

# FACULTAD DE INGENIERÍA

Carrera de Ingeniería de Sistemas Computacionales  
“APLICACIÓN DE VISIÓN COMPUTACIONAL EN LA  
DETECCIÓN DE SÍNTOMAS VISUALES DE  
PLANTACIONES DE PALTA PARA LA AGRÍCOLA MAPA  
SAC, 2023”

Tesis para optar el título profesional de:  
Ingeniero de Sistemas Computacionales

Autores:

Franz Kaiser Alba Mejia  
Luis Cristofer Mostacero Perez

Asesor:

Ing. Rolando Javier Berrú Beltrán  
<https://orcid.org/0000-0002-0739-1599>

Trujillo - Perú

**JURADO EVALUADOR**

Jurado 1 Presidente(a)	<b>JOSÉ ALBERTO GÓMEZ ÁVILA</b>	<b>40990648</b>
	Nombre y Apellidos	Nº DNI

Jurado 2	<b>MARCELINO TORRES VILLANUEVA</b>	<b>17865408</b>
	Nombre y Apellidos	Nº DNI

Jurado 3	<b>EDWIN TORRES MENDOZA</b>	<b>32983830</b>
	Nombre y Apellidos	Nº DNI

## INFORME DE SIMILITUD

### Tesis Final.docx

#### INFORME DE ORIGINALIDAD

<b>6%</b>	<b>5%</b>	<b>1%</b>	<b>1%</b>
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

#### FUENTES PRIMARIAS

<b>1</b>	<b>hdl.handle.net</b> Fuente de Internet	<b>2%</b>
<b>2</b>	<b>repositorio.upagu.edu.pe</b> Fuente de Internet	<b>1%</b>
<b>3</b>	<b>repositorio.upn.edu.pe</b> Fuente de Internet	<b>1%</b>
<b>4</b>	<b>repositorio.ucv.edu.pe</b> Fuente de Internet	<b>1%</b>
<b>5</b>	<b>Submitted to Universidad Nacional de Trujillo</b> Trabajo del estudiante	<b>1%</b>

Excluir citas      Apagado      Excluir coincidencias < 1%  
Excluir bibliografía      Apagado

## DEDICATORIA

A mis padres por inculcar en mí el ejemplo de esfuerzo y perseverancia, quienes a lo largo de su vida han velado por mi bienestar y educación en cada momento; a mi familia por creer en mí siempre y acompañándome a cumplir esta meta; sin ellos no hubiera sido posible la culminación de esta etapa de estudios en mi vida.

Franz Alba.

A mis padres, porque creyeron en mí y porque me sacaron adelante, dándome ejemplos dignos de superación y entrega, porque en gran parte gracias a ustedes, hoy puedo ver alcanzada mi meta, ya que siempre estuvieron impulsándome en los momentos más difíciles de mi carrera, y porque el orgullo que sienten por mí fue lo que me hizo ir hasta el final.

Luis Mostacero.

## **AGRADECIMIENTO**

A todos los docentes que, con su sabiduría, conocimiento y apoyo, motivaron a nuestro desarrollo como persona y profesional en la Universidad Privada del Norte.

Los autores

## TABLA DE CONTENIDOS

<b>JURADO EVALUADOR .....</b>	<b>2</b>
<b>INFORME DE SIMILITUD.....</b>	<b>3</b>
<b>DEDICATORIA .....</b>	<b>4</b>
<b>AGRADECIMIENTO.....</b>	<b>5</b>
<b>TABLA DE CONTENIDOS .....</b>	<b>6</b>
<b>ÍNDICE DE TABLAS.....</b>	<b>7</b>
<b>ÍNDICE DE FIGURAS .....</b>	<b>8</b>
<b>ÍNDICE DE ECUACIONES .....</b>	<b>9</b>
<b>RESUMEN .....</b>	<b>10</b>
<b>ABSTRACT.....</b>	<b>11</b>
<b>CAPÍTULO I. INTRODUCCIÓN .....</b>	<b>12</b>
1.1. Realidad problemática.....	12
1.2 Formulación del problema.....	30
<b>CAPÍTULO II. METODOLOGÍA .....</b>	<b>33</b>
<b>CAPÍTULO III. RESULTADOS .....</b>	<b>47</b>
<b>CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES.....</b>	<b>60</b>
<b>REFERENCIAS.....</b>	<b>64</b>
<b>ANEXOS:.....</b>	<b>68</b>

