medidas de las mismas se detallan en milímetros y el material soporte para comprobar medidas se detalla en el *Anexo II: Modelos 3D de comprobación*.

La tornillería no especificada se asume debido a la naturaleza de la impresión 3D en PLA a pequeña escala. En este contexto, la herramienta de roscado de Autodesk Inventor no es relevante, ya que dicho efecto se conseguirá forzando el tornillo directamente en el plástico. El factor más importante será el diámetro del agujero, siempre contando con una ligera holgura adicional.


### 2.4.1. Soporte para aceituna



*Ilustración 12: Modelo y planos del soporte para la aceituna. Elaboración propia.*

**Descripción:** diseñada para asegurar el eje del motor paso a paso y permitir una rotación precisa de las aceitunas durante la captura de imágenes. Su forma cilíndrica junto el diseño interno facilitan la introducción de un clip cortado para la sujeción del fruto, el cual llegará a su límite de penetración a los 20 mm y quedará empujado con el eje del motor, manteniéndolo estable durante el proceso.

El grosor del soporte y la longitud de la sección interior están basados en el tamaño y diámetro medio de clips de oficina.




*Ilustración 13: Planos del soporte para aceituna con el clip cortado. Elaboración propia.*


Su longitud de penetración de 20 mm iguala la del eje del motor. Estos 3 mm adicionales permiten que el eje choque contra la pieza y que el clip sobresalga. El diámetro exterior asegura un ajuste preciso en el mecanismo de rotación, mientras que el diámetro interior permite que el eje del motor encaje perfectamente, manteniendo una holgura extra de aproximadamente 2 mm en los diámetros.

**Problemática que resuelve:** elimina el problema de deslizamiento y caída del fruto durante la rotación, asegurando una fijación estable del clip junto al eje del motor y una rotación precisa de las aceitunas.

#### 2.4.2. Soporte para motor



**Ilustración 14:** Modelo del soporte para motor. Elaboración propia.



**Ilustración 15:** Planos del soporte para motor. Elaboración propia.

**Descripción:** este soporte en forma de "U" permite una sujeción firme del motor gracias a sus cuatro tornillos que trae de fábrica, asegurando que se mantenga en una posición fija durante el *Montaje de la estructura*. Anclado al perfil de aluminio y atornillado en las cuatro perforaciones que tiene el motor, dejando 2 mm de holgura para incluir el *Soporte para aceituna*.


Los 10 cm de longitud totales permitirán mantener el motor en el centro de la cinta.




*Ilustración 16: Comprobación pieza primeriza/motor. Elaboración propia.*

**Problemática que resuelve:** proporciona una solución estable y segura para montar el motor paso a paso en la estructura, evitando desalineaciones, movimientos y tocar el motor cuando esté ardiendo por la exposición al calor.

### 2.4.3. Soporte del eje vertical para módulo lineal




*Ilustración 17: Modelo del soporte del eje vertical para módulo lineal. Elaboración propia.*



**Ilustración 18:** Planos del soporte del eje vertical para módulo lineal. Elaboración propia.


**Descripción:** placa de soporte vertical diseñada para una conexión segura entre módulos, asegurando su alineación en forma de cruz. Su diseño robusto facilita un movimiento manual suave y estable del sistema.

El grosor de la placa permite ocultar los tornillos de conexión con el carro de la guía, manteniendo las dos piezas gemelas completamente unidas.



**Ilustración 19:** Combinación de los ejes pegados. Elaboración propia.


Las penetraciones están pegadas al carro del módulo mediante sus propios tornillos M3, garantizando una fijación estable.




*Ilustración 20: Comprobación placa con carro del módulo lineal vertical. Elaboración propia.*

**Problemática que resuelve:** asegura una conexión firme y estable entre los módulos que sostienen la cámara, previniendo desplazamientos y vibraciones no deseadas durante la operación.

#### 2.4.4. Soporte del eje horizontal para módulo lineal




*Ilustración 21: Modelo del soporte del eje horizontal para módulo lineal. Elaboración propia.*



**Ilustración 22:** Planos del soporte del eje horizontal para módulo lineal. Elaboración propia.


**Descripción:** contraparte del *Soporte del eje vertical* para pero para el eje horizontal. Misma función.




**Ilustración 23:** Comprobación placa con carro del módulo lineal horizontal. Elaboración propia.

**Problemática que resuelve:** completar la conexión con su contraparte y lograr estabilizar toda la estructura.

### 2.4.5. Soporte para cámara




*Ilustración 24: Modelo del soporte para cámara. Elaboración propia.*



*Ilustración 25: Planos del soporte para cámara. Elaboración propia.*

**Descripción:** diseñada en forma de L, esta pieza abraza el módulo lineal y monta la cámara en la estructura principal, garantizando su estabilidad durante la adquisición de imágenes. Su diseño incluye múltiples orificios para facilitar la fijación tanto a la cámara como al extremo del módulo, utilizando tornillos M3 para la cámara.



*Ilustración 26: Comprobación soporte cámara con módulo lineal horizontal. Elaboración propia.*

**Problemática que resuelve:** adhesión de la cámara a la estructura montada y ángulo de captura óptimo con una profundidad suficiente para que no choque con nada.


#### 2.4.6. Estructura para motor/carro

En el diseño del ensamblaje donde el motor está montado a la estructura y a su vez se conecta a la placa que forma parte del carro, nos enfrentamos a una limitación de espacio significativa. No existe espacio suficiente entre el motor, ya fijado a la estructura, y la placa que debe acoplarse al carro. Esta restricción hizo inviable la instalación de una sola pieza que uniera directamente el motor con el carro a lo largo del eje longitudinal.


Para superar este desafío, se tomó la decisión de diseñar la placa en dos segmentos separados. Esta modificación permitió que cada parte fuera montada de manera individual, facilitando así el proceso de ensamblaje bajo las condiciones de espacio restringido.

Una vez montadas ambas partes de la placa, éstas funcionan como una sola unidad que no solo soporta el motor, sino que también permite el movimiento controlado y preciso del carro a lo largo del eje longitudinal. Esta pieza permite mover el carro a lo largo del eje longitudinal y fijarlo utilizando el freno integrado en el carro.

### ▪ Pieza para carro




*Ilustración 27: Modelo de la pieza para el carro. Elaboración propia.*




*Ilustración 28: Planos de la pieza para el carro. Elaboración propia.*

▪ **Pieza para motor**




*Ilustración 29: Modelo de la pieza para el motor. Elaboración propia.*




*Ilustración 30: Planos de la pieza para el motor. Elaboración propia.*

- **Estructura final**



*Ilustración 31: Modelo de la estructura final motor/carro. Elaboración propia.*

**Descripción:** consta de dos piezas que se ensamblan para fijar el motor paso a paso en el carro de la guía lineal. La primera pieza es una base en forma de L que proporciona una plataforma sólida y estable para unirse al carro con freno. La segunda pieza es una placa con un orificio central grande para el eje del motor y varios orificios para atornillarla en la parte inferior a la pieza anterior.




*Ilustración 32: Comprobación de la estructura horizontal completa del setup. Elaboración propia.*


Este diseño está enormemente basado en el *Soporte para motor*, pieza que aunque quedó obsoleta en el momento que pasamos al *Montaje final*, sirvió de base teórica para este diseño final. Además, permite añadir el *Soporte para aceituna*, al igual que su antecesor.

**Problemática que resuelve:** fijación y estabilidad del motor paso a paso en la estructura del sistema. Asegura que el motor permanezca en una posición fija y alineada, permitiendo una rotación precisa del eje.

#### 2.4.7. Soporte para placa y microcontrolador




**Ilustración 33:** Modelo del soporte para placa y microcontrolador. Elaboración propia.



**Ilustración 34:** Planos del soporte para placa y microcontrolador. Elaboración propia.

**Descripción:** cuenta con múltiples orificios y ranuras que permiten una fijación segura del Arduino y un área empotrada de 97x35 mm para anclar el microcontrolador, así como su montaje en los perfiles de aluminio. Permitirá ponerla donde mejor convenga en cada momento y los tendrá localizados.




*Ilustración 35: Comprobación soporte con Arduino. Elaboración propia.*

**Problemática que resuelve:** asegura que estos componentes permanezcan en su lugar durante la operación en función de la distancia al motor, ya que los cables de conexión al mismo tienen una distancia limitada.

Es una pieza prescindible pero esencial si se quiere mantener una rigurosidad organizativa.

### 2.4.8. Bandeja para aceitunas




*Ilustración 36: Modelo y planos de la bandeja para aceitunas. Elaboración propia.*

**Descripción:** diseñada con múltiples cavidades para transportar hasta 10 aceitunas, asegurando su estabilidad durante el transporte y la captura de imágenes. Su forma rectangular y las cavidades empotradas proporcionan organización y estabilidad, optimizando el proceso de adquisición de datos.

**Problemática que resuelve:** mantiene las aceitunas organizadas y estables durante su traslado en la cinta transportadora. Esto facilita la segmentación y parametrización de las fotos, proporciona un fondo reconocible en términos de longitudes de onda, y facilita la creación de la máscara de preprocesado y el entrenamiento de los modelos de reconocimiento.

### 2.4.9. Caja y tapa para Arduino Uno



*Ilustración 37: Modelo de la caja y tapa del Arduino. (Cults 3D, 2021)*

**Descripción:** piezas de uso libre, diseñadas para albergar y proteger el Arduino. La caja tiene una forma rectangular con un compartimento interno que se ajusta a las dimensiones del modelo Uno, mientras que la tapa se coloca sobre la caja para sellarla, proporcionando una estructura robusta y resistente. No se incluyen medidas específicas, ya que están diseñadas para ajustarse a las dimensiones estándares del mismo.

Su aspecto facetado que se observa en las imágenes es por haber sido descargado directamente en formato .stl, este representa la superficie del modelo mediante una serie de triángulos conectados.

**Problemática que resuelve:** protegen del polvo y la suciedad que puede interferir con los componentes electrónicos, así como de golpes y caídas que pueden dañar el dispositivo. Además, mantienen el Arduino y sus componentes organizados y seguros, evitando desconexiones accidentales y facilitando el manejo y transporte del dispositivo.

## 2.5. Montaje de la estructura


El estudio de las aceitunas comenzó el 19 de octubre de 2023, recibiendo el primer lote del proyecto Espectrolive, aceitunas contaminadas de la variedad picual. Debido a la rapidez de la entrega, realizar un montaje preliminar básico fue necesario para poder adquirir imágenes de inmediato. Tras esta fase inicial, procedimos al diseño y ensamblaje del montaje detallado y final.

### 2.5.1. Montaje preliminar

El primer setup se realizó con los materiales disponibles en el laboratorio. El objetivo inicial era estudiar cada aceituna en detalle y con la máxima resolución posible, logrando la rotación del fruto y obteniendo un plano extendido de toda su superficie.

Para esto, el motor se fijó a una pieza reutilizada mediante bridas, sosteniendo un clip cortado que pinchaba el fruto. Aunque esta metodología rompía parcialmente el principio de no invasión, la mínima penetración permitía una experimentación rápida y sencilla.

La cámara y los focos se sujetaron con brazos articulados, proporcionando altura e inclinación ajustables, aunque inestables. Además, se comprobó experimentalmente el rango de captura de la cámara, determinando una distancia óptima de 12 cm al eje del motor. El proceso de calibración de la misma se detallará posteriormente.



*Ilustración 38: Montaje preliminar. Elaboración propia.*

Debido al funcionamiento simultáneo del motor y el calor emitido por los focos, comprobamos que la aceituna resbalaba y el agarre del fruto se dificultaba con el paso del tiempo. Para solucionar este problema, se diseñó el *Soporte para motor*.

Gracias a esto se podría conseguir una mayor estabilidad, adaptando la distancia del perfil al centro de la cinta y permitiendo atornillar el motor a esta y evitar tocarlo cuando su temperatura aumentase. Sin embargo, el principal problema del conjunto emergía: las grasas vegetales de la aceituna provocaban que esta se derritiera y cayera consecuentemente del eje, ensuciando todo y generando un olor desagradable.

Para ello, se diseñó el *Soporte para aceituna*, el cual permitía una penetración central del eje del motor y a su vez la inclusión de un clip en su parte central para pinchar y estabilizar el fruto. Dicho diseño sumado al anterior, dio como resultado una muy buena base para proceder con el estudio rotatorio. Adherimos las piezas a los perfiles y trabajamos con ellas hasta poder descartar este primer montaje y proceder al final.



**Ilustración 39:** Manchas de grasa en la pieza. Elaboración propia.

Sin embargo, el otro problema enfrentado en el estudio de este caso seguía vigente: las manchas de grasa mencionadas anteriormente. En piezas de PLA resulta tremendamente ineficiente tener que imprimir en masa piezas que se descarten en cada sesión de trabajo, por lo que en caso de ser este método el usado recurrentemente, se buscaría otro material que aguante el calor y fácil de limpiar.

## 2.5.2. Montaje final

### ▪ Estructura vertical

Una vez se experimentó con este primer escenario, se procedió a la construcción del setup definitivo. Dicho montaje debe permitir sostener la cámara de forma que se pueda trasladar verticalmente, para regular la altura a la cinta de la misma, y transversalmente, dejando así espacio a capturar el rango de visión deseado.



*Ilustración 40: Estructura base. Elaboración propia.*

La cinta cuenta de base con una estructura lateral de perfiles de aluminio de ranurado en T 40x40 mm, que serán de gran utilidad a la hora de ensamblarlo todo. La sección transversal del perfil muestra varias ranuras en forma de T y cavidades internas que nos permiten el montaje de piezas y accesorios mediante tornillos y pernos.



*Ilustración 41: Perfil de aluminio de ranurado en T. Elaboración propia.*

Se planteó una estructura en cruz, para la cual se necesitó otro perfil de aluminio, y una guía que permita colocar el motor junto a un carro que lo sostenga y permita ponerlo en la posición que se desee a lo largo de la cinta. A su vez, dicha estructura irá sostenida por dos perfiles de aluminio cruzados formando un puente con la estructura primeriza.

Con esta hipótesis en mente, se contactó con IGUS, una empresa que destaca en la fabricación de rodamientos y cojinetes que no requieren lubricación adicional, perfecto para trabajos experimentales de este estilo. En su web se pueden encontrar soporte para diferente software de diseño para las guías y piezas que venden, pudiendo así comprobar de primera mano cómo funcionaría su ensamblaje y diseñar piezas para unir los componentes. Ver *Ilustración 122* e *Ilustración 123*.

El módulo lineal SLW-1040 utiliza un husillo de avance para realizar ajustes de distancia de manera manual. Tiene un perfil de aluminio anodizado duro y puede soportar una carga axial de hasta 700N, con un diámetro de eje de 10mm y una longitud máxima de desplazamiento de 750mm. Se hará uso de dos guías acopladas en forma de cruz. Ver *Ilustración 19*.


Una vez decidida el tipo de guía, se diseñarán las dos piezas que servirán de nexo entre los dos carros. Cada una necesitará un diseño independiente, ya que irá tanto atornillado al propio carro como a la otra pieza soporte, las cuales sobresaldrán por los extremos para permitir dicha unión. Ver *Soporte del eje vertical para módulo lineal* y *Soporte del eje horizontal para módulo lineal*.

Ambas piezas contarán con ocho penetraciones útiles: cuatro para el carro y cuatro para la conexión con su gemela. Las pertenecientes al carro tendrán un diámetro de 10,5 mm, para adecuarse a los tornillos que el mismo trae. Las exteriores tendrán un diámetro de 6 mm y serán unidas por tornillos de 40 mm de longitud. Es crucial que midan eso ya que es el espacio máximo entre la penetración desde el *Soporte del eje horizontal para módulo lineal* hasta el perfil de aluminio que sostiene la estructura.






**Ilustración 44:** Escuadras de unión sosteniendo el perfil de aluminio. *Elaboración propia.*




**Ilustración 45:** Módulo vertical anclado al perfil mediante conectores. *Elaboración propia.*

Observada y comprobada su estabilidad estructural, se aunarán los dos módulos lineales con el fin de lograr la disposición teórica inicial.




**Ilustración 46:** Conexión real entre las piezas de cada módulo. Elaboración propia.

La *Ilustración 46* muestra la incorporación de los módulos lineales a la estructura, asegurando un anclaje práctico perfecto. Esta configuración permitiría de forma exitosa ajustar la posición de la cámara en ambos ejes, optimizando la captura de imágenes en diferentes condiciones experimentales. Finalmente, se incorporó el diseño de la pieza final que sostendría la cámara individualmente. Ver *Soporte para cámara*.




**Ilustración 47:** Vista cenital de la estructura de sujeción de la cámara. Elaboración propia.

Dado que la distancia entre la guía vertical y el perfil de aluminio transversal es de 10 cm, la pieza en forma de L permitirá a la par abrazar el extremo de la guía y atornillar la cámara desde la zona interior sin que choque con el perfil.




*Ilustración 48: Cámara anclada al módulo. Elaboración propia.*




*Ilustración 49: Estructura vertical del setup. Elaboración propia.*

La última adicción al esqueleto vertical del montaje será una plataforma adaptada para mantener de forma fija los drivers del motor y los cables, ya que la sensibilidad de las conexiones y la facilidad que tienen los cables para soltarse resulta una molestia a la hora de trabajar con el motor. De esta forma, se mantendrá todo fijo, estable, y con la posibilidad de colocarlo donde se quiera.



**Ilustración 50:** Perfil de aluminio con soporte de Arduino y microcontrolador. Elaboración propia.


Además, se hará uso de una urna de libre acceso para mantenerlo libre de polvo y suciedad que pueda afectar a sus pines. Ver *Caja y tapa para Arduino Uno*.



**Ilustración 51:** Montaje final del Arduino y el microcontrolador en la estructura vertical. Elaboración propia.


### ▪ Estructura horizontal

La parte horizontal del setup se encargará de permitir trasladar el motor a lo largo de la cinta. Para lograr esto, se atornillará la guía lineal a mismo perfil de aluminio inicial de la estructura base, el cual fue bajado 20 cm reajustando sus conectores. De esta forma, los cojinetes del carro se introducirán en la misma y gracias al diseño de una última pieza se logrará el objetivo.




*Ilustración 52: Vista trasera de la estructura horizontal. Elaboración propia.*

Para facilitar la incorporación de la guía lineal a los perfiles del laboratorio, hicimos el pedido de la misma con taladramientos en su recorrido. De esta forma, se podría ajustar a los perfiles con tornillos suficientemente pequeños que no chocasen ni con el carro ni con los cojinetes del mismo.



*Ilustración 53: Instalación de guía y carro en el perfil horizontal inicial. Elaboración propia.*

Se dividirá la pieza en dos partes para permitir el atornillado individual tanto del soporte del carro como del motor. Este diseño fue claramente inspirado en el primerizo del montaje inicial, ya que permitió sentar las bases de la estabilidad que se buscaba. Ver *Estructura para motor/carro*.



*Ilustración 54: Estructura horizontal del setup. Elaboración propia.*

## **2.6. Configuración y programación del Arduino y microcontrolador**


Para controlar el motor paso a paso y rotar las aceitunas, se realizarán las conexiones necesarias entre el hardware. Este apartado detalla cómo interactúan estos componentes para garantizar la rotación precisa del motor y cómo se realizan las conexiones específicas.

### **2.6.1. Interacción entre componentes**

El Arduino Uno actúa como el cerebro del sistema, enviando señales de control al microcontrolador TB6600, que a su vez maneja la corriente y dirección del motor paso a paso Nema 17. A su vez, la fuente de alimentación proporciona la energía necesaria para el funcionamiento del motor.

Las señales del Arduino determinan cuándo el motor debe moverse, en qué dirección y cuántos pasos debe dar, permitiendo una rotación controlada y precisa de las aceitunas para la captura de las imágenes.


Por otro lado, el microcontrolador trabaja con microstepping, una técnica que permite subdividir cada paso completo del motor en pasos más pequeños. Esto mejora la resolución del movimiento y permite un control más suave y preciso de la rotación del motor. S1, S2 y S3 controlan los micropasos, mientras que S4, S5 y S6 configuran la corriente del motor. (TB6600 Stepper Motor Driver, 2024)



**Ilustración 55:** Ajuste manual en las pestañas del microcontrolador. *Elaboración propia.*

Para este proyecto, se configuró a 1/16 bajando la pestaña 3 y a 1.5 A bajando la pestaña 4 y 5. El propio microcontrolador tiene una tabla en su carcasa que detalla qué interruptores hay que bajar y subir en función de las necesidades del usuario.

## 2.6.2. Conexiones del hardware



*Ilustración 56: Conexiones del motor con el hardware. Elaboración propia.*

- **ENA+ (Enable+):** Conectado al pin 8 del Arduino. Esta conexión permite habilitar o deshabilitar el motor, esencial para controlar cuándo debe estar activo.
- **ENA- (Enable-):** Conectado a GND del Arduino, completando el circuito de habilitación.
- **DIR+ (Direction+):** Conectado al pin 3 del Arduino. a dirección del motor se controla mediante los pines DIR+ y DIR-. Dependiendo del estado lógico (alto o bajo) del pin DIR+, el motor girará en una dirección específica, horario o antihorario.
- **DIR- (Direction-):** Conectado a GND del Arduino.
- **PUL+ (Pulse+):** Conectado al pin 2 del Arduino. Los pulsos enviados a través de PUL+ determinan los pasos que el motor debe dar. Como se comentó anteriormente, cada pulso corresponde a un micropaso del mismo.
- **PUL- (Pulse-):** Conectado a GND del Arduino, completando el circuito de pulsos.
- **A+ (negro), A- (verde), B+ (rojo), B- (azul):** Conectados a las respectivas salidas del microcontrolador. Las conexiones A+ y A- controlan una bobina del motor, mientras que las conexiones B+ y B- controlan la otra bobina. Estas conexiones

aseguran que el motor reciba las señales correctas para moverse en la dirección y pasos deseados.

- **VCC:** Conectado al terminal VCC del microcontrolador, suministrando la energía necesaria.
- **GND:** Conectado al terminal GND del microcontrolador, completando el circuito de alimentación.

### 2.6.3. Programación y control

Para la programación del Arduino se usará el entorno de desarrollo Arduino IDE, concretamente la versión 2.3.2. Este software proporciona nos permite escribir, compilar y cargar el código en el microcontrolador. El lenguaje de programación empleado es una variante de C/C++ adaptado. El procedimiento sería el siguiente:

```
Iniciar:
    Establecer velocidad máxima del motor
    Establecer la aceleración del motor
    Inicializar la posición actual del motor a 0
Fin

Iniciar Bucle principal:
    Si no se ha completado una vuelta:
        Mover.motor(3200)
        Ejecutar el movimiento hasta alcanzar la posición deseada
        Marcar que se ha completado una vuelta
    Fin
Fin
```

*Código 1: Control arduino y microcontrolador. Elaboración propia.*

El código controla el motor utilizando la librería *AccelStepper* para realizar una única vuelta completa cuando se inicia el sistema. Inicialmente, configura la velocidad máxima y la aceleración del motor, y establece su posición inicial en cero.

Para saber cuántos pasos tiene que dar el motor, se tendrá que revisar en las especificaciones el ángulo de paso del mismo, el cual es de 1.8 grados en este caso. Esto indica que es un motor de 200 pasos por revolución en modo de paso completo.

Para calcular cuántos pasos son necesarios para una vuelta completa utilizando microstepping de 1/16, se usará la siguiente fórmula:

$$\text{Número de pasos}_{360^\circ} = \frac{360^\circ}{1.8^\circ/\text{paso}} = 200 \text{ paso} \cdot \frac{16 \text{ pasos}}{1 \text{ paso}} = 3200 \text{ pasos}$$

En el ciclo principal, el movimiento se ejecuta solo una vez, gracias a una variable de control que evita repeticiones en ciclos subsiguientes del programa. Después de completar la vuelta, el motor se detiene, permitiendo que el programa realice otras tareas si se requieren.

## 2.7. Implementación de la cinta transportadora

El primer paso para la implementación de la cinta transportadora y su motor se detalla en el *Anexo III: Protocolo de control de cinta transportadora*. Para poder hacer un uso preciso de ella, se deberá establecer primero la conexión de red adecuada para garantizar la comunicación efectiva entre el software y el motor Lexium 32 M-S.

Una vez realizada, se procede a utilizar SoMove para controlar e interactuar con la cinta transportadora y su motor. En la interfaz principal se encuentran las especificaciones del hardware. El motor y el drive tienen las siguientes referencias: LXM32MU45M2 para el drive y SHS055P3K1Axx para el motor, con sus respectivos números de serie y versiones de firmware.

Los parámetros de configuración indican una tensión de 230V, una velocidad nominal de 8000 rpm y una velocidad máxima de 9000 rpm, con un par nominal de 95 Ncm y una potencia nominal suministrada de 0.880 kW. El encoder utilizado es SinCos with Hiperface con 128 líneas de resolución. Esta configuración permite un control preciso del motor, adecuado para las necesidades del sistema de captura de imágenes.

| Nombre del eje | <input type="text" value="LEXIUM_SERVO"/> <input type="button" value="Aplicar"/>   |  |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|----------------|--|--|--------------|------------------|-----------------------|---------|------------|-----------------|--------------|------------|-----------------------|-------|-------------|------------|----------|-----------|--------------------|-------|---------------|------------|-----|------------------|--|--------|-------|--|--|--|--|--------|-------|--|--|--|--|--------|--|--|--|--|--------------------|
| Estructura     | <table border="1"> <thead> <tr> <th>Aparato</th> <th>Referencia</th> <th>Número de serie</th> <th>Número de FW</th> <th>Versión FW</th> <th>Nombre del fabricante</th> </tr> </thead> <tbody> <tr> <td>Drive</td> <td>LXM32MU45M2</td> <td>2024008718</td> <td>P0912.00</td> <td>V01.02.05</td> <td>Schneider Electric</td> </tr> <tr> <td>Motor</td> <td>BSH0553Px1Axx</td> <td>2106013006</td> <td>BSH</td> <td>SinCos With HIFa</td> <td></td> </tr> <tr> <td>Slot 1</td> <td>empty</td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td>Slot 2</td> <td>empty</td> <td></td> <td></td> <td></td> <td></td> </tr> <tr> <td>Slot 3</td> <td colspan="4">Bus de campo EtherNet/IP (ETH) V00.00+</td> <td>Schneider Electric</td> </tr> </tbody> </table> |  |              |                  |                       | Aparato | Referencia | Número de serie | Número de FW | Versión FW | Nombre del fabricante | Drive | LXM32MU45M2 | 2024008718 | P0912.00 | V01.02.05 | Schneider Electric | Motor | BSH0553Px1Axx | 2106013006 | BSH | SinCos With HIFa |  | Slot 1 | empty |  |  |  |  | Slot 2 | empty |  |  |  |  | Slot 3 | Bus de campo EtherNet/IP (ETH) V00.00+ |  |  |  | Schneider Electric |
| Aparato        | Referencia   | Número de serie                                  | Número de FW | Versión FW       | Nombre del fabricante |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Drive          | LXM32MU45M2  | 2024008718                                       | P0912.00     | V01.02.05        | Schneider Electric    |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Motor          | BSH0553Px1Axx  | 2106013006                                       | BSH          | SinCos With HIFa |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Slot 1         | empty  |  |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Slot 2         | empty  |  |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Slot 3         | Bus de campo EtherNet/IP (ETH) V00.00+   |  |              |                  | Schneider Electric    |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Configuración  | Tensión  | 1~ 230V  |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Velocidad nominal  | 8000 rpm   |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Par nominal  | 95 Ncm   |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Velocidad máxima   | 9000 rpm   |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Potencia nominal suministrada  | 0.880 kW   |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Freno de parada disponible   | No   |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Encoder  | SinCos with Hiperface: SKS 128 lines single turn |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
|                | Interfaz   | Fieldbus, PTI, PTO, Modbus RTU                   |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |
| Versión de DTM | V1.20.5.1  |  |              |                  |                       |         |            |                 |              |            |                       |       |             |            |          |           |                    |       |               |            |     |                  |  |        |       |  |  |  |  |        |       |  |  |  |  |        |  |  |  |  |                    |

**Ilustración 57:** Interfaz de Somove. Elaboración propia.

Una vez comprobada y establecida la conexión con la cinta, se seleccionarán los parámetros de conexión, control de velocidad y sentido.

|        |  |        |  |   |   |
|--------|--|--------|--|---|---|
| Excl.  | Estado operacional   | Etapas | Modos de funcionamiento  | Continuar   | Regulación  |
| On     | <input checked="" type="checkbox"/> POWER ENABLED<br><input checked="" type="checkbox"/> [6] Operation Enabled | On     | Profile Velocity <input type="text" value="-4 [1rpm]"/> Target speed<br>Ramp profile <input type="radio"/> Profile Off <input checked="" type="radio"/> Profile On<br>Max. Acc. <input type="text" value="100 [1rpm/s]"/><br>Max. Decel. <input type="text" value="100 [1rpm/s]"/> | <input type="button" value="Inicio"/><br><input type="button" value="Parada"/><br><input type="button" value="Parada"/> | <input type="button" value="CTRL 1"/> <input type="button" value="CTRL 2"/><br><input type="checkbox"/> Forza |
| Apa    | <input type="button" value="Quick Stop"/>  | Apa    |  |   |   |
| Online | Equipo/registro de datos   |        | Equipo OK  |   |   |

**Ilustración 58:** Panel de control de la cinta. Elaboración propia.

En la sección superior izquierda se indican el estado operacional del dispositivo con "POWER ENABLED" y "Operation Enabled" en verde, lo cual significa que el motor está listo para operar. Justo debajo, se encuentra el botón de "Quick Stop" que permite detener el motor rápidamente en caso de emergencia.

En la parte central de la pantalla, se selecciona el modo de funcionamiento "Profile Velocity", lo que significa que el control de velocidad se realizará mediante un perfil de velocidad definido manualmente. Se configura la "Target Speed" en -4 rpm (el signo determina el sentido de la cinta), y los valores de aceleración y deceleración máxima se establecen en 100 rpm/s. Esta configuración se ha elegido para controlar de manera precisa la velocidad del motor, permitiendo un arranque y parada suaves, con el fin de coordinarlo con el software de captura, Spectronon.

### 3. Diseño y desarrollo software

Es crucial contar con una metodología de desarrollo de software bien definida para asegurar que el proyecto cumpla con sus objetivos de calidad en tiempo de vida útil del fruto. En este apartado, se detallará el proceso seguido para la selección de muestras, adquisición de datos espectrales, procesamiento y análisis de datos, desarrollo de modelos predictivos y la validación de los mismos.

En primer lugar, se procederá a la selección de muestras, donde se elegirán aceitunas de mesa con distintos tipos de daños, tanto visibles como no visibles al ojo humano. Esto se hace con el fin de crear un conjunto diverso de muestras que represente adecuadamente las posibles condiciones del fruto. Para ello, se utilizarán aceitunas de la variedad picual, proporcionadas por el Centro Tecnológico del Olivar y del Aceite, ubicado en Mengíbar, Jaén.

Posteriormente, se llevará a cabo la adquisición de datos espectrales utilizando el software de captura. Los datos se capturarán en dos formatos principales:

- **.bil (Band Interleaved by Line):** este formato almacena los datos de imagen con las bandas dispuestas línea por línea. Cada línea de la imagen se escribe sucesivamente por banda, lo que facilita el acceso a los datos espectrales completos de una línea específica de píxeles sin necesidad de leer el archivo completo.
- **.hdr (Header File):** el archivo de cabecera .hdr acompaña al archivo .bil, proporcionando metadatos esenciales sobre la imagen. Estos metadatos incluyen información como el número de bandas, el tipo de datos, las dimensiones de la imagen, y otros parámetros necesarios para la correcta interpretación de los datos. El archivo .hdr es crucial porque sin él, el archivo .bil sería difícil de interpretar y procesar correctamente, ya que no se podría determinar la estructura exacta de los datos almacenados.

El siguiente paso es el procesamiento y análisis de datos. Los datos recopilados se procesarán utilizando MATLAB, donde se desarrollarán códigos específicos para la lectura y posterior procesamiento de estos datos. Este proceso incluirá la normalización de los datos, la eliminación de ruido potencial y la aplicación de algoritmos para extraer características relevantes.

Con los datos ya procesados, se procederá al desarrollo de modelos predictivos. Utilizando herramientas de predicción y clasificación, se crearán modelos que permitan detectar daños potenciales en las muestras de aceitunas. Estas herramientas facilitan la implementación de algoritmos avanzados que pueden identificar patrones y anomalías en los datos espectrales.

Finalmente, se realizará la validación del modelo. Este paso es fundamental para asegurar que los modelos predictivos desarrollados funcionen correctamente. Se llevará a cabo una validación tanto visual como algorítmica para comprobar que los modelos han sido entrenados adecuadamente y que alcanzan el nivel de precisión deseado. La validación garantiza que el sistema puede identificar daños en las aceitunas con un alto grado de confianza, asegurando así la calidad del proceso de detección.

### **3.1. Software de captura**


Spectronon fue la elección para el proyecto debido a su compatibilidad y capacidad para manejar datos complejos. Este software de uso libre, proporcionado por Resonon, incluye herramientas avanzadas para la calibración y corrección de imágenes. Permite visualizar, analizar y exportar datos hiperespectrales en formatos compatibles con otras herramientas de análisis, como MATLAB o Python. (Resonon, 2024)

#### **3.1.1. Enfoque**

El enfoque de la lente es el primer paso para poder utilizar el software. Se retira la tapa del objetivo de la misma y se asegura el usuario de que la apertura del diafragma ( $f\#$ ) esté en una posición igual o menor a la especificación de la cámara, en el caso de la Pika L, esta es 2.4. De este modo se asegura una apertura adecuada para el paso correcto de la luz a través de la lente.

A continuación, se hace clic en el botón "F" de la barra de herramientas en la parte superior de la pantalla. El botón debe volverse rojo, indicando que el modo de enfoque está activo. Este modo permite ajustar la lente en tiempo real, facilitando el proceso de enfoque al proporcionar una vista en vivo de la imagen. A continuación, se debe ver una ventana de vista en vivo (LVW) en el centro de la pantalla.

En la pestaña "Controles" dentro de la ventana "Herramientas", se hace clic en la casilla "Auto Update". Esto permite que la vista en vivo se actualice automáticamente con cualquier cambio de configuración, asegurando que los ajustes de enfoque se reflejen instantáneamente.




**Ilustración 59:** Función Auto Update de Spectronon. Elaboración propia.

Se selecciona la pestaña "Cámara" en la ventana de herramientas y se aumenta el tiempo de integración hasta que aparezca una barra blanca en la ventana de vista en vivo. El tiempo de integración determina la cantidad de luz que entra al sensor durante la captura de la imagen. Ajustar este tiempo es crucial para obtener una imagen bien iluminada y detallada. El tiempo de integración es el período durante el cual el sensor de la cámara recoge luz.

Un mayor tiempo de integración permite la captura de más luz, resultando en imágenes más brillantes, mientras que un tiempo de integración más corto reduce la cantidad de luz capturada, produciendo imágenes más oscuras. Se necesita garantizar que las imágenes de las aceitunas sean claras y tengan suficiente detalle para el análisis posterior.

Se coloca una hoja de enfoque dentro del campo de visión, asegurándose de que esté orientada perpendicularmente a la longitud de la rendija del imager. Esta hoja de enfoque tiene patrones que ayudan a visualizar claramente si la imagen está enfocada correctamente.



*Ilustración 60: Enfoque de la cámara. Elaboración propia.*


Se enfoca la lente del objetivo hasta que las líneas de la hoja de enfoque sean claramente visibles en la ventana de vista en vivo. Esto se realiza girando el anillo de enfoque de la lente. Verificar las líneas ayuda a asegurarse de que la imagen capturada esté nítida y clara. Finalmente, se activa el eje X en la ventana de gráficos haciendo clic en la pestaña "X". Esto permite visualizar los datos espectrales de las líneas negras de la hoja para buscar las zonas de mayor ruido.

### **3.1.2. Calibración**

La calibración de los equipos de adquisición de imágenes hiperespectrales es otro paso crucial para garantizar la precisión y fiabilidad de los datos obtenidos. Una calibración adecuada permite corregir cualquier variación o sesgo inherente al sistema de captura, asegurando que las mediciones reflejen fielmente las propiedades espectrales de las muestras analizadas.

Sin una calibración precisa, los datos espectrales podrían estar contaminados por artefactos y errores que comprometerían la validez de los resultados y, por ende, la eficacia de los modelos predictivos desarrollados a partir de ellos.

El primer paso para la calibración es la captura de una imagen de oscuridad. Para ello, se cierra la tapa del objetivo de la cámara para evitar la entrada de luz. Este proceso permite capturar una imagen que refleja únicamente el ruido electrónico inherente al sistema. Se hará uso de “Record dark current correction”.



*Ilustración 61: Calibración para referencia oscura. Elaboración propia.*

A continuación, se realiza la calibración de referencia blanca colocando un panel de referencia blanca frente a la cámara, asegurándose de que esté bien iluminado y que ocupe todo el campo de visión, así se corrigen las variaciones en la iluminación y asegura la precisión de los datos espectrales. Se hará uso de “Record response correction”.

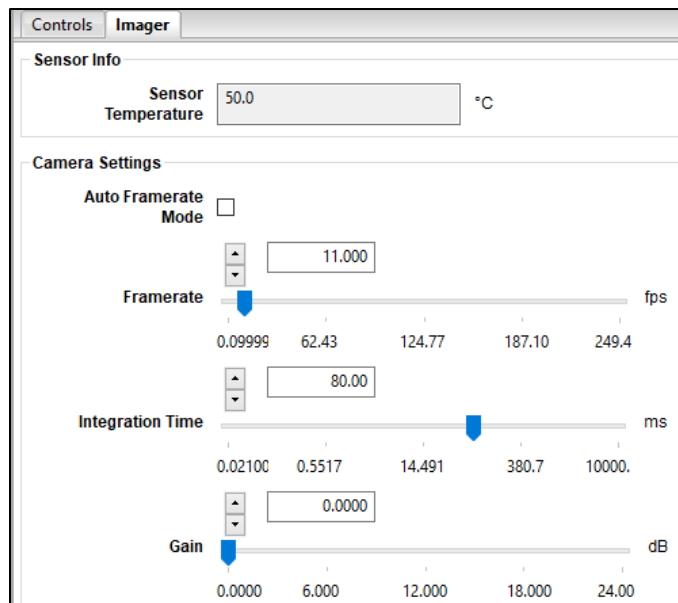


*Ilustración 62: Calibración para referencia blanca. Elaboración propia.*

Tras realizar ambas calibraciones, se recomienda capturar una imagen de prueba para verificar la precisión de la calibración, asegurándose de que no haya anomalías y que los datos espectrales sean consistentes. Finalmente, se guardan los datos de calibración en el software para que se apliquen automáticamente las correcciones necesarias a todas las imágenes capturadas posteriormente.

### **3.1.3. Captura experimental**

Spectronon permite ajustar varios parámetros de la cámara, como la velocidad de fotogramas (framerate), el tiempo de integración y la ganancia. Estas configuraciones son cruciales para asegurar que las imágenes capturadas sean de alta calidad y adecuadas para el análisis espectral detallado. Para cada caso de estudio se seleccionarán unos específicos.

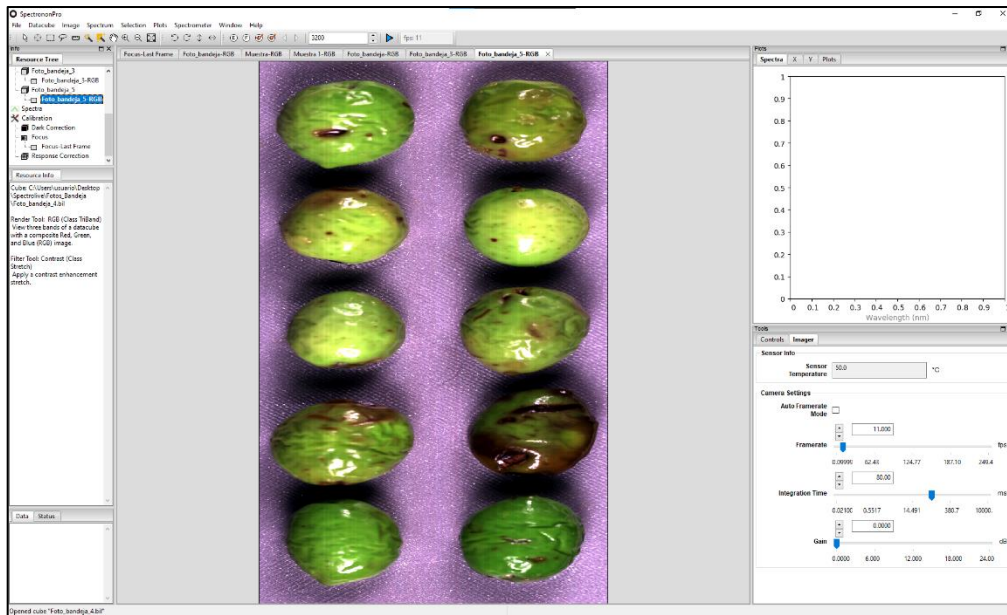


*Ilustración 63: Configuración de la cámara. Elaboración propia.*

- **Framerate.** Permite un equilibrio entre la cantidad de datos capturados y la calidad de la imagen. Se obtendrán imágenes claras y detalladas sin sobrecargar el sistema con demasiada información. Los fotogramas por segundo están relacionados con las líneas de captura porque determinan cuántas líneas de datos se pueden adquirir por segundo.
- **Tiempo de integración.** Un mayor tiempo de integración permite capturar más luz, resultando en imágenes más brillantes y con más detalle. Sin embargo, tiempos de integración excesivamente largos pueden provocar saturación y pérdida de información.
- **Ganancia.** Una ganancia de 0 dB significa que no se amplificó la señal adicionalmente. Un ajuste de ganancia inapropiado puede introducir ruido en la imagen, por lo que mantenerla baja es generalmente preferible para asegurar la calidad de la imagen.