## ÍNDICE DE TABLAS

Tabla 1. Indicador del Tiempo- Pretest.....	37
Tabla 2. Indicador de Costo. Pretest.....	38
Tabla 3. Indicador de Detección de Síntomas. Pretest.....	39
Tabla 4. Indicador del nivel de satisfacción.....	40
Tabla 5. Comparación de metodologías de desarrollo de software. ....	41
Tabla 6. Indicador del Tiempo- Pretest.....	43
Tabla 7. Indicador de Costo. Pretest.....	44
Tabla 8. Indicador de Detección de Síntomas. Pretest.....	45
Tabla 9. Indicador del nivel de satisfacción.....	46
Tabla 10. Datos del Indicador Tiempo. Pretest - Postest .....	47
Tabla 11. Descriptivos Indicador Tiempo. ....	47
Tabla 12. Prueba t-student. Indicador tiempo .....	49
Tabla 13. Datos del Indicador Costo. Pretest - Postest.....	50
Tabla 14. Descriptivos Indicador Costo.....	51
Tabla 15. Prueba t-student. Indicador tiempo .....	52
Tabla 16. Datos del Indicador de detección. Pretest - Postest .....	53
Tabla 17. Descriptivos Indicador Detección. ....	54
Tabla 18. Prueba t-student. Indicador detección de síntomas.....	55
Tabla 19. Datos del Indicador de satisfacción. Pretest - Postest.....	56
Tabla 20. Descriptivos Indicador Satisfacción.....	56
Tabla 21. Prueba t-student.. Indicador de Satisfacción .....	58
Tabla 22. Datos indicador tiempo. Pretest .....	75
Tabla 23. Indicador de Costo. Pretest.....	76
Tabla 24. Indicador de detección. Pretest.....	77
Tabla 25. Indicador de Tiempo. Postest.....	78
Tabla 26. Indicador de Costo. Postest .....	79
Tabla 27. Indicador de detección. Postest .....	80
Tabla 28. Product Backlog.....	82
Tabla 29 . HU-001 .....	84
Tabla 30. HU-002 .....	84
Tabla 31. HU-005 .....	85
Tabla 32. HU-006 .....	85
Tabla 33. HU007.....	86
Tabla 34. HU-009 .....	86
Tabla 35. HU-010 .....	87

## ÍNDICE DE FIGURAS

Figura 1. Fases de SCRUM .....	29
Figura 2 Equipo de Trabajo SCRUM.....	30
Figura 3. Comparativo del Indicador de Tiempo.....	48
Figura 4. Aceptación o rechazo indicador tiempo.....	49
Figura 5. Comparativo del Indicador de Tiempo.....	51
Figura 6. Aceptación o rechazo indicador costo.....	52
Figura 7. Comparativo del Indicador de Detección.....	54
Figura 8. Aceptación o rechazo indicador detección de síntomas.....	55
Figura 9. Comparativo del Indicador de Satisfacción .....	57
Figura 10. Aceptación o rechazo indicador Satisfacción .....	58
Figura 11. HU-004. Login de Seguridad.....	88
Figura 12. HU-005. Registrar áreas .....	88
Figura 13. HU-006. Gestionar usuarios.....	88
Figura 14. HU007. Subir archivos (videos).....	89
Figura 15. HU008. Crear Video.....	90
Figura 16. HU009. Mostrar videos subidos por área .....	91
Figura 17. HU0010. Mostrar síntomas detectados .....	91
Figura 18. HU011. Reporte de síntomas.....	92

## ÍNDICE DE ECUACIONES

<b>Ecuación 1.</b> <i>Indicador de detección (IDE)</i> .....	39
<b>Ecuación 2.</b> <i>Indicador de satisfacción (ISA)</i> .....	40