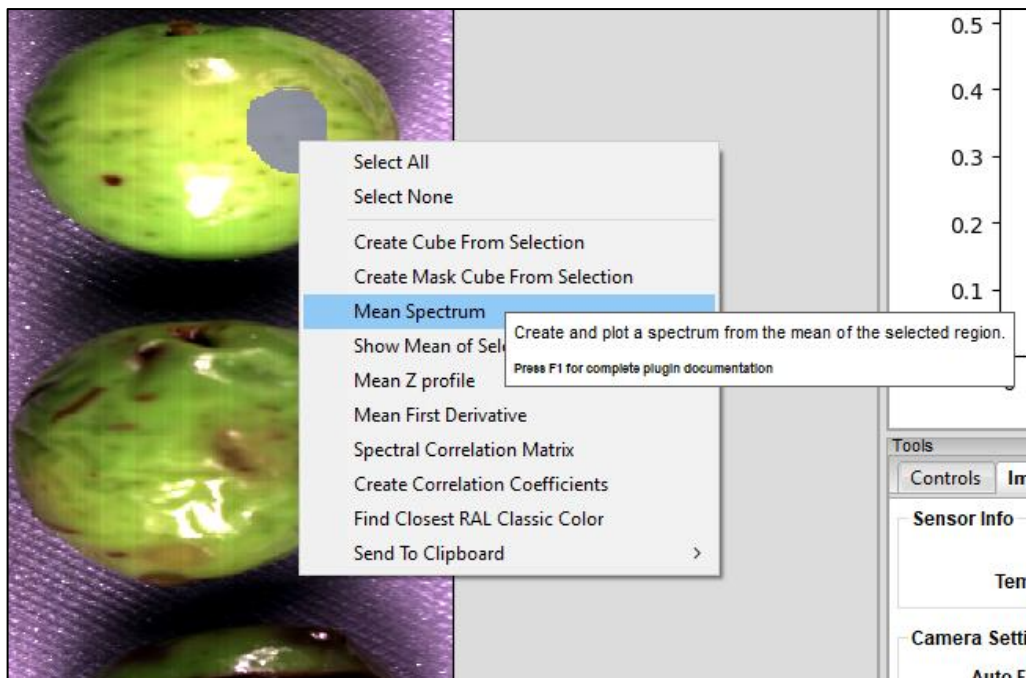
### 3.1.4. Interfaz

La interfaz principal muestra las imágenes capturadas, permitiendo una inspección detallada de las mismas. En la *Ilustración 64*, se puede observar la disposición de las aceitunas bajo la cámara hiperespectral, mostrando cómo el software presenta los datos capturados en una vista clara y detallada.



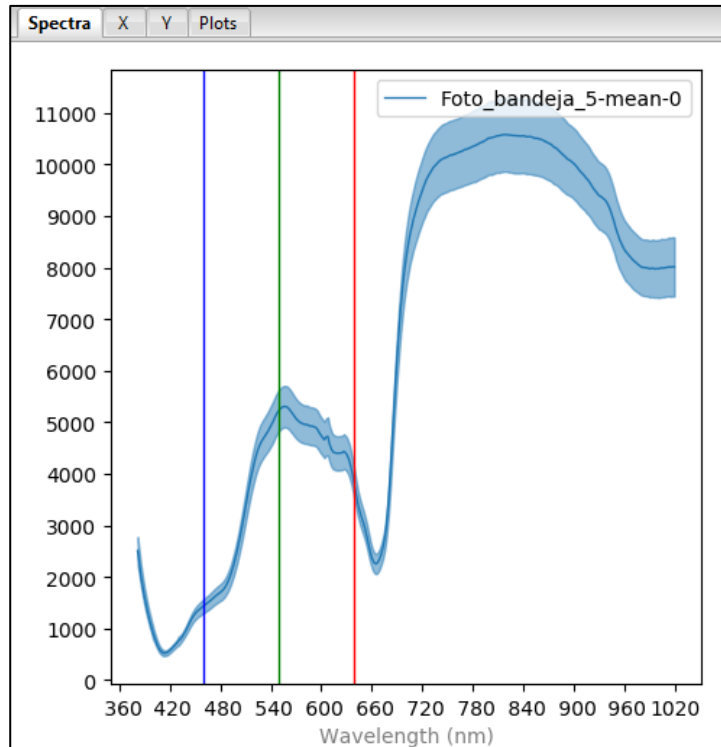
**Ilustración 64:** Interfaz principal de Spectronon. Elaboración propia.

Spectronon permite generar y visualizar espectros a partir de las imágenes capturadas. Por ejemplo, al seleccionar una región de interés en la imagen, se puede calcular el espectro medio de esa región. Este espectro proporciona información detallada sobre las propiedades espectrales del objeto analizado.



**Ilustración 65:** Función Mean Spectrum. Elaboración propia.

La función "Mean Spectrum" permite crear y trazar un espectro a partir del promedio de una región seleccionada. Esto es útil para obtener una visión general de las características espectrales del área seleccionada, facilitando el análisis comparativo y la interpretación de los datos espectrales.



**Ilustración 66:** Gráfica espectral de la zona estudiada. Elaboración propia.

El eje horizontal muestra la longitud de onda de la luz capturada, que generalmente abarca un rango desde el ultravioleta hasta el infrarrojo cercano. En la gráfica, este rango va aproximadamente desde 360 nm hasta 1020 nm. Cada punto en el eje horizontal representa una longitud de onda específica de la luz reflejada o emitida por el objeto. Por otro lado, el eje vertical indica la intensidad de la señal, que refleja la cantidad de luz capturada en cada longitud de onda. Valores más altos en el eje vertical indican mayor intensidad de la luz en esa longitud de onda específica.

La curva azul en la gráfica representa el espectro medio de la región seleccionada del fruto. Esta curva muestra cómo varía la intensidad de la luz en función de la longitud de onda. Las áreas sombreadas alrededor de la curva indican la variabilidad o incertidumbre en la medición. Los picos en la curva representan longitudes de onda donde la reflectancia o emisión de luz es alta, mientras que los valles indican longitudes de onda con baja reflectancia o emisión. Estos picos y valles son característicos del material y pueden ser utilizados para identificar y buscar separabilidad entre clases.

## 3.2. Técnicas de adquisición de imágenes

La adquisición de imágenes hiperespectrales en este proyecto se realizó mediante dos métodos principales: la rotación de la aceituna usando un motor paso a paso y la captura de imágenes de múltiples aceitunas dispuestas en una bandeja.

Con el fin de añadir el juicio de valor experimental, se concluirá cada método con una tabla que resumirá las principales ventajas y desventajas encontradas.


### 3.2.1. Rotación de la aceituna

Metodología perteneciente al *Montaje preliminar*, donde las aceitunas se rotan usando un motor paso a paso para capturar imágenes de toda su superficie, ver *Ilustración 38*. Este procedimiento se realiza de la siguiente manera:

El eje motor paso a paso se conecta al *Soporte para aceituna*, sujeto a su vez al perfil de aluminio gracias al *Soporte para motor*. El diseño del soporte incluye un clip central que pinchará la aceituna, asegurando una rotación precisa sin desplazamientos indeseados. Ver *Ilustración 54*.

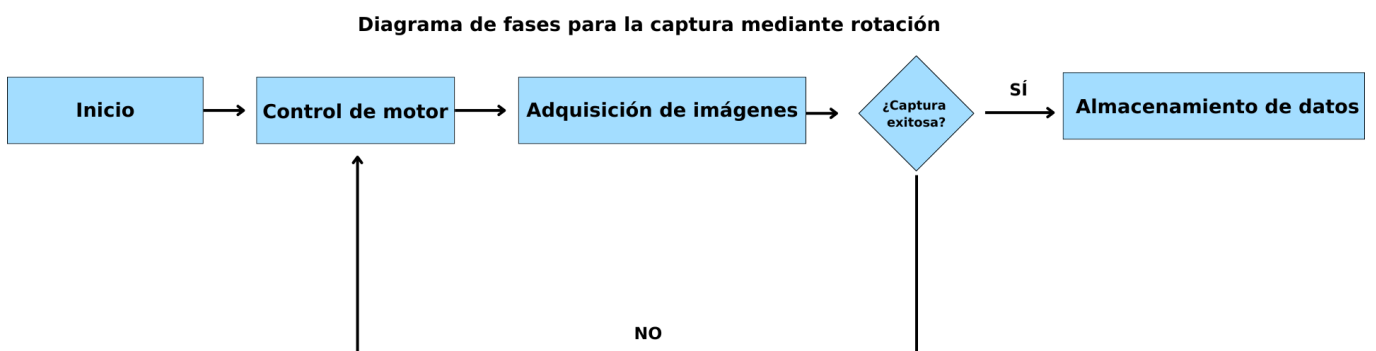
El diagrama de fases que describe la metodología procede de la siguiente manera:

1. **Inicio.** Se inicializa el software de control.
2. **Control del motor.** La rotación del eje del motor se controla mediante un Arduino. El código desarrollado permite una rotación completa de 360°, después de la cual el sistema entra en un estado de espera hasta que el usuario vuelva a ejecutar el script desde la interfaz de Arduino IDE.
3. **Adquisición de imágenes.** La captura de imágenes se realiza de manera manual y par a la rotación del motor a 750 líneas. Mientras se ejecuta el script del Arduino, el usuario debe presionar el botón de captura en el software Spectronon. En caso de error, el usuario espera a que finalice la rotación y vuelve a intentar la captura hasta obtener una imagen completa del fruto.



**Ilustración 67:** Captura experimental de aceitunas en lote por rotación, proyecto Espectrolive. Elaboración propia.

- 4. Almacenamiento de datos.** Una vez capturado el hipercubo, se guarda en formatos .bil y .hdr para su posterior análisis. Se utiliza un formato numerado para facilitar el análisis iterativo y uniforme de los lotes, asegurando una clasificación detallada de cada fruto y su correspondiente fitosanitario.



**Ilustración 68:** Diagrama de fases para la captura mediante rotación. Elaboración propia.

| CAPTURA POR ROTACIÓN   |  |
|--|--|
| Ventajas   | Desventajas  |
| Alta resolución de imágenes  | Proceso más lento debido a la rotación individual de cada aceituna   |
| Captura detallada de toda la superficie de la aceituna               | Mayor complejidad en la sincronización manual de captura de imágenes |
| Análisis preciso de daños en cada aceituna individual                | Menor eficiencia para el análisis de grandes lotes                   |
| Proporciona datos precisos para el desarrollo de modelos predictivos | Caída del fruto por derretimiento con la exposición al calor         |

**Tabla 1:** Ventajas y desventajas de la captura por rotación. *Elaboración propia.*

Aunque este método proporciona datos de muy alta resolución, ideales para el entrenamiento de modelos predictivos y el análisis detallado de cada fruto, su aplicación práctica en un entorno industrial presenta limitaciones. Este método es más lento y requiere una mayor intervención manual, lo que lo hace menos eficiente para el análisis de grandes lotes de aceitunas.

Para simular un entorno de almazara y analizar lotes completos de aceitunas de manera eficiente, sería más adecuado optar por un método que permita el análisis simultáneo de múltiples frutos. Este enfoque no solo incrementará la velocidad del proceso, sino que también permitirá una evaluación más representativa y práctica en aplicaciones industriales.


### 3.2.2. Traslación de la aceituna

El método de translación de la aceituna implica la captura de imágenes en lotes de frutos dispuestos en una bandeja que se mueve a través del campo de visión de la cámara.

En este caso tendremos 10 aceitunas más por hipercubo que por rotación, 20 muestras en total sumando las dos caras de cada una. Este procedimiento se realiza de la siguiente manera:

- 1. Inicio.** Se inicializa el software de control.

2. **Control de cinta.** La cinta se pone en marcha continua, asegurando un movimiento constante y controlado mediante Somove, con una velocidad establecida en 4 rpm.
3. **Adquisición de imágenes.** Se coloca la bandeja con las aceitunas y se traslada con la cinta ya en marcha. El usuario debe capturar las imágenes a 3200 líneas cuando las aceitunas están dentro del rango óptimo de la cámara para asegurar una calidad de imagen adecuada, por lo que manualmente deberá calcular el momento adecuado, con la posibilidad de iterar de nuevo en caso de error. Después, se les da la vuelta y se vuelve a capturar.



*Ilustración 69: Captura de lotes de aceitunas con la bandeja. Elaboración propia.*

4. **Almacenamiento de datos.** Una vez capturadas las imágenes, los datos se guardan en formatos .bil y .hdr para su posterior análisis. Los archivos se numeran para facilitar el análisis iterativo y uniforme de los lotes, asegurando una clasificación detallada de cada pasada.

Diagrama de fases para la captura mediante traslación

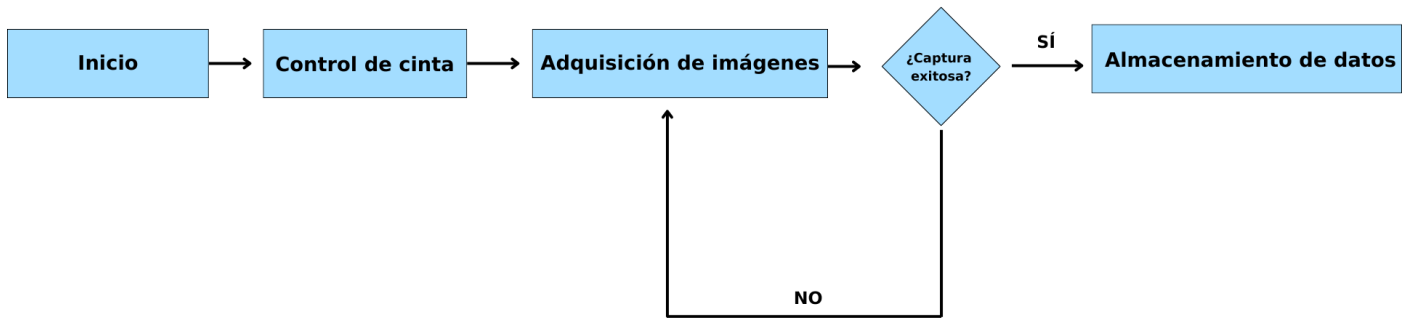


Ilustración 70: Diagrama de fases para la captura mediante traslación. Elaboración propia

| CAPTURACIÓN POR TRASLACIÓN                            |   |
|---|---|
| Ventajas  | Desventajas   |
| Permite el análisis simultáneo de múltiples aceitunas | Menor resolución en comparación con el método de rotación               |
| Mayor eficiencia en el análisis de grandes lotes      | Mayor complejidad en la segmentación de imágenes                        |
| Simula un entorno industrial de almazara              | Posible variabilidad en la iluminación debido al movimiento de la cinta |
| Doble de imágenes por aceituna                        | Posibilidad de superposición de imágenes                                |

Tabla 2: Ventajas y desventajas de la captura por traslación. Elaboración propia.

El método de traslación de aceitunas se destaca por su capacidad para analizar múltiples frutos simultáneamente, lo que lo hace mucho más eficiente en comparación con el método de rotación individual. Este enfoque es especialmente beneficioso en un entorno industrial, como una almazara, donde la rapidez y eficiencia en el procesamiento de grandes lotes son cruciales. Además, el método permite realizar dos pasadas por aceituna, capturando imágenes de ambas caras, lo que mejora la cobertura y precisión del análisis.

La ventaja significativa del método de traslación es su idoneidad para el preprocesado de datos, ya que facilita la obtención de imágenes uniformes y consistentes de grandes cantidades de aceitunas.

### 3.3. Procesamiento y análisis de datos

Para el procesamiento y análisis de los datos en el proyecto se optó por utilizar MATLAB en lugar de otros lenguajes de programación como Python. Esta elección se fundamenta en varias razones técnicas y prácticas que hacen de esta una herramienta especialmente adecuada para trabajar con datos en forma de matrices, como es el caso de los hipercubos.

Un hipercubo hiperespectral es esencialmente una colección de imágenes bidimensionales tomadas en diferentes longitudes de onda. Esto se puede conceptualizar como una matriz tridimensional donde dos dimensiones representan las coordenadas espaciales ( $x$ ,  $y$ ) y la tercera dimensión representa las distintas bandas espectrales ( $\lambda$ ). La naturaleza matricial de los hipercubos hace que MATLAB, con su capacidad optimizada para manejar y operar matrices, sea una opción ideal para este tipo de análisis. (MathWorks, 2024)

Cada elemento del hipercubo  $H(x,y,\lambda)$  contiene la información de reflectancia o intensidad de un píxel en una longitud de onda específica. Esta estructura permite el análisis detallado de las propiedades espectrales y espaciales de las muestras capturadas.

MATLAB permite realizar operaciones como la extracción de espectros de píxeles individuales, la aplicación de filtros espectrales y espaciales, y la implementación de algoritmos de clasificación y análisis de datos hiperespectrales con gran facilidad. Además, la integración de funciones y bibliotecas para el manejo de grandes matrices asegura que el procesamiento de hipercubos sea rápido y eficiente, lo cual es crítico en proyectos que involucran grandes volúmenes de datos.

#### 3.3.1. Toolboxes utilizadas

Para el procesamiento y análisis de datos en este proyecto, se utilizaron varias toolboxes de MATLAB debido a sus capacidades específicas y avanzadas que facilitan el trabajo con matrices y datos espectrales. A continuación, se detalla la razón de uso de cada una junto con su disponibilidad y posibles dependencias. El proceso de instalación de las mismas se detalla en el *Anexo IV: Instalación de paquetes y librerías*.

## 1. Image Processing Toolbox

- **Versión:** 24.1
- **Descripción:** proporciona un conjunto integral de algoritmos estándar de referencia y herramientas de flujo de trabajo para el procesamiento, análisis y visualización de imágenes. Es fundamental para el preprocesamiento de datos. Utilizada para mejorar la calidad de las imágenes y extraer características significativas. (MathWorks, 2024)
- **Disponibilidad:** desde R2021a.
- **Dependencias:** independiente.

## 2. Computer Vision Toolbox

- **Versión:** 24.1
- **Descripción:** proporciona algoritmos, funciones y apps para diseñar y probar sistemas de visión por computadora. Crucial para tareas como la detección de objetos, la estimación de movimiento y la reconstrucción 3D. (MathWorks, 2024)
- **Disponibilidad:** desde R2011a.
- **Dependencias:** *Image Processing Toolbox*.

## 3. Image Processing Toolbox Hyperspectral Imaging Library

- **Versión:** 24.1.0
- **Descripción:** específicamente diseñada para el procesamiento de datos. Proporciona funciones para manejar, visualizar y analizar hipercubos. Facilita la manipulación de datos hiperespectrales, incluyendo la calibración y corrección espectral, además de herramientas específicas para el análisis y la interpretación de los mismos. (MathWorks, 2024)
- **Disponibilidad:** desde R2020a.

- **Dependencias:** *Image Processing Toolbox*.

#### 4. Statistics and Machine Learning Toolbox

- **Versión:** 24.1
- **Descripción:** ofrece herramientas y funciones para describir, analizar y modelar datos. Incluye algoritmos de estadística descriptiva, inferencia, y aprendizaje automático. Crucial para el desarrollo de modelos predictivos basados en los datos hiperespectrales. Proporciona métodos estadísticos para interpretar los resultados del procesamiento de imágenes y datos. (MathWorks, 2024)
- **Disponibilidad:** desde R2021a.
- **Dependencias:** Independiente.

Se utilizó la versión R2024a, ya que es la que permite usar todas las toolboxes mencionadas en su versión más actualizada. Sin embargo, dado que esta versión es de pago, se hizo uso de la versión de prueba mensual que se puede obtener a través de la web de MathWorks utilizando el correo académico de la Universidad.


#### 3.3.2. Muestras de aceituna empleadas en la experimentación

El estudio comenzó con la captura de lotes de aceitunas contaminadas recibidas para el proyecto Espectrolive. La finalidad es evaluar si esta tecnología puede discriminar entre aceitunas dopadas con diferentes fitosanitarios en varias concentraciones. A continuación, se describen los fitosanitarios analizados y los niveles de contaminación observados en las muestras:

- **Diflufenican:** 5 bolsas. Desde 0.05 mg/kg hasta 31.8 mg/kg, comparados con el límite máximo de residuo (LMR) de la UE de 0.6 mg/kg.
- **Oxifluorfen:** 4 bolsas. Variaron entre 1.12 mg/kg y 72.3 mg/kg, superando el LMR de 1 mg/kg establecido por la UE.
- **Deltametrina:** 4 bolsas. Desde 0.77 mg/kg hasta 19.1 mg/kg, excediendo el LMR de 0.6 mg/kg de la UE.

- **Lambda Cihalotrina:** 5 bolsas. Entre 0.95 mg/kg y 84.9 mg/kg, superando el LMR de 0.5 mg/kg según la normativa de la UE.
- **Tebuconazol:** 5 bolsas. Desde 1.29 mg/kg hasta 116 mg/kg, con un LMR de 0.5 mg/kg establecido por la UE.
- **Sin tratar:** 1 bolsa. Referencia del fruto base sin contaminar.

De cada bolsa se analizaron por rotación 10 aceitunas, obteniendo una base de datos equivalente a 240 imágenes. Con el fin de establecer la normalización de la misma, se establecerán acortamientos para cada fitosanitario, añadiendo a qué bolsa pertenecen y el número de aceituna. Por ende, la muestra “Diflu\_1\_1” pertenecería a la primera aceituna de la bolsa número 1 dopada con diflufenican.



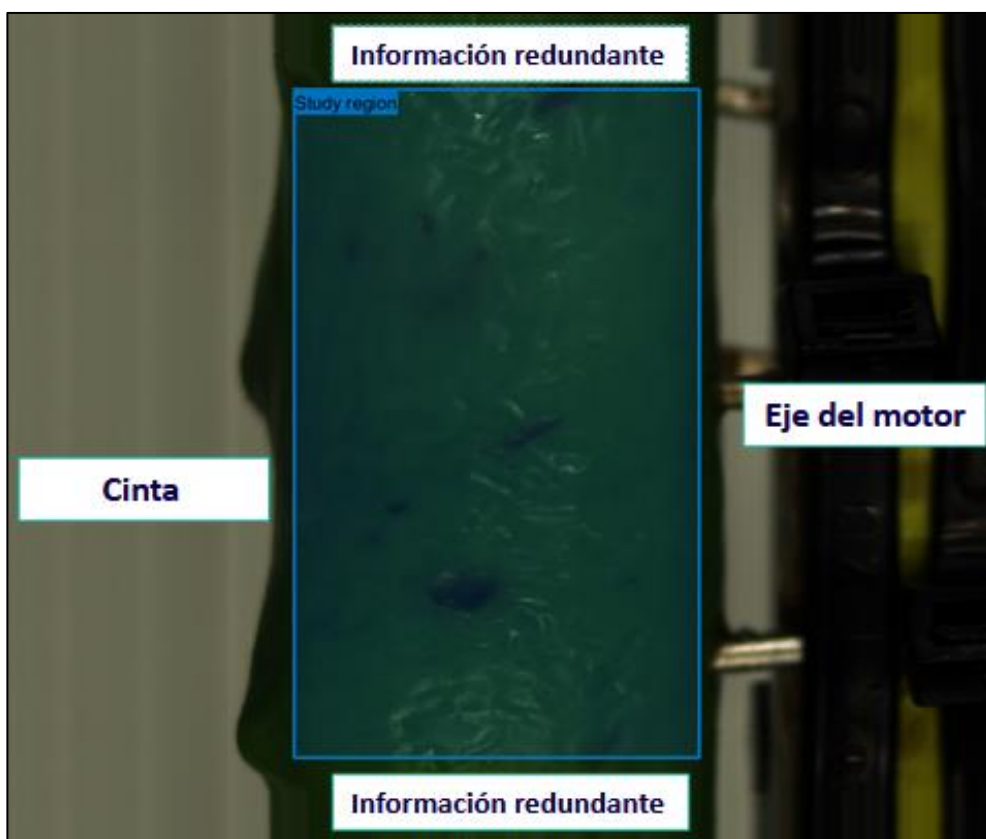
*Ilustración 71: Aceituna rotada, vista en Spectronon. Elaboración propia.*

En la imagen hiperespectral de una aceituna rotada obtenida mediante una cámara lineal, existen varias áreas que contienen información no relevante o redundante que debemos excluir para un análisis preciso:

- **Cinta transportadora:** aparece en el lado izquierdo de la imagen. Esta área no aporta información relevante sobre la aceituna y puede introducir ruido en el análisis.
- **Eje del motor:** aparece en el lado derecho de la imagen. Similar a la cinta, el eje del motor no contiene información útil sobre la calidad o condición de la aceituna.

- **Líneas repetidas:** parte superior e inferior de la imagen. Pueden capturar repetidamente secciones de la aceituna debido a la rotación, lo que introduce datos duplicados que no son útiles para el análisis.

Esto provoca una limitación significativa a la hora de procesar las imágenes, debido a la imposibilidad de usar el hipercubo al completo. Para solucionar este problema, se hará uso una Región de Interés (ROI) que contenga únicamente la información relevante sobre la aceituna. Esto se logra mostrando en RGB la aceituna por pantalla y posteriormente el usuario manualmente seleccionará la zona a estudiar.



*Ilustración 72: Información innecesaria en imagen rotada. Elaboración propia.*

Una vez entendida la forma de trabajar con este formato, se buscará una forma eficiente de encontrar posible separabilidad entre clases. Una opción viable sería hacer un estudio de la escala de grises de cada píxel de las capturas. Para ello, se calculará la media y desviación típica de este parámetro para cada bolsa individual para posteriormente compararlo gráficamente con las muestras dopadas. El proceso sería tal que:

```
Iniciar:  
    Establecer configuración inicial (ruta base, tamaño de muestra,  
dimensiones, número de bandas, número de bolsas)  
    Cargar datos de control (medias y desviaciones)  
Fin  
  
Función ProcesarMuestra():  
    Para cada fitosanitario en lista de fitosanitarios:  
        Configurar Entorno de Fitosanitario  
        Procesar Bolsas(fitosanitario_actual)  
    Fin  
Fin  
  
Iniciar:  
    Generar(reporte_final)  
Fin
```


*Código 2: Análisis y media de grises de las aceitunas dopadas rotadas. Elaboración propia.*

En primer lugar, se define la ruta base donde se encuentran las carpetas de datos, el tamaño de las muestras, las dimensiones de las imágenes, y el número de bandas espectrales. Además, se establece el número de bolsas de aceitunas que se van a procesar. Los datos de control, que consisten en medias y desviaciones estándar, se cargan desde archivos CSV utilizando la función `readmatrix`. Esto se utiliza para establecer los límites superior e inferior de control, que se calcularán sumando y restando la desviación estándar a la media respectivamente. A continuación, se inicializan varias estructuras de datos. Se crean listas de fitosanitarios y sus abreviaturas correspondientes. También se preparan celdas para almacenar la información de los hipercubos, matrices para las medias de grises, y matrices para las coordenadas de las regiones de interés (ROI).

El código recorrerá cada fitosanitario en la lista. Para cada fitosanitario, se itera sobre cada bolsa. Se construye el nombre de la bolsa actual y se verifica si la carpeta correspondiente existe utilizando las funciones `exist` y `fullfile`. Si la carpeta no existe, se muestra un mensaje informativo y se continúa con la siguiente bolsa.

Para cada muestra en la bolsa, se muestra un mensaje con el fitosanitario actual, el número de bolsa y el número de hipercubo que se está procesando. Se leen los archivos `.bil` y `.hdr` correspondientes a la muestra utilizando las funciones `sprintf`, `enviinfo` y `multibandread`. La información del hipercubo y su metadata se almacenan en las estructuras previamente inicializadas.

Luego, se convierte el hipercubo a una imagen RGB para su visualización. Se seleccionan bandas específicas para los canales rojo, verde y azul, y se concatenan en una imagen utilizando la función `cat`. Esta imagen se normaliza para su visualización con las funciones `uint8` y `double`.



**Ilustración 73:** Selección de la región de interés con `ginput`. Elaboración propia.

Para seleccionar la región de interés (ROI), se muestra la imagen RGB y se solicita al usuario que seleccione la esquina superior izquierda de la región de interés utilizando la función `ginput`. Se valida que la región seleccionada esté dentro de los límites de la imagen. Si no es así, se muestra un mensaje de error y se solicita una nueva selección. Una vez que la selección es válida, se recorta la región de interés del hipercubo.

Las coordenadas de la ROI seleccionada se almacenan, y se calculan y almacenan las medias de grises de la ROI para cada banda utilizando la función `mean2`.


Después de procesar todas las muestras en una bolsa, se guardan los datos de las medias de grises y las coordenadas en archivos CSV utilizando la función `writematrix`. Además, se calculan la media y la desviación estándar de los valores de grises para la bolsa actual.

Finalmente, se generan gráficos comparativos entre la media de la bolsa y la media de control. Se crean áreas de desviación estándar para ambos conjuntos de datos y se trazan en el gráfico utilizando las funciones `fill` y `plot`. El gráfico se configura con etiquetas, leyendas y se guarda en archivos `.fig` y `.jpg`.

### 3.4. Entrenamiento de los modelos

#### 3.4.1. Entorno: Pequeña escala

El objetivo del entrenamiento fue desarrollar un sistema capaz de identificar y clasificar aceitunas en función de su moleestado. Se optó por un enfoque de aprendizaje supervisado que permite etiquetar manualmente las regiones de interés y entrenar el modelo con una base de datos manualmente supervisada. Se utilizó un conjunto de datos etiquetados para entrenar el modelo a diferenciar entre aceitunas en buen estado (OK) y moleestado (KO).



*Ilustración 74: Entrenamiento OK vs KO. Elaboración propia.*

Para el entrenamiento del modelo se utilizó la herramienta Classification Learner Toolbox, perteneciente a *Statistics and Machine Learning Toolbox*. Esta herramienta proporciona una interfaz gráfica que permite seleccionar, entrenar y comparar diferentes algoritmos de clasificación de manera eficiente.

Para evaluar el rendimiento del modelo se empleó en todos los casos una validación holdout, reservando el 10% de los datos para la validación. Este porcentaje se seleccionó porque ofrece un equilibrio entre el tamaño del conjunto de entrenamiento y la capacidad de evaluar el modelo en datos no vistos, lo que es crucial para asegurar que el modelo generalice bien a nuevas muestras.

El primer código tuvo como objetivo pues procesar las imágenes de aceitunas tratadas con diferentes fitosanitarios, seleccionar manualmente regiones de interés (ROI), etiquetar estas regiones y consolidar los datos para el entrenamiento de modelos de clasificación. A continuación, se describe su funcionamiento en detalle.

```
Iniciar:  
    Establecer configuración inicial (rutas de base y destino, tamaño de  
muestra, dimensiones, número de bandas, número de bolsas)  
    Inicializar contador y estructuras de datos  
Fin  
  
Función ProcesarMuestra():  
    Para cada fitosanitario:  
        Configurar Entorno de Fitosanitario  
        Para cada bolsa:  
            Procesar Muestras de la Bolsa  
        Fin  
    Fin  
    Consolidar Datos para Clasificación  
Fin  
  
Iniciar:  
    Guardar(datosConsolidados.mat)  
Fin
```

**Código 3:** Procesamiento y etiquetado de aceitunas rotadas para machine learning. Elaboración propia.

El bucle principal comienza iterando sobre cada fitosanitario en la lista de manera idéntica a cómo se realizó anteriormente, y dentro del bucle de cada bolsa se incrementa el contador y se construyen los nombres de los archivos .bil y .hdr correspondientes a la muestra actual.

Para selección la región de interés (ROI), se muestra la imagen RGB y se solicita al usuario que seleccione la esquina superior izquierda de la captura utilizando `ginput`. Siempre se validará que esta esté dentro de los límites de la imagen cuando se seleccione una región de interés. Si la selección no es válida, se muestra un mensaje de error y se solicita nueva selección. Ver *Ilustración 73*.


Una vez que dicho recorte sea válido, se obtiene la ROI del hipercubo y se muestra por pantalla la sección recortada.

El tamaño la misma será definido por el usuario al inicio de la ejecución, siendo 40 de altura por 40 de anchura en este caso.

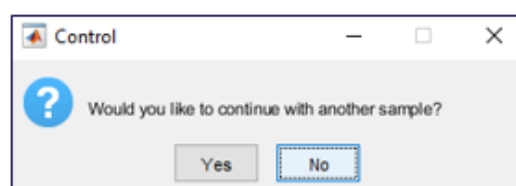


**Ilustración 75:** ROI seleccionada. Elaboración propia.

El usuario debe seleccionar la clase (OK o KO) utilizando `questdlg`. Si este no selecciona ninguna o se equivoca al hacerlo, se le vuelve a solicitar. Este paso es imprescindible por la naturaleza y pesadez de la clasificación supervisada de bases de datos grandes, situación que puede generar en el usuario un estrés mental que pueda provocarle cometer missclick.



**Ilustración 76:** Etiquetado manual OK vs KO. Elaboración propia.



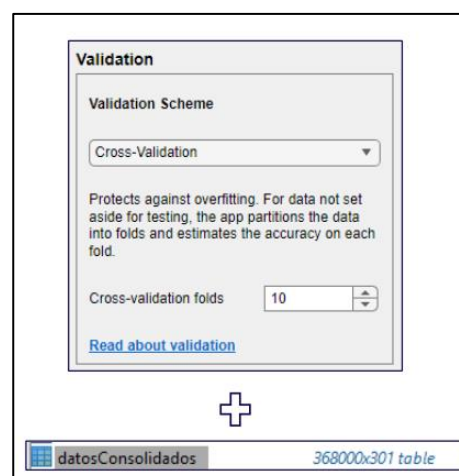
**Ilustración 77:** Pregunta al usuario si quiere continuar. Elaboración propia.

Los datos de la ROI recortada se aplanan y se organizan en una tabla. Se añade una columna de etiquetas con la clase seleccionada para cada fila de datos. La región procesada se guarda en la carpeta de hipercubos utilizando `save`, y los datos aplanados se guardan en la carpeta de datos.

Después de procesar todas las muestras y bolsas, se inicia la consolidación de datos. Se iteran todos los archivos de datos guardados, se cargan los datos y se consolidan en una única matriz de  $n+1$  columnas llamada "datosConsolidados.mat", siendo  $n$  el número de bandas y la 301 la etiqueta que el usuario añadió. Esto permite tener todos los datos necesarios en un solo lugar para su posterior análisis y entrenamiento del modelo.

| 295<br>banda295 | 296<br>banda296 | 297<br>banda297 | 298<br>banda298 | 299<br>banda299 | 300<br>banda300 | 301<br>Etiquetas |
|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|------------------|
| 10063           | 9807            | 9521            | 9519            | 9554            | 9585            | 'KO'             |
| 9156            | 8846            | 10082           | 9399            | 9932            | 9315            | 'KO'             |
| 10467           | 9807            | 9521            | 9638            | 9177            | 10126           | 'KO'             |
| 9055            | 9807            | 9521            | 10234           | 9806            | 10396           | 'KO'             |
| 9559            | 9594            | 9409            | 9876            | 9303            | 9855            | 'KO'             |
| 9559            | 10341           | 9745            | 9519            | 10058           | 9585            | 'KO'             |
| 9357            | 10128           | 9633            | 10472           | 10562           | 9450            | 'KO'             |
| 10568           | 11196           | 10530           | 9996            | 11192           | 10666           | 'KO'             |
| 11173           | 11516           | 10866           | 11665           | 10562           | 11477           | 'KO'             |
| 10971           | 11730           | 11988           | 11188           | 11066           | 11477           | 'KO'             |
| 10870           | 11089           | 10530           | 10949           | 10310           | 11072           | 'KO'             |
| 10568           | 10768           | 10418           | 9399            | 10814           | 11072           | 'KO'             |
| 10669           | 10234           | 10194           | 10592           | 10814           | 9990            | 'KO'             |
| 9963            | 8739            | 9073            | 9876            | 10310           | 10261           | 'KO'             |
| 9357            | 8953            | 9409            | 9399            | 10058           | 9045            | 'KO'             |
| 9055            | 9487            | 9745            | 9757            | 8799            | 9315            | 'KO'             |
| 9156            | 9807            | 9745            | 9280            | 9303            | 9450            | 'KO'             |
| 9862            | 9273            | 9633            | 9280            | 9429            | 10126           | 'KO'             |
| 9357            | 10341           | 9185            | 10830           | 10436           | 10126           | 'KO'             |
| 9862            | 9914            | 10082           | 9757            | 10940           | 10126           | 'KO'             |
| 10164           | 9914            | 9521            | 10234           | 10310           | 10666           | 'KO'             |
| 10063           | 10021           | 10306           | 10115           | 10940           | 10261           | 'KO'             |

**Ilustración 78:** Representación de parte de los datos consolidados. Elaboración propia.




**Ilustración 79:** Inputs del primer entrenamiento. Elaboración propia.

Classification Learner puede trabajar con una matriz 555000x301 como

máximo, límite por el cual se estudiaron 230 hipercubos con una ROI de 40x40, dando como resultado una matriz de 368000 líneas.

El algoritmo elegido para el entrenamiento fue un árbol de decisión (Fine Tree). Estos funcionan creando un modelo que predice el valor de una variable objetivo mediante el aprendizaje de reglas de decisión simples inferidas de los datos.

Este algoritmo se seleccionó debido a su capacidad para manejar grandes conjuntos de datos y su interpretación intuitiva de los resultados. Este mostró el mayor porcentaje de precisión y rapidez en comparación con el resto de algoritmos probados.



*Ilustración 80: Precisión del 98.3% con Fine Tree. Elaboración propia.*

MATLAB proporciona al usuario un código generado automáticamente desde la interfaz de Classification Learner Toolbox para entrenar y validar el modelo. Este código entrena un clasificador de árbol de decisión utilizando los datos etiquetados adquiridos previamente.

Primero, extrae los predictores y la respuesta de los datos de entrada, configurando 300 bandas espectrales como variables predictoras y las etiquetas OK/KO como la variable de respuesta. Luego, utiliza la función `fitctree` para entrenar un modelo de árbol de decisión con estos datos. A continuación, define una función de predicción para aplicar el modelo entrenado a nuevos datos. Por último, realiza una validación cruzada con 10 particiones para evaluar la precisión del modelo y devuelve tanto el clasificador entrenado como la precisión de validación.

Finalmente, se comprobará este entrenamiento con un nuevo script que se encargue de verificar si las predicciones son exitosas. Para esto, se iterará sobre una nueva imagen hiperespectral de una aceituna usando el clasificador entrenado y comprobaremos su capacidad predictiva seleccionando una nueva región de interés con la función `drawrectangle`, ya que a diferencia de `ginput`,

permite arrastrar el ratón y seleccionar todo lo que el usuario desee. De esta forma evitaremos la información no deseada representada en la *Ilustración 72*.

El procedimiento será el siguiente:

```
Iniciar:  
    Cargar el modelo y los datos entrenados  
    Entrenar el clasificador con los datos consolidados  
    Definir parámetros de la ruta y cargar la imagen  
    Convertir la imagen a RGB para visualización  
Fin  
  
Función ProcesarROI():  
    Mostrar imagen RGB y permitir selección manual de ROI  
    Extraer la ROI de la imagen original  
Fin  
  
Función Predicción(ROI):  
    Colorear la matriz de clasificación visualizada con 2 clases  
Fin  
  
Iniciar:  
    Mejorar la visualización ajustando el espacio entre los subplots  
Fin
```

**Código 4:** Validación de predicciones del modelo clasificador para aceitunas rotadas. Elaboración propia.

El proceso comienza cargando el modelo entrenado desde un archivo "ClassificationLearnerSession.mat" y los datos consolidados desde "datosConsolidados.mat". Estos datos se utilizan para entrenar nuevamente el clasificador utilizando la función `trainClassifier`, obteniendo así la precisión de validación.