## RESUMEN

El presente estudio tuvo como objetivo establecer la influencia de la aplicación de visión computacional en detección de síntomas visuales de plantaciones de palta para la Agrícola SAC, 2023. Fue aplicada y el diseño fue diagnóstico propositivo, donde las tomas se realizaron en la zona salitre. Referente a los resultados que se obtuvieron a partir de la aplicación visual una mejora en el tiempo de obtención de 105.57min reduciéndose a 25.33 min (reduciendo en 76.01%), en cuanto al costo promedio, pasó de S/. 88.82 reduciéndose a S/. 21.31 (75.99%) y el indicador de detección tuvo una mejora de 21.37%. El estudio concluye que la aplicación de visión computacional influye significativamente en detección de síntomas visuales de plantaciones de palta

***Palabras clave:*** Aplicación Visual, detección, síntomas visuales.

## ABSTRACT

The objective of this study was to establish the influence of the application of computer vision in detecting visual symptoms of avocado plantations for Agrícola SAC, 2023. It was applied and the design was purposeful diagnosis, where the shots were taken in the saltpeter zone. Regarding the results obtained from the visual application, an improvement in the obtaining time of 105.57 min was reduced to 25.33 min (reduced by 76.01%), as for the average cost, it went from S/. 88.82, reducing to S/. 21.31 (75.99%) and the detection indicator had an improvement of 27.18%. The study concludes that the application of computer vision significantly influences the detection of visual symptoms of avocado plantations.

**Keywords:** Visual Application, detection, visual symptoms.

## CAPÍTULO I. INTRODUCCIÓN

### 1.1. Realidad problemática

Dentro de las actividades que las empresas del sector agrícola desarrollan, se encuentra la necesidad de obtener frutos, a partir de las plantaciones, con una calidad requerida por sus demandantes, lo cual les obliga a monitorear el crecimiento de las mismas y detectar oportunamente, posibles factores que afecten a su crecimiento. En USA en el 2022, se tuvo disponibles 1.216.050 TN de palta Hass, siendo un 78% de México, un 10% de California, 10% de Perú, entre otras (Agraria, 2022).

En Brasil la visión computacional, está penetrando rápidamente en muchos campos de la ciencia, en especial en agricultura, donde el Deep Learning es una de las herramientas más usadas para detectar diferentes anomalías que puedan presentarse en las plantas (Fracarolli et al., 2020)

Un estudio realizado en Colombia, indica que, desde muchos años la cuantificación de zonas enfermas en hojas de plantas, constituye un procedimiento vital en la agricultura dado que permite el monitoreo y la toma de decisiones en ayuda para cuidar los cultivos. Pero, actualmente se realiza manualmente, consumiendo un tiempo prolongado y es subjetivo, por lo que, se debe buscar la automatización del proceso (Novoa et al., 2018).

En Chile un estudio realizado sobre plantas indica que existe un desarrollo menor vegetativo en las plantas que se ubican en la solución con déficit de nitrógeno, seguido del fósforo y del potasio y que estas deben ser identificadas a tiempo para que puedan desarrollarse normalmente (Gorziglia et al., 2019)

En Junio del 2022, en nuestro país, la producción de palta alcanzó más de 168 mil Tn., con un crecimiento del 10,1% comparándolo con el período anterior anual, lo cual se presenta como algo atractivo para nuestro país (INEI, 2022).

Sin embargo, el seguimiento del cultivo a la palta Hass, se viene desarrollando tradicionalmente, usando el suelo como factor de propagación, según el SENASA, existen una serie de causas que pueden afectar el crecimiento normal de las plantaciones de palta y que sino son detectadas oportunamente, pueden ocasionar un nivel de calidad bajo (SENASA, 2017). Asimismo, el mal uso brindado al suelo ha desencadenado una variedad de inconvenientes, entre ellos, las deficiencias nutricionales, tales como, el Nitrógeno, Fósforo, Potasio, Magnesio y Manganeso; que influye para el crecimiento normal de cada una de las plantaciones, y por lo tanto reduce la producción y calidad del fruto (Novoa et al., 2018).

En la región norte el país, resalta los estudios realizados para la variedad de paltas Hass, aplicando computación visual, la precisión en la clasificación aumentó hasta 65.4% en las de tipo I, agilizando las operaciones y mejorando la productividad de la cosecha (García, 2019).