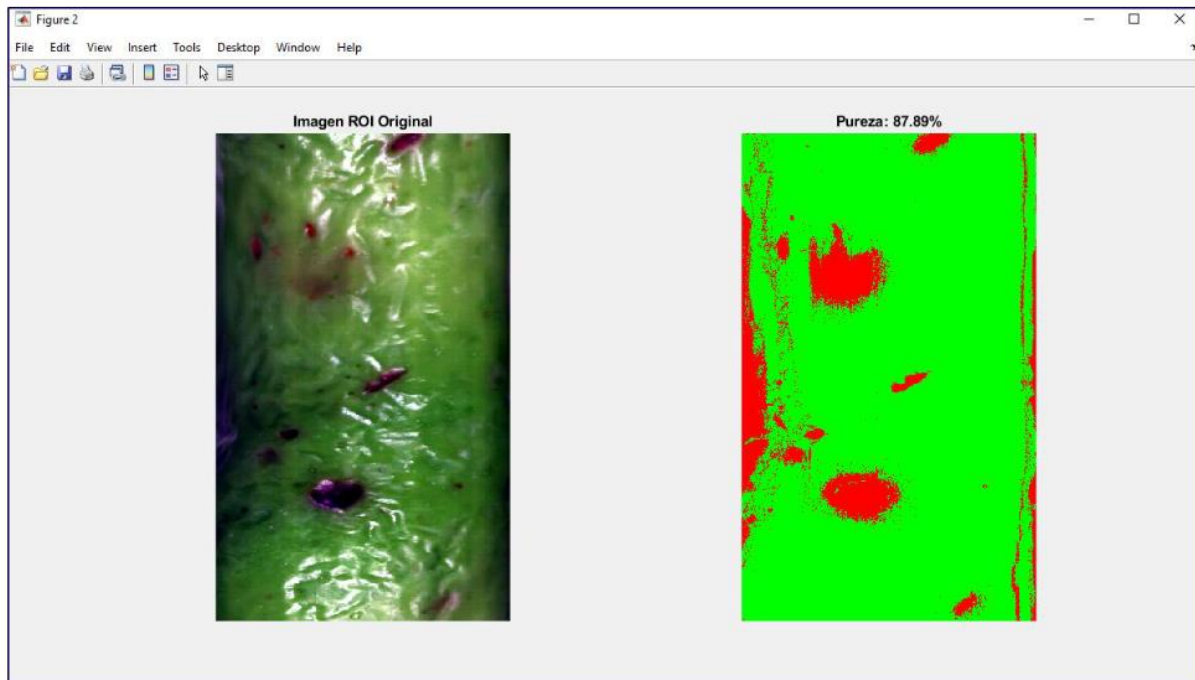
Se definen las rutas para la imagen hiperespectral y su archivo `.hdr` correspondiente, se carga, selecciona y convierte su ROI a RGB para su visualización, ajustando el brillo utilizando `imadjust`. Esto mejora la visualización de la región seleccionada.



**Ilustración 81:** Selección de la región de interés con `drawrectangle`. Elaboración propia.

La región de interés se aplanara y se convierte en una tabla de datos para la clasificación. La predicción se realiza utilizando la función `predictFcn` del clasificador entrenado. Luego, se cuentan y calculan los píxeles clasificados como 'OK' y 'KO', y se calcula el porcentaje de píxeles clasificados como 'KO' y la pureza de la aceituna (porcentaje de píxeles 'OK' sobre el total).

Finalmente, se inicializa una matriz con ceros para la visualización de la clasificación. Cada píxel se coloreará en verde si se predice como 'OK' y en rojo si 'KO'. Así pues, se muestran dos imágenes: la imagen original de la ROI y el mapa de clasificación visualizada con las predicciones del modelo. Dicha imagen formará una zona de calor donde se resaltarán las regiones molestadas.



*Ilustración 82: Mapa de clasificación visualizada para rotación. Elaboración propia.*

```
Quantity OK: 190584
Quantity OK: 26254
The percentage of KO pixels in the ROI is: 12.11%
```

*Ilustración 83: Resultados predictivos del modelo. Elaboración propia.*

El tamaño y alto porcentaje predictivo del Fine Tree dio por resultado una representación visual muy fidedigna a la realidad, siendo capaz de clasificar y no confundir brillos y sombras con sus correspondientes clases. Las imágenes rotadas contienen información muy detallada y permite al modelo establecer una diferenciación definida y marcada.

### 3.4.2. Entorno: Gran escala

Con el fin de aplicar este algoritmo a un entorno caótico y mejorar las imperfecciones del procedimiento rotativo, se añadirá una nueva clase “Tray” (bandeja) y analizaremos un lote completo. Para ello, la hipótesis inicial fue usar la matriz de datos previamente obtenida y sumarle los datos espectrales de la bandeja, la cual será el fondo las imágenes. De esta forma, el algoritmo sería capaz de individualizar cada fruto y analizarlo posteriormente. Ver *Bandeja para aceitunas*.




**Ilustración 84:** Captura de bandeja con aceitunas. Elaboración propia.



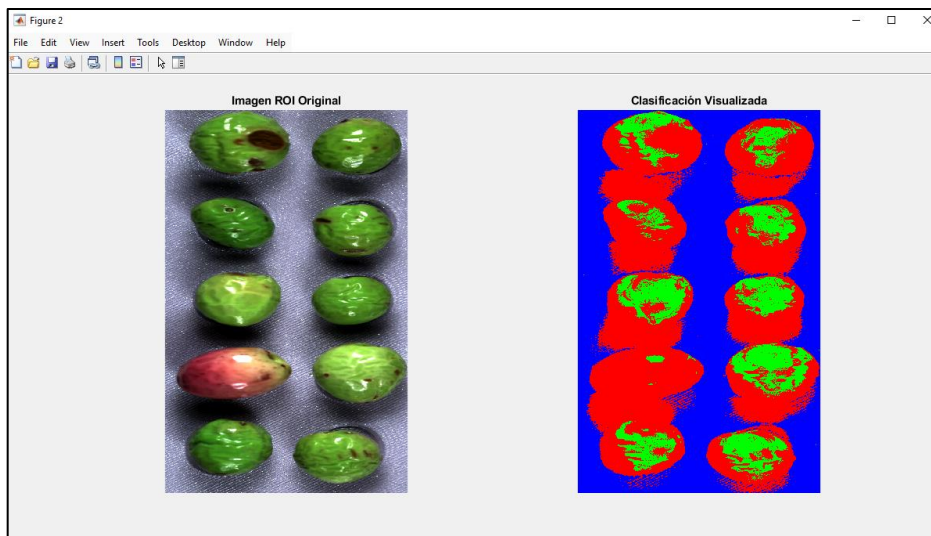
**Ilustración 85:** Hipótesis para nuevos datos consolidados. Elaboración propia.

Dicha unión se consiguió iterando 15 veces sobre cada imagen y seleccionando con la función `drawrectangle` diversas regiones de estudio de la clase “bandeja”. Se obtuvo pues una nueva matriz de 468584x301.

Aplicando la misma validación anterior, se consiguió un porcentaje para el árbol de decisión incluso mayor al obtenido previamente.



**Ilustración 86:** Precisión del 98.8% con Fine Tree. Elaboración propia.




**Ilustración 87:** Mapa de clasificación visualizada fallida. Elaboración propia.

El modelo no fue capaz de predecir correctamente el estado de molestado de las aceitunas principalmente debido a una razón: la alta variabilidad en los datos. La diferencia inherente entre los dos métodos de captura utilizados resulta un factor clave a la hora de generar la matriz etiquetada, debido a factores como la resolución, iluminación y posicionamiento de las aceitunas dificulta la capacidad del modelo para generalizar y realizar predicciones precisas.

Además, cabe destacar el claro desequilibrio visual entre clases. Si la clase "Tray" tiene significativamente menos ejemplos en los datos de entrenamiento que las clases "OK" y "KO", el modelo podría estar sesgado hacia la identificación de la clase "KO" en lugar de "Tray". Este percance provoca que confunda sombras con zonas de molestado.

La solución será, pues, obtener una nueva matriz etiquetada manualmente utilizando solamente fotos de aceitunas en bandeja, añadiendo directamente las tres clases que se buscan: parte sana (OK), molestado (KO) y bandeja (Tray). Esta nueva hipótesis permitiría que el modelo tenga acceso a datos más representativos y equilibrados, buscando solucionar los problemas existentes.



**Ilustración 88:** Selección de ROI en bandeja con `drawrectangle`. Elaboración propia.

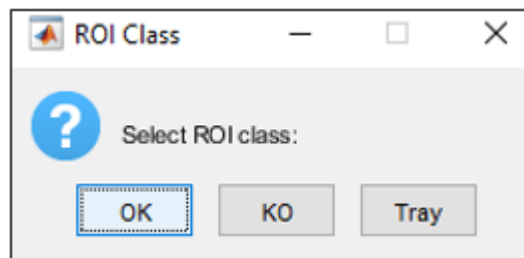
El procedimiento variaría con respecto al rotado en el número de clases que tendrá la matriz coloreada.

**Función** Predicción (ROI) :  
     **Colorear** la matriz de clasificación visualizada con 3 clases  
**Fin**

**Código 5:** Mejora para el nuevo mapa de clasificación visualizada en aceitunas traladadas. Elaboración propia.


El proceso de creación de la nueva matriz de datos consolidados será idéntico al seguido con las capturas de las aceitunas rotadas, con la diferencia de incluir la función `drawrectangle` como nueva selección de ROI debido a su buen rendimiento previo experimental. Se decantó por ella por delante de `ginput` debido a que, aunque el tamaño de nuestra matriz no estará previamente definido por los valores de la ROI, el usuario podrá seleccionar tanta superficie como desee. Finalmente, se obtienen las coordenadas y el tamaño de la región de interés a partir de la posición del rectángulo dibujado.

A continuación, se recorta y muestra la región de interés al usuario para etiquetarla. El usuario seleccionará la clase de la ROI (OK, KO, Tray) mediante `questdlg`.




**Ilustración 89:** Etiquetado manual OK, KO y Tray. Elaboración propia.

Finalmente, esta se aplanó y se convirtió en una tabla de datos. Se añadió una columna de etiquetas con la clase seleccionada para cada fila de datos. La ROI procesada se guardó en la carpeta de hipercubos, y los datos aplanados se guardaron en la carpeta de datos. Como último paso, se consolidaron todos los datos y etiquetas. Así pues, se cargaron y concatenaron los datos de cada archivo guardado, convirtiendo las etiquetas a categóricas. La tabla final de datos consolidados se guardó para su uso posterior en el entrenamiento y validación del modelo.

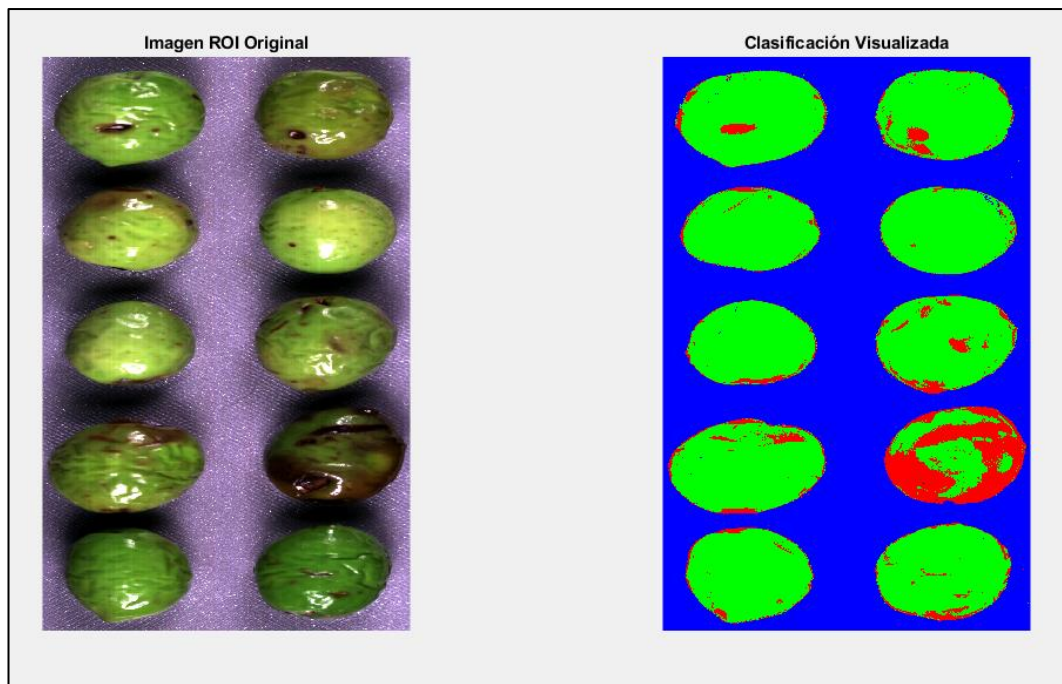


**Ilustración 90:** Matriz de datos consolidados de entrenamiento con imágenes de bandeja. Elaboración propia.



**Ilustración 91:** Precisión del 99.9% con Fine Tree. Elaboración propia.

Los resultados obtenidos tras la generación de una nueva matriz de 488849x301 etiquetada y entrenada con el modelo de árbol de decisión demostró una precisión de validación del 99.9%, aunque esto a priori no aseguraría el éxito, ya que en la primera hipótesis se obtuvo otro porcentaje alto y una clasificación errónea.



**Ilustración 92:** Mapa de clasificación visualizada para bandeja. Elaboración propia.

Con la implementación de los nuevos cambios, se logró solventar los problemas que se encontraron anteriormente al predecir las clases.

Gracias a la rica información espectral proporcionada por la cámara, el modelo es finalmente capaz de distinguir eficazmente entre sombras y molesto, algo que una cámara RGB no podría lograr al disponer de una información mucho más limitada. La capacidad de la tecnología hiperespectral para proporcionar información detallada en múltiples bandas del espectro ha sido clave para mejorar la precisión del modelo y subraya la importancia de esta tecnología en aplicaciones de clasificación complejas donde la precisión es vital.

Una vez que se tiene un modelo capaz de predecir correctamente las clases en la matriz coloreada, el paso final consiste en realizar un posprocesado de los datos para simular un entorno real de una almazara, donde las aceitunas pasarían por un sistema de clasificación automatizado en una cinta transportadora controlada. Utilizando *Image Processing Toolbox*, se evaluará y segmentará cada zona de la imagen para comprobar los resultados del modelo predictivo, aplicándolo a nuevas imágenes de aceitunas en bandeja.

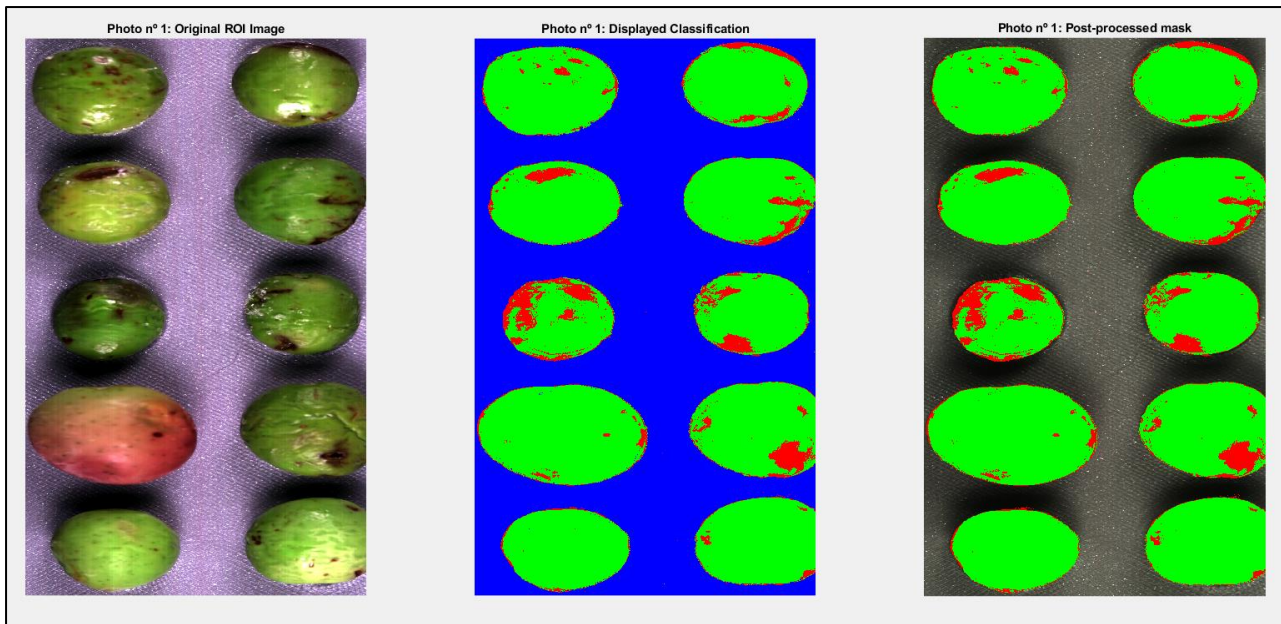
El procedimiento será el siguiente:

```
Iniciar:  
  Cargar los datos consolidados  
  Entrenar el clasificador con los datos consolidados  
  Definir parámetros de la ruta de la imagen  
  Convertir la imagen a RGB y ajustar el brillo para visualización  
Fin  
  
Función ProcesarROI():  
  Mostrar imagen RGB para selección manual de ROI  
  Extraer la ROI de la imagen original y ajustar el brillo  
Fin  
  
Función Predicción(ROI):  
  Colorear la matriz de clasificación visualizada para 3 clases  
Fin  
  
Función PosProcesamiento():  
  Corregir los píxeles mal clasificados  
  Mostrar imágenes  
  Agregar etiquetas  
Fin  
  
Iniciar:  
  Mostrar la imagen final con regiones y porcentajes de molesto  
  Generar gráficos  
Fin
```

**Código 6:** Validación de predicciones del modelo clasificador para aceitunas trasladadas. *Elaboración propia.*

Dicho script carga el modelo de clasificación previamente y procesa las fotos seleccionándolas al completo.

El factor diferencial reside en el posprocesamiento, crucial para eliminar el fondo (clase "Tray") y las sombras con él, destacando solo las aceitunas y sus defectos. Se realiza creando máscaras para las áreas rojas y verdes, y luego corrigiendo los píxeles mal clasificados utilizando la imagen original.

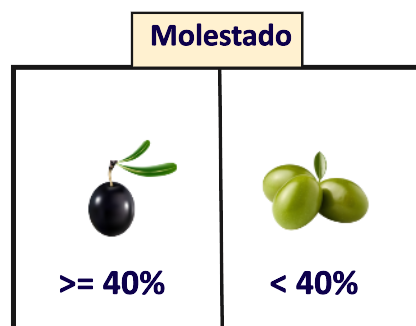


**Ilustración 93:** Máscara posprocesada, primera iteración. Elaboración propia.

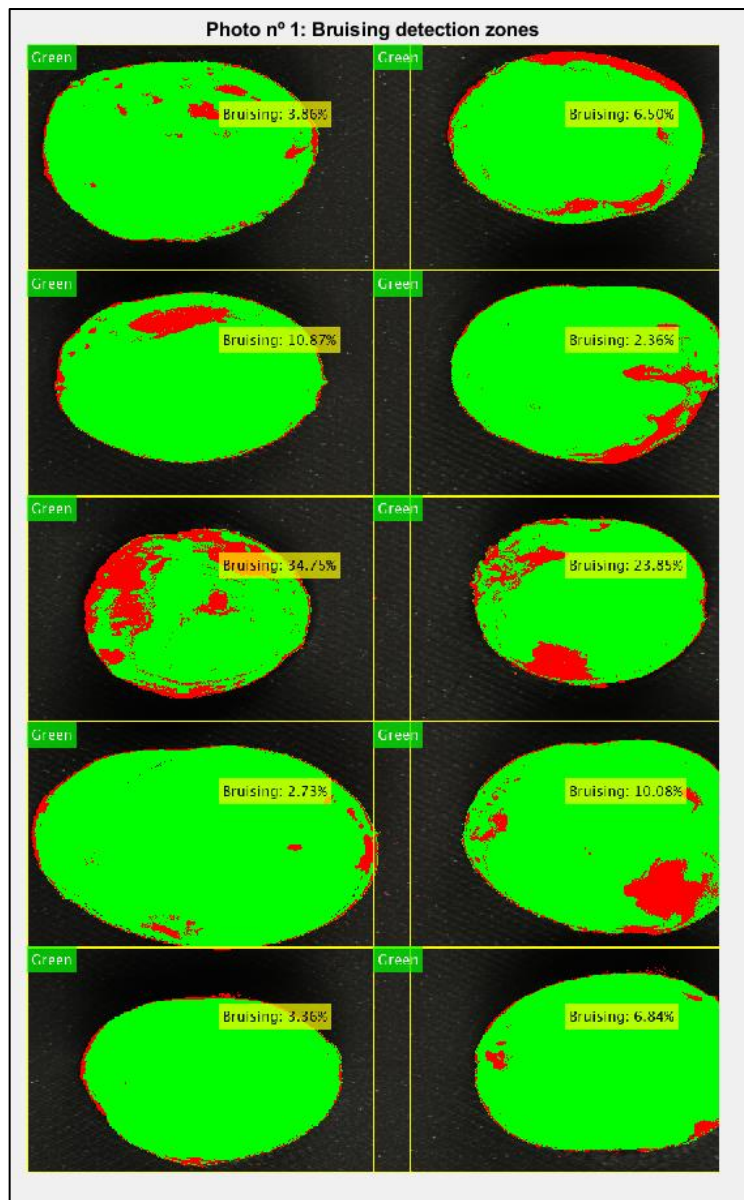
Se muestra por pantalla paralelamente: la imagen en los canales RGB con un mayor brillo, su mapa de clasificación visualizada y la correspondiente máscara con el fondo eliminado.