Actualmente la empresa Agrícola Mapa S.A.C, realiza la detección de síntomas visuales de deficiencias nutricionales en las plantas por medio de una persona experta en el campo, para así lograr identificar con anticipación posibles daños que puedan perjudicar el éxito del establecimiento (lugar de producción agrícola), aun así, a los operadores se les encarga realizar este tipo de actividad lo cual representa un problema debido a las discrepancias que puedan existir, al momento de la detección de los síntomas, de un juicio a otro ocasionando una mala interpretación del análisis de estado nutricional de las plantaciones provocando pérdidas en la producción, esto aunado al tiempo que demanda la obtención de los resultados, sin contar el número de veces que podría incurrir tomas adicionales, lo cual conlleva a un costo alto al realizar esta actividad programada.

Referente a los estudios desarrollados para la Computación Visual, así como la detección de síntomas visuales, se tienen los siguientes artículos:

Los autores Dairath et al. (2023) en el artículo, preparado en Pakistan “Computer vision-based prototype robotic picking cum grading system for fruits” se plantearon el objetivo desarrollar un prototipo de sistema robótico de recolección y clasificación que integra la recolección robótica y los procesos de clasificación basados en reconocer la calidad de la fruta, para lograrlo la detección de frutos, los pasos incluyeron la conversión de esquema de color, enmascaramiento de piel normal/fresca, enmascaramiento de defectos y operaciones de dilatación morfológica; usando el lenguaje Python para el desarrollo de la propuesta. Como resultado se tiene que el brazo fabricado tarda para conversión de esquema de color, segmentación, operaciones morfológicas y operaciones bit a bit, respectivamente; y el tiempo total para el esquema completo es 0.0125 segundos. Los autores concluyen que la propuesta agiliza los tiempos de detección de inconvenientes en plantas.

Otro estudio de Li et al. (2022) en USA, “Barriers to computer vision applications in pig production facilities” tuvo como objetivo ayudar a catalogar y considerar los principales obstáculos del uso eficaz de las tecnologías visión por computadora ofreciendo un análisis sistemático. El desarrollo tuvo 3 componentes (i) Desafíos de las aplicaciones de visión computacional; (ii) Uso de algoritmos; (iii) construcción de datasets para desarrollar algoritmos de visión computacional, destacando los algoritmos: DeepLabv3, CClusnet, Faster R-CNN. En cuanto al resultado se presentan datos para futuras investigaciones con visión por computadora y, barreras existentes en su aplicación. El estudio concluye destacando las oportunidades de aplicar la visión por computadora en los procesos de crianza.

Sapkota et al. (2023) en su artículo “Towards reducing chemical usage for weed control in agriculture using UAS imagery analysis and computer vision techniques”, preparado en USA, tuvieron el objetivo de realizar un control de malezas específico del sitio (SSWC) en un campo de maíz. Para ello desarrollaron los siguientes pasos: (1) el uso de un sistema aéreo no tripulado (UAS) para mapear la información de distribución espacial de las malezas; (2) crear un mapa de prescripción de distribución de malezas y (3) rociar el campo usando el mapa de prescripción. Como resultado usando el enfoque SSWC, evitaron que el 26,2 % de la superficie en acres fuera rociada con herbicida. Concluyeron que se puede ahorrar incluso en una situación con una alta infestación de malezas, lo que podría brindar una oportunidad para reducir la cantidad de químicos.

Nadafzadeh y Mehdizadeh (2019) en su artículo, preparado en Irán, tuvo como objetivo el diseño y desarrollo de un sistema inteligente, con Red Neuronal Artificial (ANN) y visión artificial para optimizar el crecimiento de las plantas. Para ello se extrajeron características de color, morfológicas y texturales de un conjunto de imágenes de plantas de césped en condiciones de sequía y se analizaron para determinar el requerimiento de agua de la planta y se aplicó el algoritmo ANN. Entre los resultados tenemos la precisión del clasificador para tres situaciones de planta (fresca, al borde de la marchitez y marchita) así como su precisión total fueron 91,3, 77,8, 97,9 y 90,7%, respectivamente. Los autores concluyen que un sistema de riego automatizado puede medir y determinar la condición de marchitez de la planta.