Después, se define el tamaño de las subregiones alrededor de cada aceituna para calcular los porcentajes de molestado. Estas subregiones permiten aislar cada aceituna y calcular el porcentaje de área defectuosa (molestado) de manera precisa. Se dibujan rectángulos alrededor de las regiones de las aceitunas y se agregan etiquetas con los porcentajes de molestado.

Por otro lado, se distingue visualmente entre aceitunas “Verdes” y “Negras” basándose en el porcentaje de área defectuosa. En este caso, toda aceituna con un porcentaje de molestado mayor al 40% se etiquetará como “Negra”.



**Ilustración 94:** Criterio de etiquetación para porcentaje de molestado. Elaboración propia.

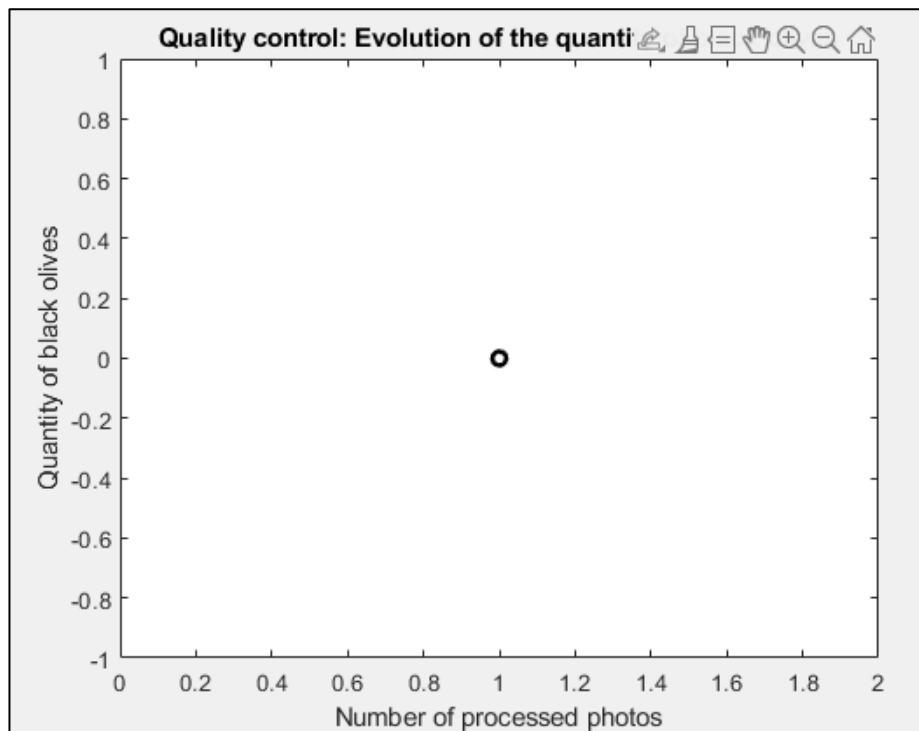


**Ilustración 95:** Zonas de detección de molestado y clasificación del fruto, primera iteración. Elaboración propia.

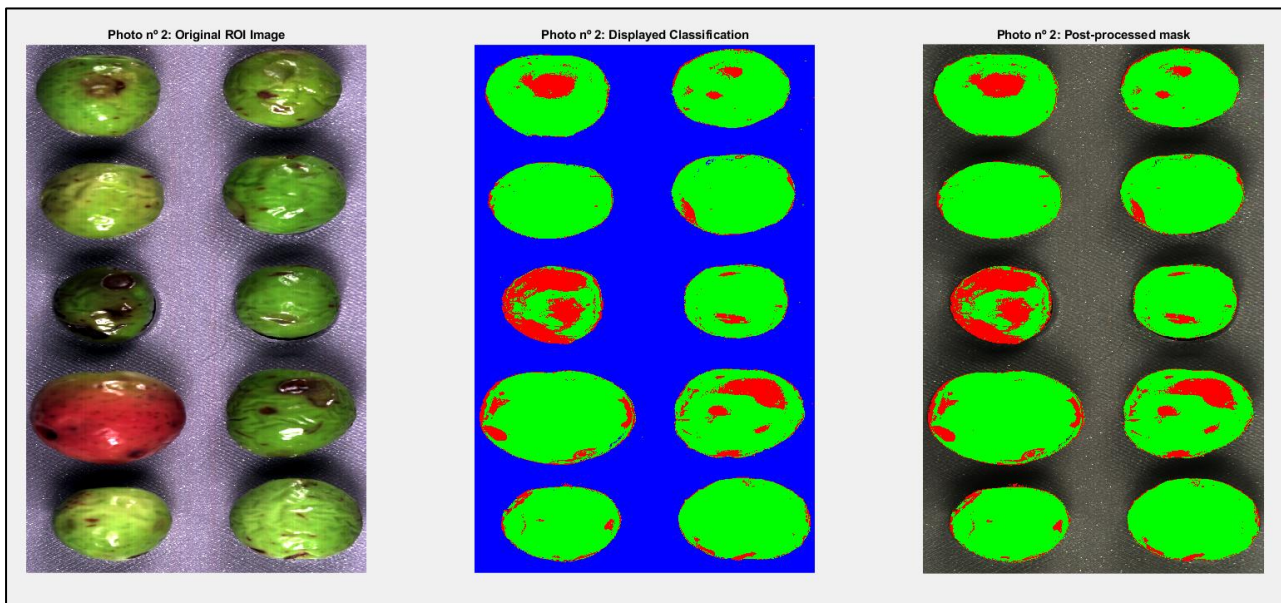
| Bruising percentage for each olive in photo n° 1: |         |
|---|---------|
| 3.8647  | 6.4952  |
| 10.8715   | 2.3615  |
| 34.7477   | 23.8494 |
| 2.7305  | 10.0833 |
| 3.3582  | 6.8386  |

**Ilustración 96:** Porcentaje de molestado mostrado por pantalla, primera iteración. Elaboración propia.

Este código se aplicó a 4 imágenes diferentes para comprobar su correcto funcionamiento. Después de procesar cada foto, se genera un gráfico que muestra cómo cambia la cantidad de aceitunas clasificadas como negras a lo largo de las fotos procesadas. Utiliza un gráfico de líneas para representar esta evolución, actualizando después de cada foto procesada. Esto permite observar si hay tendencias y establecer un control de calidad a tiempo real.



**Ilustración 97:** Gráfico de control de calidad, primera iteración. Elaboración propia.



**Ilustración 98:** Máscara posprocesada, segunda iteración. Elaboración propia.

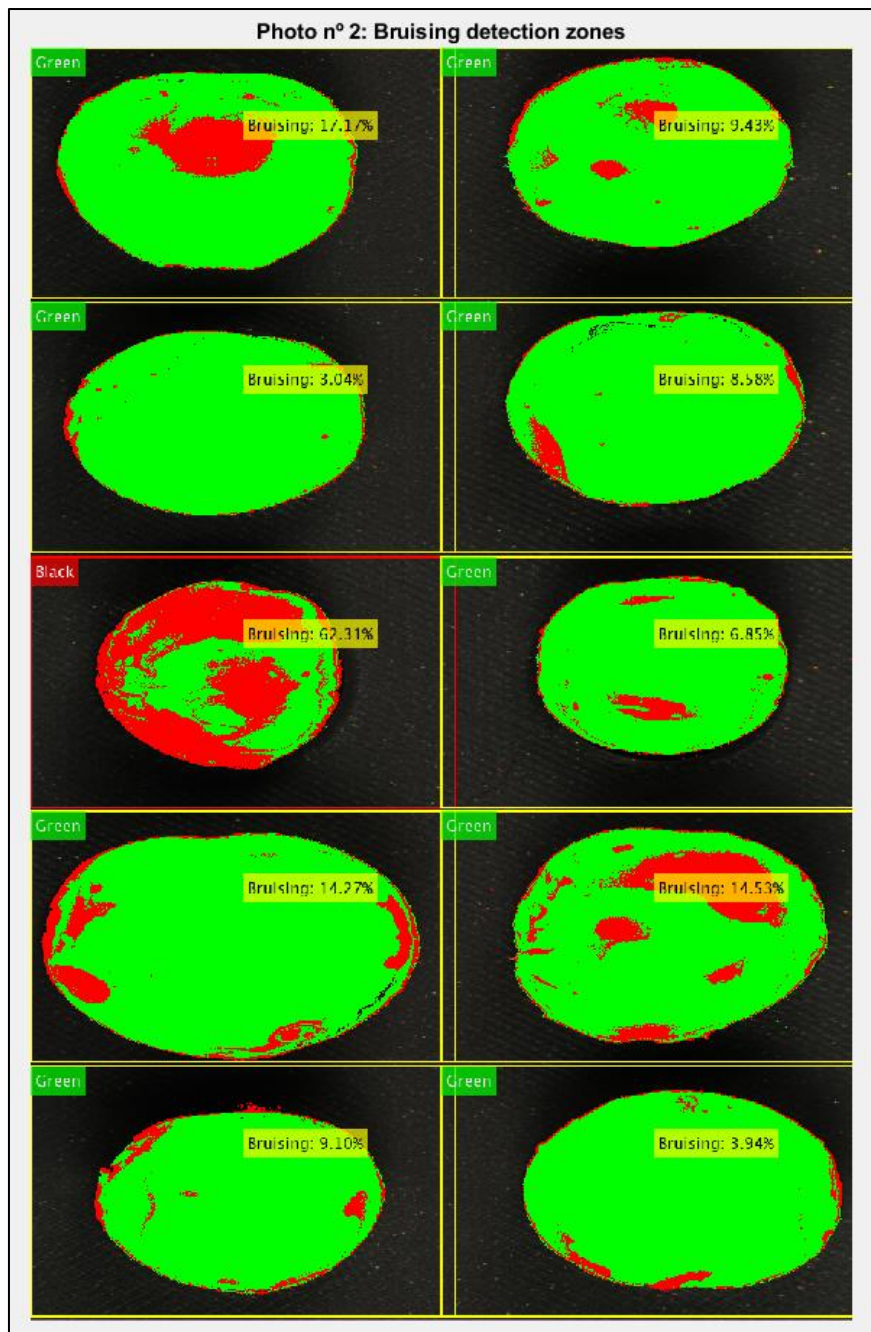



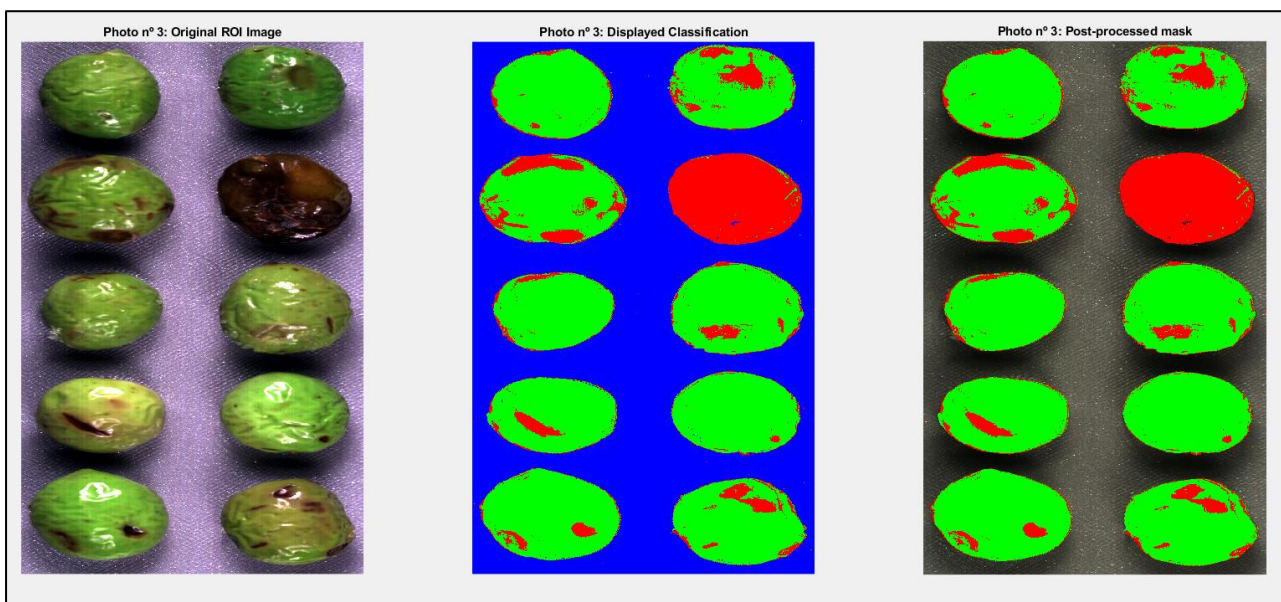
Ilustración 99: Zonas de detección de molestado y clasificación del fruto, segunda iteración. Elaboración propia.

| Bruising percentage for each olive in photo n° 2: |         |
|---|---------|
| 17.1731   | 9.4319  |
| 3.0405  | 8.5842  |
| 62.3054   | 6.8511  |
| 14.2739   | 14.5331 |
| 9.1001  | 3.9379  |

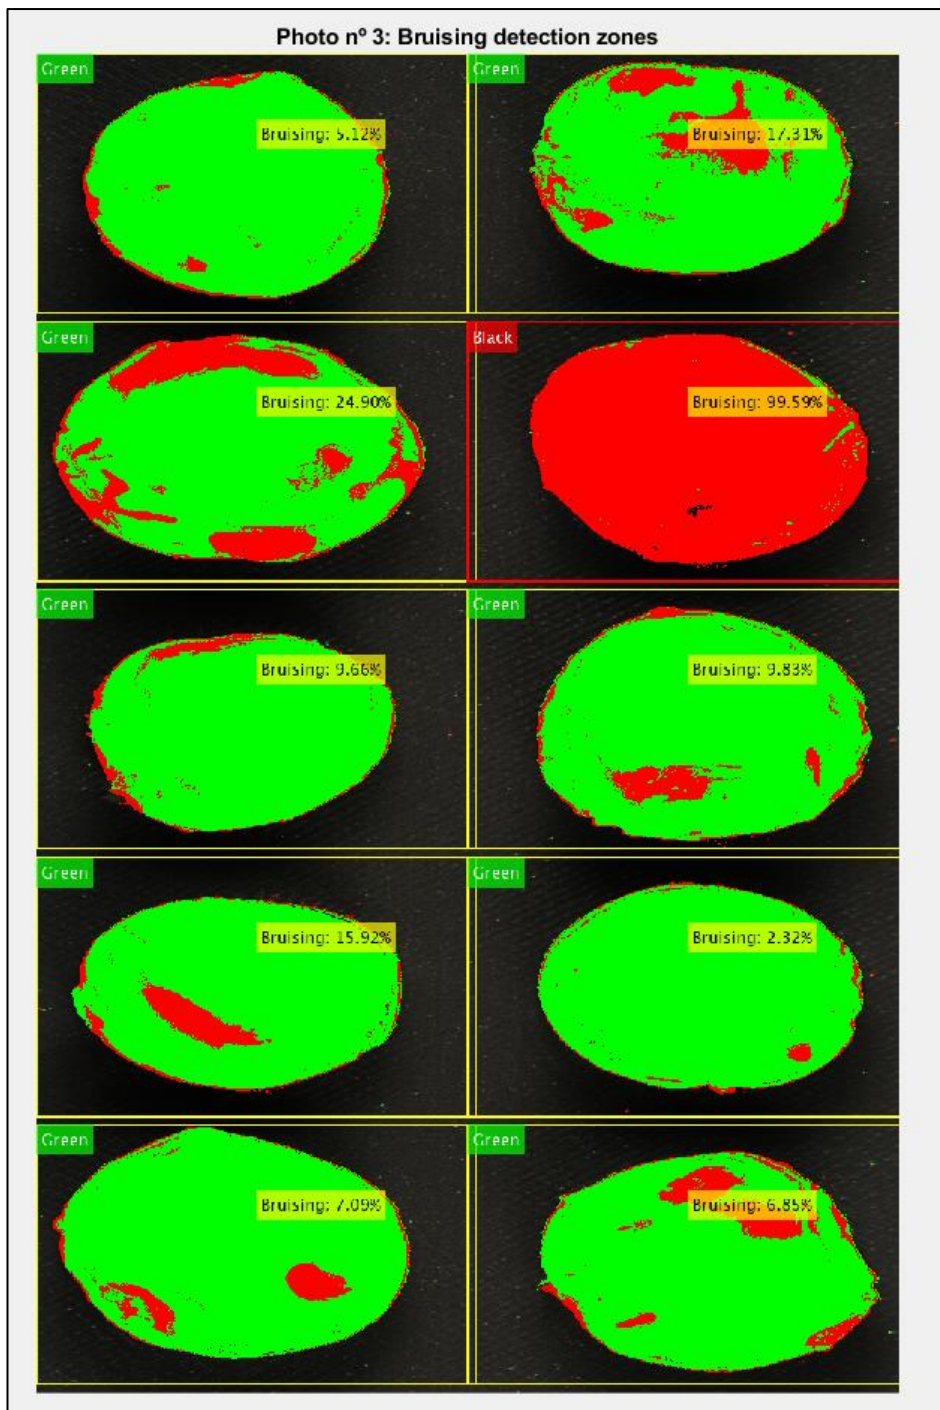
Ilustración 100: Porcentaje de molestado mostrado por pantalla, segunda iteración. Elaboración propia.



**Ilustración 101:** Gráfico de control de calidad, segunda iteración. Elaboración propia.



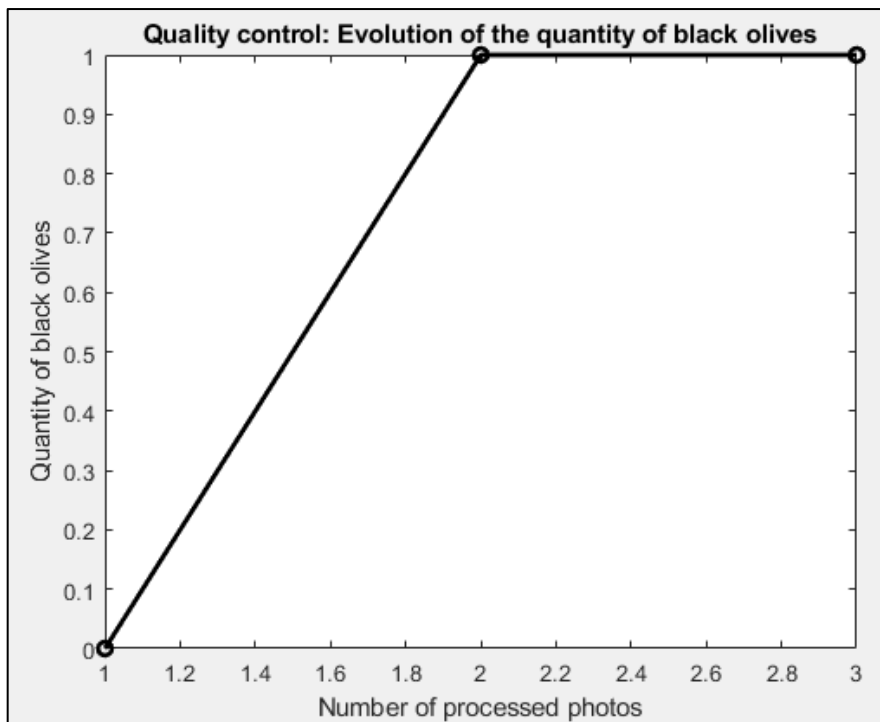
**Ilustración 102:** Máscara posprocesada, tercera iteración. Elaboración propia.