De los autores Tripathi y Maktedar (2020) en su estudio “A role of computer vision in fruits and vegetables among various horticulture products of agriculture fields: A survey”, preparado en la India, analizaron como se relaciona las frutas y verduras con otros productos hortícolas agrícolas, el desarrollo metodológico

involucró el análisis de las encuestas centrándose en la comparación de diferentes enfoques de aprendizaje automático con respecto a diferentes métricas de rendimiento en el mismo conjunto de datos. Como resultado se tiene que, de las técnicas de aprendizaje automático existentes, el SVM (Support Vector Machine) presenta una precisión de 96.47% mejor precisión de clasificación, sobre KNN (K-nearest neighbors), los valores obtenidos para SVM y KNN fueron 92,5% y 82,2%. Tuvieron como conclusión que la visión por computadora juega un papel importante y tiene un gran potencial para abordar los desafíos relacionados con los campos agrícolas.

GHERGAN (2021) en su artículo “THE ROLE OF COMPUTER VISION IN SUSTAINABLE AGRICULTURE”, de Rumanía, buscó como objetivo identificar aspectos de métodos de aplicación de la visión por computador, resaltando el avance de la innovación agrícolas, basada en gestión de datos. El desarrollo del estudio se basó en un recorrido por los métodos reales de procesamiento de imágenes y visión por computadora que podrían usarse más intensamente en agricultura campo. Entre los resultados destaca la propuesta de técnicas de clasificación para frutas usando algoritmos de aprendizaje automático basados que ayudan a detectar y clasificar la calidad de la fruta. El estudio concluye que la innovación agrícola, con análisis de datos ayuda en el avance de los retos de la agricultura y producción de alimentos.

Donmez et al. (2021) en su investigación de Alemania, tuvo como objetivo diseñar un algoritmo de componentes que se conectan (CCL) para detectar y contar los árboles de cítricos. Para el desarrollo del trabajo se aplicó algoritmos de operación de imágenes morfológicas sobre imágenes ortofotográficas multiespectrales de 5 bandas. El resultado refleja un conteo de 1462 de 1506 árboles, con una exactitud y precisión superiores al 95 %. Los autores concluyen que su propuesta proporcionó un

desempeño satisfactorio para predecir el número de árboles (en el caso de estudio de cítricos) en parches densos.

Xiang y Wang (2023) en su artículo “A review of three-dimensional vision techniques in food and agriculture applications”, de USA, siguen el objetivo de presentar una variedad de técnicas de imágenes en 3D, para aplicarlo en agricultura y sistemas alimentarios. Para ello incluyen imágenes 3D basadas en la iluminación de la estructura, sistema de imágenes 3D Multiview, sistema de imágenes 3D basado en el tiempo de vuelo. El resultado del estudio indica luego de aplicar imágenes 3D con visión computacional, se mejoran los tiempos de respuesta y frecuencias de muestreo. El estudio concluye que las técnicas de imágenes en 3D tengan mayor aplicación en la era de la agricultura de precisión y la fabricación de alimentos de forma autónoma y basada en datos.

Narciso y Manzano (2021) en su artículo “Sistema de visión artificial basado en redes neuronales convolucionales para la selección de arándanos”, elaborado en Perú, sigue el objetivo de detectar defectos en los arándanos a través de visión artificial. Para el desarrollo se trabajó con uno de los modelos para detección Faster R-CNN basado en redes neuronales, que incluyó la creación de base datos con el preprocesamiento de imágenes obtenidas. Los resultados a opinión de expertos, ayudan en la selección de los arándanos, con una alta precisión. El autor concluye que al usar el criterio IoU (intersección sobre unión) se determina una mayor precisión al sistema propuesto.