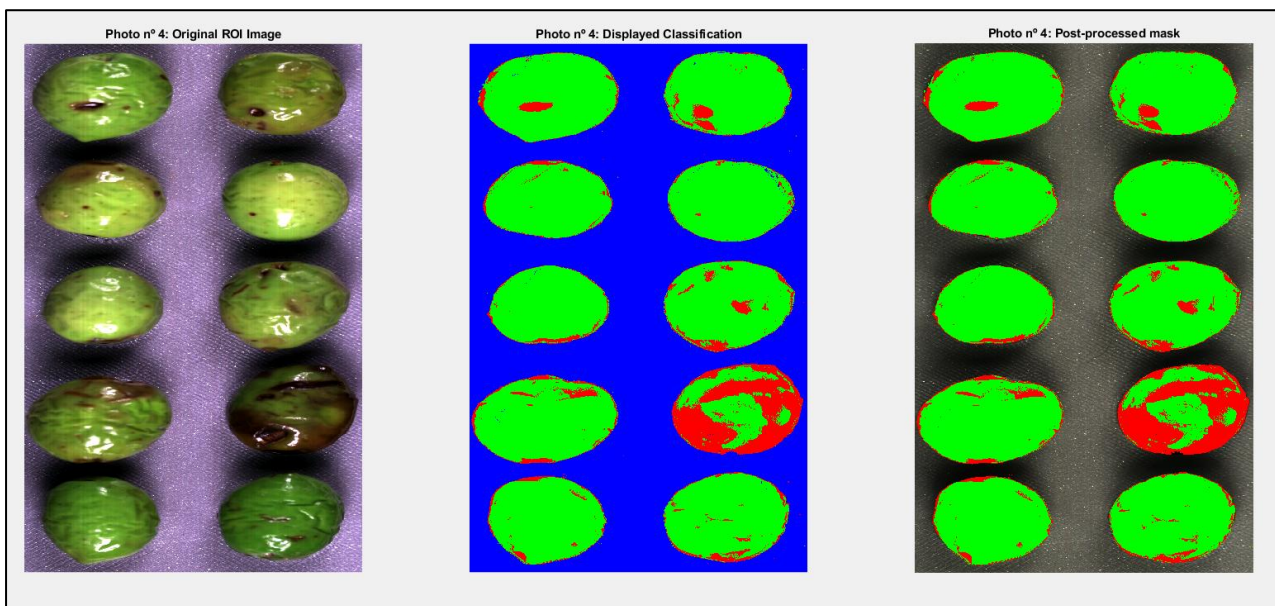
**Ilustración 103:** Zonas de detección de moleestado y clasificación del fruto, tercera iteración. Elaboración propia.

| Bruising percentage for each olive in photo n° 3: |         |
|---|---------|
| 5.1170  | 17.3063 |
| 24.8976   | 99.5919 |
| 9.6598  | 9.8310  |
| 15.9224   | 2.3177  |
| 7.0906  | 6.8482  |

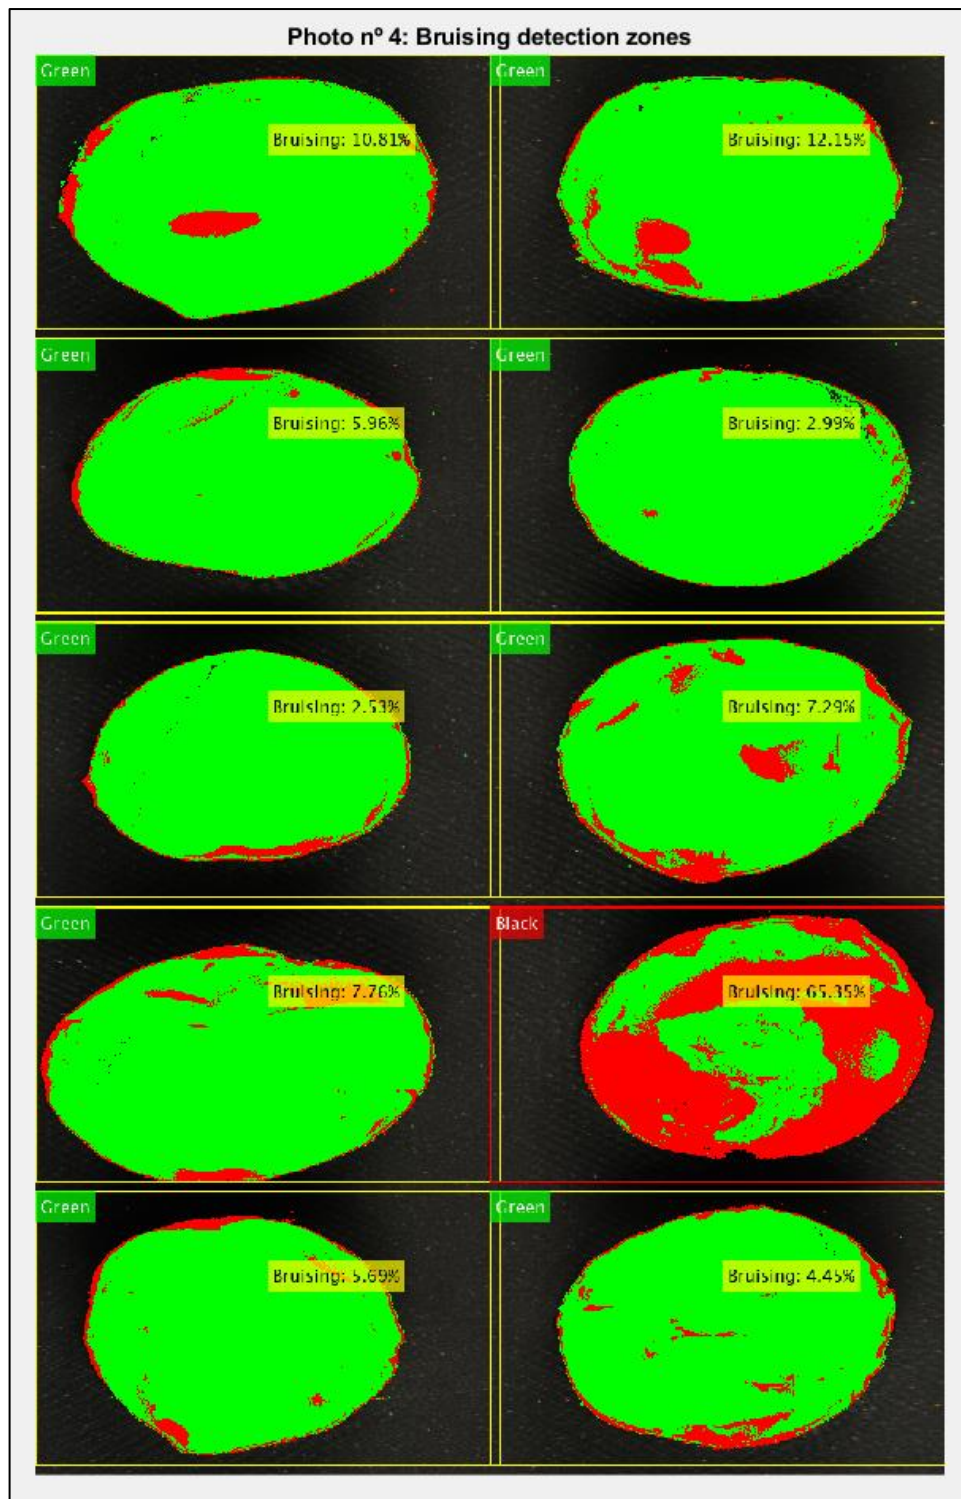
**Ilustración 104:** Porcentaje de moleestado mostrado por pantalla, tercera iteración. Elaboración propia.



**Ilustración 105:** Gráfico de control de calidad, tercera iteración. Elaboración propia.



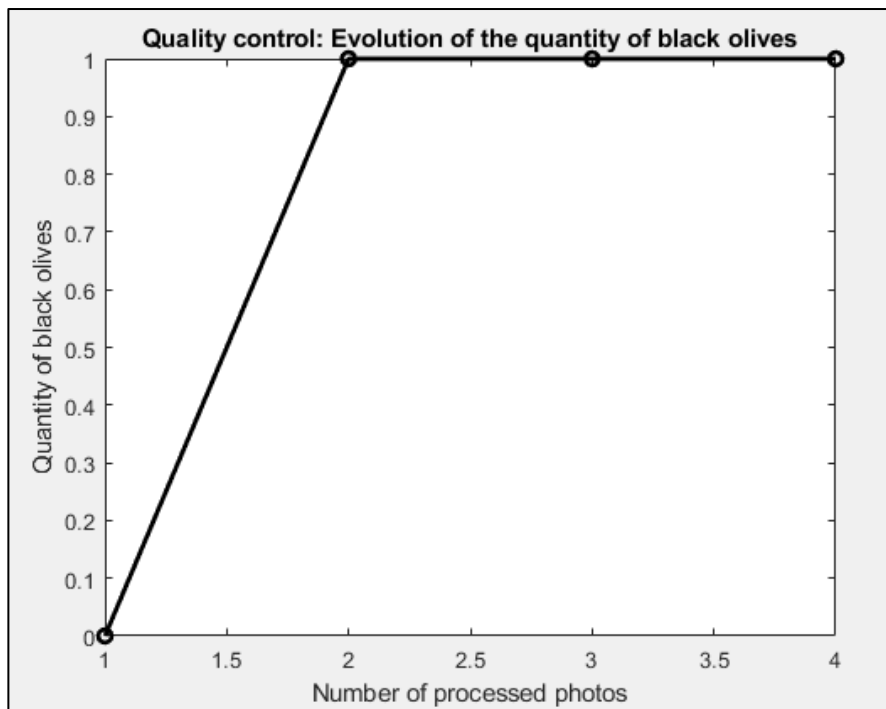
**Ilustración 106:** Máscara posprocesada, cuarta iteración. Elaboración propia.



**Ilustración 107:** Zonas de detección de moleestado y clasificación del fruto, cuarta iteración. Elaboración propia.


| Bruising percentage for each olive in photo n° 4: |         |
|---|---------|
| 10.8127   | 12.1514 |
| 5.9593  | 2.9918  |
| 2.5303  | 7.2922  |
| 7.7572  | 65.3473 |
| 5.6896  | 4.4546  |

**Ilustración 108:** Porcentaje de moleestado mostrado por pantalla, cuarta iteración. Elaboración propia.



**Ilustración 109:** Gráfico de control de calidad, cuarta iteración. Elaboración propia.


Además, se crea un histograma para visualizar la distribución de los porcentajes de molesto de todas las aceitunas analizadas en todas las fotos, 40 en total. Esto ayuda a entender la frecuencia de diferentes niveles de molesto, mostrando cuán común es cada rango de porcentaje en el conjunto de datos analizado.



**Ilustración 110:** Histograma para porcentajes de molesto. Elaboración propia.

Por otro lado, se presenta un gráfico de barras que compara los porcentajes de aceitunas verdes y negras en cada foto.

Esto proporciona una visualización clara de la proporción de aceitunas en cada categoría por foto, ayudando a identificar si hay más aceitunas en buen estado (verdes) o molestadas (negras) en cada conjunto de imágenes.



**Ilustración 111:** Gráfico de barras para porcentajes de molestado. Elaboración propia.

Finalmente, se genera un gráfico de línea que muestra el porcentaje promedio de molestado por cada foto. Este gráfico es útil para evaluar el nivel medio de molestado a lo largo de las fotos procesadas y para ver cómo este nivel varía de una foto a otra.

## 4. Resultados

### 4.1. Análisis de los datos obtenidos

En esta sección se presenta un análisis enfocado en los resultados cuantitativos de los estudios de rotación y traslación.

El modelo de rotación se implementó utilizando la técnica de Fine Tree. Los resultados mostraron una alta precisión predictiva con un porcentaje de exactitud del 98.3%. Este fue capaz de diferenciar correctamente entre los píxeles clasificados como 'OK' y 'KO', evitando confusiones debidas a los reflejos o ruido. La visualización de los resultados predictivos del modelo se muestra en la *Ilustración 82*, donde se observa una representación visual fidedigna de la realidad.

Para el modelo de traslación, el mismo algoritmo de predicción aplicado a este método también mostró una precisión elevada. En el entrenamiento inicial, se obtuvo una precisión del 98.8%, la cual se incrementó al 99.9% tras la generación de una nueva matriz de datos consolidados.

El posprocesado de los datos obtenidos mediante el método de traslación incluyó la segmentación y entrenamiento de un modelo que predijo con éxito las tres clases, mostrando una matriz de clasificación visualizada con una sólida precisión, como se ilustra en la *Ilustración 93*. Gracias al paso intermedio eliminamos las sombras de las aceitunas.

El porcentaje de molestado fue evaluado a lo largo de cuatro iteraciones distintas utilizando la bandeja. Los porcentajes promedio para cada iteración fueron:

| PORCENTAJE PROMEDIO DE MOLESTADO [%] |         |         |        |
|--------------------------------------|---------|---------|--------|
| Primera                              | Segunda | Tercera | Cuarta |
| 10.52                                | 14.92   | 19.86   | 12.5   |

**Tabla 3:** Porcentaje promedio de molestado para cada iteración. *Elaboración propia.*

Por otro lado, las gráficas de los resultados del modelo de traslación muestran un rendimiento sobresaliente en la clasificación y segmentación de las aceitunas.

La *Ilustración 110* presenta un histograma, el cual muestra la distribución de los porcentajes de molesto de todas las aceitunas analizadas en las fotos. Este gráfico es crucial para entender la frecuencia de diferentes niveles de molesto en el conjunto de datos:

- **Distribución:** la mayoría de las aceitunas tienen un porcentaje de molesto bajo, con picos significativos en los rangos más bajos de porcentaje (por debajo del 20%).
- **Frecuencia:** se observa que las aceitunas con porcentajes de molesto elevados son menos comunes en este conjunto de datos. Los rangos superiores (más del 60%) tienen una frecuencia mucho menor.
- **Interpretación:** esto indica que el método es eficiente para identificar aceitunas con niveles bajos a moderados de molesto, lo que es deseable para mantener la calidad del producto final.

Además, se generaron gráficos de barras para visualizar la proporción de aceitunas en cada categoría para la condición de etiquetado impuesta por el usuario, donde sólo una de cada diez aceitunas en las tres últimas iteraciones serían clasificadas como negras. Ver *Ilustración 111*.

## 4.2. Evaluación de técnicas no invasivas en la detección de daños

Antes de adentrarse en la discusión de los resultados, es crucial destacar que realizar una evaluación meramente cuantitativa en este tipo de estudios presenta desafíos significativos. La naturaleza experimental de la tecnología hiperespectral con condiciones controladas y sujetas a laboratorio pueden afectar los resultados.

Estos factores incluyen la variabilidad inherente de los frutos, las condiciones de iluminación y las limitaciones de la configuración experimental. Por tanto, aunque los datos cuantitativos son valiosos, es esencial considerar los aspectos cualitativos y contextuales para una evaluación integral. La siguiente tabla resume la comparación final entre ambos métodos:

| ROTACIÓN VS TRASLACIÓN   |                   |               |
|--------------------------|-------------------|---------------|
| Criterio                 | Rotación          | Traslación    |
| Precisión del modelo     | 98.3%             | 99.9%         |
| Tiempo de procesamiento  | Alto (lento)      | Bajo (rápido) |
| Volumen procesado        | Bajo (individual) | Alto (lote)   |
| Consumo de recursos      | Alto              | Moderado      |
| Aplicabilidad industrial | Limitada          | Alta          |
| Calidad de imagen        | Alta              | Moderada      |

**Tabla 4:** Comparación de ambos métodos para posibles aplicaciones industriales. Elaboración propia.

El método de traslación, a pesar de tener una resolución notablemente inferior, se destaca por su eficiencia y escalabilidad, haciéndolo más adecuado para operaciones a gran escala. Por otro lado, el método de rotación, aunque altamente preciso y detallado, resulta menos práctico para aplicaciones industriales debido a su lentitud y mayor consumo de recursos.

Este análisis cualitativo demuestra que, para una implementación en entornos industriales, el método de traslación ofrece ventajas significativas en términos de eficiencia y escalabilidad, sin comprometer la precisión en la detección de daños. Sin embargo, todo esto irá siempre sujeto a las necesidades de cada estudio y usuario.

### 4.3. Discusión de resultados

La tecnología hiperespectral ha mostrado una clara ventaja sobre las cámaras RGB, especialmente en la gestión de sombras y brillos. Estos pueden distorsionar la percepción en imágenes tradicionales, donde cada color se

representa combinando tres componentes de color primarios. La intensidad de cada uno de estos componentes se mide en una escala que va de 0 a 255, lo que permite un total de 256 niveles posibles para cada componente, siendo el negro el 0 0 0. Este dato sería fácilmente confundible ya que tanto molestado como sombras tendrían la misma información de intensidad.

Por otro lado, las imágenes hiperespectrales proporcionan datos más ricos y detallados, lo que reduce la incidencia de falsos positivos y negativos en la clasificación de aceitunas. Junto al posprocesamiento avanzado, se asegura que solo las características reales de las aceitunas sean analizadas.

El método de traslación usando cintas transportadoras, combinado con la tecnología hiperespectral, no solo es preciso sino también eficiente en términos de tiempo y recursos. La capacidad de procesar grandes volúmenes de aceitunas simultáneamente lo hace altamente escalable y adecuado para su implementación en líneas de producción industrial. La integración de esta tecnología en sistemas automatizados de control de calidad puede aumentar significativamente la productividad, optimizando el proceso de inspección y garantizando la consistencia de los resultados.

Los resultados de este estudio también incluyen implicaciones para la industria oleícola de nuestra provincia. La mejora en la detección de daños asegura un producto de mayor calidad, lo cual es esencial para la satisfacción del consumidor y la reputación del productor. Además, la implementación de dicha tecnología puede reducir las pérdidas al detectar daños de manera temprana y precisa, optimizando la cadena de producción y maximizando la eficiencia.

Es por todo ello que, aunque los resultados son prometedores, es importante reconocer las limitaciones del estudio. El tamaño de la muestra y las condiciones controladas del experimento pueden haber influido en los resultados. Futuros trabajos deberían enfocarse en validar el método en condiciones de producción real, ampliando el tamaño de la muestra y explorando otras aplicaciones de la tecnología hiperespectral en la industria agroalimentaria. Además, la mejora continua de los algoritmos de procesamiento avanzado y machine learning pueden proporcionar avances adicionales en la precisión y eficiencia del sistema.

## 5. Conclusiones

Este estudio ha demostrado que, a pesar del alto coste inicial y la complejidad del análisis de datos, la tecnología hiperespectral pasa a jugar un papel importante a la hora de detectar anomalías en aceitunas.

Actualmente, el campo de estudio sobre esta tecnología es limitado, lo que subraya la necesidad de más investigaciones para explorar su potencial completo. Este estudio contribuirá a llenar este vacío y establece una base sólida para futuras investigaciones en el Grupo de Robótica, Automática y Visión por Computador de la Universidad. A medida que se desarrolle y se unifique el análisis de datos, se volverá más accesible y práctico para la industria.

En el futuro, la adopción de esta tecnología puede revolucionar los sistemas de control de calidad en la producción industrial, asegurando productos de mayor calidad y reduciendo las pérdidas por daños no detectados. Además, contribuirá a una agricultura más sostenible y eficiente, promoviendo prácticas agrícolas que minimicen el desperdicio y maximicen la productividad.

En resumen, a pesar de los desafíos actuales, la visión hiperespectral muestra un gran potencial para mejorar significativamente la calidad y eficiencia en el estudio de aceitunas de mesa y otros productos para la industria oleícola, tanto en términos de calidad del producto como de sostenibilidad.