Los autores Patrício y Rieder (2018) en su artículo “Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review”, realizado en Brasil, cuyo objetivo fue la identificación de la aplicabilidad de la visión artificial en el área agrícola de precisión para producir granos: maíz, arroz, trigo, soja

y cebada. Para el desarrollo del estudio se seleccionaron artículos con diferentes enfoques relacionados con la detección de enfermedades, calidad del grano y fenotipado. Como resultado se identificaron alternativas, como la explotación de GPU (Graphics Processing Unit) y técnicas avanzadas de inteligencia artificial, como DBN (Deep Belief Networks) para preparar métodos robustos de visión artificial aplicado a la agricultura. Se concluye que la visión computacional ayuda en identificar en forma precisa los granos.

Tian et al. (2020) en su artículo “Computer vision technology in agricultural automation: A review”, preparado en China, tiene el objetivo de resumir y analizar sistemáticamente las tecnologías y los desafíos explorando oportunidades y perspectivas de orden futuro en aplicar visión computacional. Se desarrolló evaluando 4 factores: objetivos, métodos adoptados, tipos de sensores y resultados obtenidos. En cuanto al resultado se determinó que la tecnología existente puede ayudar al desarrollo de la automatización agrícola presentando ventajas de bajo costo, alta eficiencia y alta precisión. El estudio concluye, que la visión computacional se usará ampliamente para resolver problemas agrícolas, y mejorar el rendimiento económico, general y robusto de los sistemas de automatización agrícola.

Sulistyo et al. (2018) en su artículo “Computational Deep Intelligence Vision Sensing for Nutrient Content Estimation in Agricultural Automation”, preparado en Inglaterra, su objetivo fue aplicar la visión computacional para estimar los nutrientes en hoja de trigo. Para su desarrollo, se extraen cuatro momentos de la distribución del color de las imágenes de las hojas (media, varianza, asimetría y curtosis) y se utilizan como predictores una técnica precisa, simple y de bajo costo que ayuda a estimar el contenido de nitrógeno en las hojas de trigo analizando las imágenes del color RGB de las imágenes de las hojas. Los resultados han demostrado la superioridad del

método propuesto en términos de calidad y velocidad de procesamiento en todos los pasos, es decir, normalización de color, segmentación de imágenes y predicción de nutrientes, en comparación con otros métodos existentes.

Los autores Amin y Awang (2018), en la investigación “Automated Detection of Nitrogen Status on Plants: Performance of Image Processing Techniques”, preparado en la India, tuvieron como objetivo determinar el estado del nitrógeno de la hierba napier haciendo uso del procesamiento de imágenes. Para lograrlo se consideraron factores al adquirir la imagen como un formato de fotografía, donde se utilizó un equipo digital para capturar la imagen con condiciones de iluminación constante. Los resultados fueron que hubo un 100% de precisión utilizando el árbol de decisión, mientras que el clasificador KNN mostró un 95% de precisión, por lo que se llegó a la conclusión de que al aplicar alguna técnica para procesar imágenes se alcanza la capacidad de ayudar a los agricultores locales con herramientas prometedoras para determinar el estado de nitrógeno de las hojas de las plantas, y así alcanzar una menor merma al recolectar los productos finales.

Se tiene a los autores Lu y Young (2020) en su propuesta “A survey of public datasets for computer vision tasks in precision agriculture”, elaborado en USA, donde el objetivo es realizar una revisión integral de conjuntos de datos de imágenes recopilados en condiciones de campo para facilitar la agricultura de precisión, incluyen datos sobre control de malezas, sobre detección de frutas y otros datos sobre aplicaciones diversas. En cuanto a la metodología aplicada, se seleccionaron 34 dataset con los que se desarrolló la propuesta. El resultado permite a los investigadores la selección rápida de los conjuntos de datos apropiados de acuerdo a sus necesidades para permitir tareas de agricultura de precisión. El documento concluye que la encuesta es valiosa para la comunidad seleccionando conjuntos de

datos de imágenes adecuados para desarrollar algoritmos e identificar dónde se necesita crear nuevos conjuntos de datos de imágenes en apoyo a la agricultura.