## Referencias

- Abdullah Beyaz, D. M. (2019). Olive fly sting detection based on computer vision. *Postharvest Biology and Technology*, 129. Obtenido de <https://www.sciencedirect.com/science/article/pii/S0925521418309736>
- Avila, Y. S. (24 de 10 de 2022). *Paper Clip*. Obtenido de <https://grabcad.com/library/paper-clip-104>
- BricoGeek. (2024). Obtenido de Fuente de alimentación 12V: [https://tienda.bricogeek.com/fuentes-de-alimentacion/828-alimentador-12v-2a-para-arduino.html?search\\_query=fuente+alimentacion&results=90](https://tienda.bricogeek.com/fuentes-de-alimentacion/828-alimentador-12v-2a-para-arduino.html?search_query=fuente+alimentacion&results=90)
- BricoGeek. (2024). *Controlador de motores paso a paso 3.5A (TB6600)*. Obtenido de <https://tienda.bricogeek.com/controladores-motores/992-controlador-de-motores-paso-a-paso-35a-tb6600.html>
- BricoGeek. (2024). *Motor NEMA 17 / 3.5Kg con conector y cable*. Obtenido de <https://tienda.bricogeek.com/motores-paso-a-paso/1360-motor-nema-17-35kg-con-conector-y-cable.html>
- Congress, L. o. (9 de 11 de 2020). *STL (STereoLithography) File Format Family*. Obtenido de <https://www.loc.gov/preservation/digital/formats/fdd/fdd000504.shtml>
- Cults 3D. (5 de 5 de 2021). *Arduino Uno Slide Case*. Obtenido de <https://cults3d.com/es/modelo-3d/artilugios/arduino-uno-slide-case>
- Diego Martínez Gila, P. C. (2012). Hyperspectral imaging for determination of some quality parameters for olive oil. *IEEE Xplore*, 6.
- Gowen, A. A., O'Donnell, C. P., Cullen, P. J., Downey, G., & Frias, J. M. (2007). Hyperspectral imaging e an emerging process analytical tool for food quality and safety control. *Trends in Food Science & Technology*, 598.
- Igus Motion Plastics. (2024). *Carro lineal drylin® W - WW*. Obtenido de <https://www.igus.es/product?artNr=WW-10-40-10>
- Igus Motion Plastics. (2024). *drylin® SLW-1040 módulo lineal*. Obtenido de <https://www.igus.es/product/20275?artNr=DL-SLW-0549>
- Igus Motion Plastics. (2024). *Raíl doble drylin® W- WS*. Obtenido de <https://www.igus.es/product?artNr=WS-10-40>
- INOLEO, s. (2024). *Espectrolive*. Obtenido de <https://www.secpho.org/casos/espectrolive-2/>
- Javiera Navarro Soto, S. S. (2018). Fast and Reliable Determination of Virgin Olive Oil Quality by Fruit Inspection Using Computer Vision. *Sensors*, 3826.
- Libano, J. O. (22 de 7 de 2022). *Motor Nema 17 40mm*. Obtenido de <https://grabcad.com/library/motor-nema-17-40mm-1>
- MathWorks. (2024). Obtenido de Image Processing Toolbox:

<https://es.mathworks.com/help/images/>

MathWorks. (2024). Obtenido de Computer Vision Toolbox:

<https://es.mathworks.com/help/vision/>

MathWorks. (2024). *Image Processing Toolbox Hyperspectral Imaging Library*. Obtenido de <https://es.mathworks.com/matlabcentral/fileexchange/76796-image-processing-toolbox-hyperspectral-imaging-library>

MathWorks. (2024). *Procesamiento de imágenes hiperespectrales*. Obtenido de <https://es.mathworks.com/help/images/hyperspectral-image-processing.html>

MathWorks. (2024). *Statistics and Machine Learning Toolbox*. Obtenido de <https://es.mathworks.com/help/stats/>

Prusa Research. (2024). *Original Prusa i3 MK3S+*. Obtenido de

<https://www.prusa3d.com/es/categoria/original-prusa-i3-mk3s/>

Prusa Research. (2024). *Prusament PLA Galaxy Silver 1kg*. Obtenido de

<https://www.prusa3d.com/es/producto/prusament-pla-galaxy-silver-1kg/>

Prusa3d. (2024). *Github*. Obtenido de <https://github.com/prusa3d/PrusaSlicer/releases>

Rafael R. Sola-Guirado, S. B.-T.-R.-G. (2020). A smart system for the automatic evaluation of green olives visual quality in the field. *Computers and Electronics in Agriculture*, 105858.

Resonon. (2024). Obtenido de Spectronon Software: <https://resonon.com/software>

Resonon. (2024). *Pika L*. Obtenido de <https://resonon.com/Pika-L>

Schneider Electric. (2024). *Motion servo drive - Lexium 32*. Obtenido de

<https://www.se.com/es/es/product/LXM32MD30M2/motion-servo-drive-lexium-32-tensi%C3%B3n-de-alimentaci%C3%B3n-monof%C3%A1sica-115-230v-08-16kw/>

*TB6600 Stepper Motor Driver*. (2024). Obtenido de


[https://wiki.dfrobot.com/TB6600\\_Stepper\\_Motor\\_Driver\\_SKU\\_\\_DRI0043#target\\_2](https://wiki.dfrobot.com/TB6600_Stepper_Motor_Driver_SKU__DRI0043#target_2)

## Anexo

### Anexo I: Protocolo de impresión 3D


Se abre el archivo del modelo en Autodesk Inventor.

En el menú "Archivo", se selecciona "Exportar" y luego "Formato de CAD".



*Ilustración 112: Exportar a Formato de CAD. Elaboración propia.*

Se selecciona ".stl" como el formato de exportación y se guarda en el directorio deseado.



*Ilustración 113: Guardar en formato ".stl". Elaboración propia.*

Se abre PrusaSlicer y crea un nuevo proyecto clicando en "Añadir".

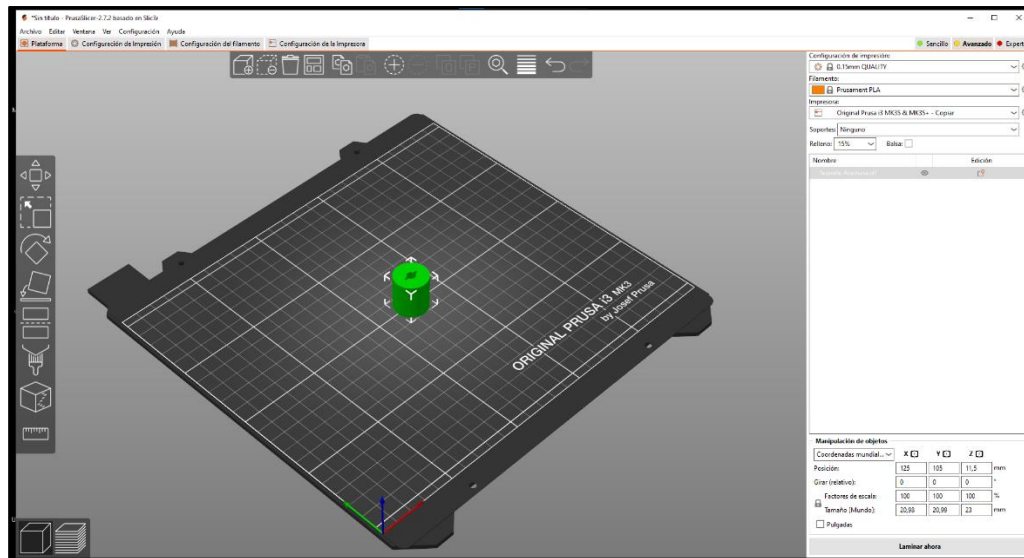


*Ilustración 114: Añadir proyecto en PrusaSlicer. Elaboración propia.*

A continuación, se importa cualquier archivo .stl que se quiera imprimir.




*Ilustración 115: Guardar en formato ".stl". Elaboración propia.*



**Ilustración 116:** Interfaz de PrusaSlicer. Elaboración propia.

Se podrá rotar el objeto además de configurar su impresión en el panel de control izquierdo y derecho. Para este caso no será necesario pues las piezas tendrán poco detalle.

Una vez seleccionados los parámetros de impresión, se seleccionará “Laminar ahora” y se exportará finalmente el archivo G-Code. Este será introducido en la tarjeta SD de la impresora y posteriormente impreso.



**Ilustración 117:** Laminar objeto en PrusaSlicer. Elaboración propia.



**Ilustración 118:** Guardar en formato “.gcode”. Elaboración propia.

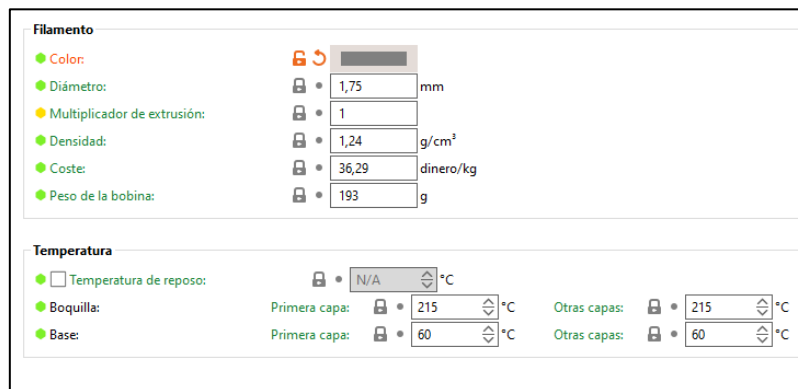
Se añadirá adicionalmente los parámetros usados para la impresión de las piezas, basados en las necesidades estructurales de las mismas.

### Configuración del filamento y temperaturas

- Tipo de Filamento: Prusament PLA (modificado).
- Diámetro: 1.75 mm.

- Multiplicador de extrusión: 1.
- Densidad: 1.24 g/cm<sup>3</sup>.

Se seleccionó una temperatura de 215 °C para asegurar una extrusión fluida del filamento PLA, mejorando la adherencia entre capas y una temperatura de la base de 60 °C para garantizar una buena adherencia de la primera capa al lecho de impresión, minimizando el riesgo de deformaciones y levantamientos.




The image shows a screenshot of the PrusaSlicer software interface, specifically the filament and temperature configuration panels. The 'Filamento' (Filament) panel includes fields for Color, Diámetro (1,75 mm), Multiplicador de extrusión (1), Densidad (1,24 g/cm<sup>3</sup>), Coste (36,29 dinero/kg), and Peso de la bobina (193 g). The 'Temperatura' (Temperature) panel includes fields for Temperatura de reposo (N/A °C), Boquilla (215 °C for first layer, 215 °C for other layers), and Base (60 °C for first layer, 60 °C for other layers).

**Ilustración 119:** Configuración de filamento y temperatura en PrusaSlicer. Elaboración propia.


### Configuración de la impresión

- Altura de la capa: 0.15 mm. Permite obtener detalles finos y superficies lisas sin alargar demasiado el tiempo de impresión.
- Altura de la primera capa: 0.2 mm. Mejora la adherencia inicial de la impresión y asegurar una base sólida para las capas siguientes.
- Se han seleccionado 2 perímetros para asegurar una buena integridad estructural sin aumentar excesivamente el tiempo de impresión.
- Densidad de relleno: Un 20% de densidad, suficiente para la mayoría de aplicaciones sin añadir peso innecesario a la estructura del setup.
- Patrón de relleno: Cuadrícula. Ofrece buena estabilidad y soporte para las capas superiores.


## Anexo II: Modelos 3D de comprobación




*Ilustración 120: Clip cortado. (Avila, 2022).*



*Ilustración 121: Motor Nema 17. (Libano, 2022).*



*Ilustración 122: Módulo lineal drylin® SLW-1040. (Igus Motion Plastics, 2024)*



**Ilustración 123:** Guía drylin® W L:500mm y carro drylin® W con freno manual. (Igus Motion Plastics, 2024)

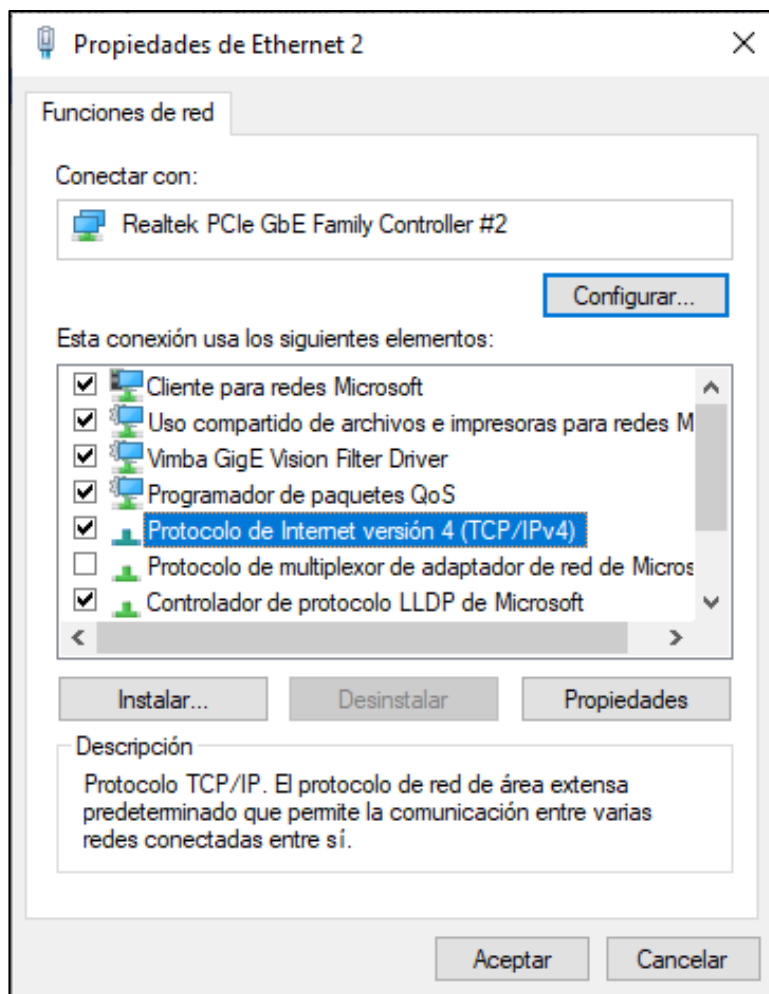
## Anexo III: Protocolo de control de cinta transportadora

### Configuración de la conexión de red

Se inserta el cable Ethernet en el puerto correspondiente del dispositivo.

Se accede al Panel de Control y se selecciona "Conexiones de red".

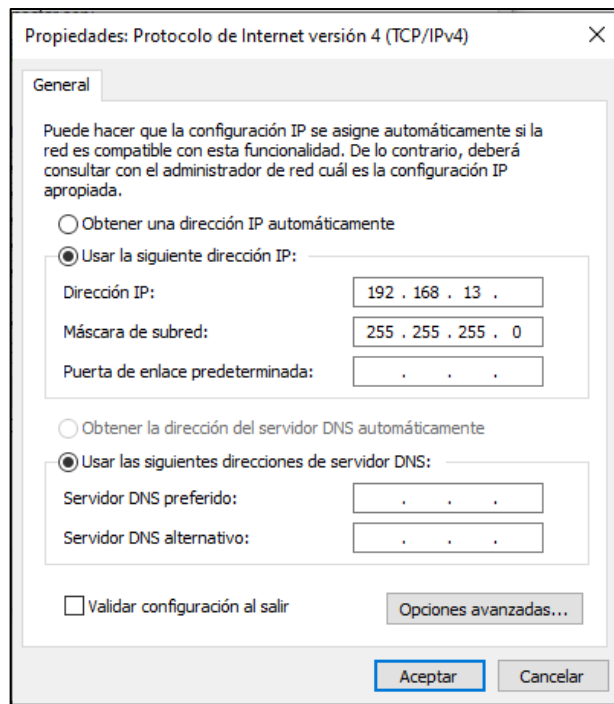
A continuación, clic derecho en la conexión de red utilizada (Realtek PCIe GbE Family Controller #2) y se selecciona "Propiedades".



*Ilustración 124: Protocolo de conexión con cinta I. Elaboración propia.*

En la ventana de Propiedades de Ethernet, se selecciona "Protocolo de Internet versión 4 (TCP/IPv4)" y se hace clic en "Propiedades".

Se configura la dirección IP manualmente:



**Ilustración 125:** Protocolo de conexión con cinta II. Elaboración propia.

- Dirección IP: 192.168.1.3
- Máscara de subred: 255.255.255.0

Se aceptan los cambios y se cierran todas las ventanas de propiedades.

### Configuración de Somove

Se abre el software de control de la cinta, Somove, y se selecciona "Conectar" para establecer la comunicación.

Una vez conectado, puede proceder a transferir configuraciones, cargar o guardar desde el dispositivo según sea necesario.



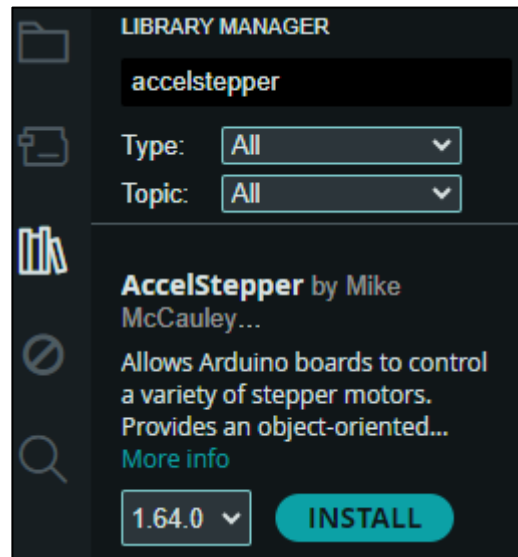
**Ilustración 126:** Protocolo de control de cinta. Elaboración propia.

## Anexo IV: Instalación de paquetes y librerías

### Arduino: Accelstepper

Se ejecuta Arduino IDE.

En el panel de control izquierdo, se accede al gestor de bibliotecas.




*Ilustración 127: Instalación de Accelstepper. Elaboración propia.*

Se busca "Accelstepper" y se instala la versión más reciente.

**MATLAB:** *Image Processing Toolbox, Image Processing Toolbox Hyperspectral Imaging Library, Computer Vision Toolbox y Statistics and Machine Learning Toolbox.*

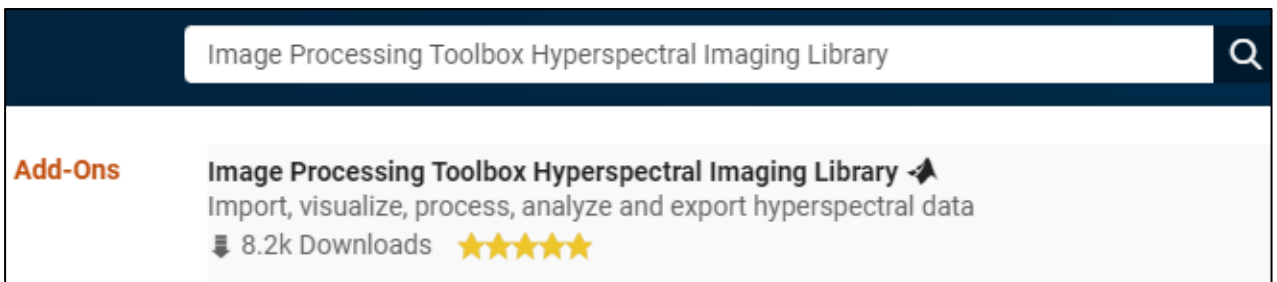
Dentro de MATLAB, se selecciona la pestaña Home (Inicio).

A continuación, se selecciona Add-Ons (Complementos) en la barra de herramientas.











*Ilustración 128: Pestaña "Add-Ons". Elaboración propia.*

Desde la pestaña de Add-Ons explorer, se busca la librería deseada en su versión más reciente y se instala.



**Ilustración 129:** Add-Ons explorer. Elaboración propia.

Se comprueba desde Add-Ons Manager que todo está correctamente instalado.

| Installed   |   | Updates |  |
|---|---|---------|--|
| Name  | Author  |         |  |
|  <b>Computer Vision Toolbox</b> version 24.1 (5 days remaining on trial)                 |  MathWorks |         |  |
|  <b>Image Processing Toolbox</b> version 24.1 (5 days remaining on trial)                |  MathWorks |         |  |
|  <b>Image Processing Toolbox Hyperspectral Imaging Library</b> version 24.1.0            |  MathWorks |         |  |
|  <b>Statistics and Machine Learning Toolbox</b> version 24.1 (5 days remaining on trial) |  MathWorks |         |  |

**Ilustración 130:** Add-Ons Manager. Elaboración propia.

## Anexo V: Presupuesto total

La inversión del proyecto fue enfocada predominantemente en activos no corrientes, diseñados para establecer una infraestructura sólida y duradera para la investigación en el laboratorio. A continuación, se resumirá en una tabla todos los costes asociados al montaje y experimentación. Dichos cálculos fueron realizados con Microsoft Excel.

Todos los precios han sido basados en las webs oficiales de cada empresa y albaranes de los pedidos. Sin embargo, para elementos cuya información no sea pública o estuvieran disponibles previamente en el laboratorio, se estimará un coste basado en el precio medio de mercado.

| Ítem                               | Coste              |
|------------------------------------|--------------------|
| Cámara Hiperespectral Pika L       | 12.325,51 €        |
| Lente objetivo VNIR – 23 mm        | 898,78 €           |
| Ordenador de alto rendimiento      | 1.200,00 €         |
| Pedido IGUS                        | 565,57 €           |
| Impresora 3D Prusa i3 MK3S+        | 999,00 €           |
| Filamento PLA (1 kg)               | 29,99 €            |
| Arduino Uno                        | 12,00 €            |
| Microcontrolador y motor           | 39,40 €            |
| Cinta transportadora               | 1.500,00 €         |
| Focos halógenos                    | 46,00 €            |
| Cables, conectores y perfiles      | 150,00 €           |
| Herramientas y accesorios diversos | 100,00 €           |
| <b>Coste total</b>                 | <b>17.866,25 €</b> |

**Tabla 5:** Presupuesto total del montaje. Elaboración propia.