Se tiene el artículo de Owino (2023) titulado “Challenges of Computer Vision Adoption in the Kenyan Agricultural Sector and How to Solve Them: A General Perspective”, elaborado en China, cuyo objetivo fue identificar los desafíos que dificultan la implementación de la tecnología de visión artificial en el sector agrícola de Kenia y proponer posibles soluciones para abordar estos desafíos. Para el desarrollo del estudio se ejecutó: inventario de unidades, recolección de fotos y vídeos, procesamiento, aplicación del modelo. Como resultado, el estudio sirvió de base para que el gobierno aumente la aplicación de la visión computacional facilitando la creación de empresas subsidiadas y con beneficios fiscales. El autor concluye indicando que el gobierno también debe invertir en educación, la investigación y el desarrollo para guiar a las personas a obtener habilidades importantes en visión artificial.

Los *autores* Zaman et al. (2019) en su artículo “*Cost-effective visual odometry system for vehicle motion control in agricultural environments*”, preparado en Noruega, tuvieron el *objetivo* de diseñar un sistema de odometría visual monocular confiable y rentable, debidamente calibrado para la localización y navegación de vehículos rastreados en terrenos agrícolas. Para el *desarrollo* del algoritmo aplicaron un hardware simplificado y un sistema mecánico de baja complejidad, sin comprometer el rendimiento. Como *resultado* diseñaron e implementaron un algoritmo mejorado para el proceso de imágenes, basado en el enfoque de correlación cruzada, *concluyeron* que el método propuesto es efectivo e idóneo para soluciones de control automático en aplicaciones de agricultura de precisión.

Así mismo los autores Dhanya et al. (2022) en su investigación “Deep learning based computer vision approaches for smart agricultural applications”, preparado en la India, buscaron como objetivo ofrecer un resumen detallado de los avances actuales en la medición de las características externas de los productos avícolas basados en sistemas de visión por computador. En él la aplicación de la propuesta, recurrieron a la exploración de diversos artículos. Como resultado se muestra una variedad de aplicaciones de computación visual, que fueron clasificación, en función al peso y volumen de los productos avícolas, mejorando la eficiencia del proceso en 62.3%. *Concluyen* con la importancia que resulta la aplicación de la computación visual en la estimación del tamaño, peso y volumen de los productos avícolas.

Los autores Sharat et al. (2019), en la investigación “Image based Plant Disease Detection in Pomegranate Plant for Bacterial Blight”, preparado en la India, tuvieron como objetivo realizar una aplicación para identificar las infecciones de la planta de granada. Para lograrlo se desarrolló diferentes técnicas de procesamiento de imágenes para la detección de enfermedades en plantas. Los resultados fueron que de 450 imágenes bacterianas infectadas por tizón , 35 de ellas mostraron el nivel de infección por debajo del 20%(etapa inicial),72 imágenes mostraron una infección de 40% que indica que está apunto de contraer el tizón bacteriano y más del 80% indica que la fruta de la granada se ve afectada por el tizón bacteriano, por lo que se llegó a la conclusión de que este sistemas se puede utilizar para reemplazar el reconocimiento manual de enfermedades técnicas y dar algunas sugerencias.

Los autores Pavel et al. (2019), en la investigación “An Iot Based Plant Health Monitoring System Implementing Image Processing”, preparado en Malasya, tuvieron como objetivo identificar las dolencias de hojas de plantas junto a la

medición de la infección y comparar la calidad del suelo con la salud de las plantas a través del procesamiento de imágenes. Para lograrlo se diseñó el algoritmo de agrupamiento k-mean para fragmentar la imagen enferma de cada superpixel. El resultado fue que el algoritmo SVM funciona mejor implementando el método de segmentación de umbral Otsu con un 94.95% de precisión, por lo que se llegó a la conclusión de que agregando estas funcionalidades del procesamiento de imágenes para cualquier industria agroindustrial actual pueden posiblemente reconocer increíblemente el bienestar de las plantas y estén listos para tomar decisiones más rápidas.

Velesaca et al. (2021) en su artículo “Computer vision based food grain classification: A comprehensive survey”, elaborado en Ecuador, tuvo como objetivo presentar una encuesta exhaustiva sobre técnicas recientes de clasificación de granos alimentarios basadas en visión por computadora. Para su desarrollo se incluyen enfoques de última generación destinados a analizar diferentes variedades de granos, con la estrategia que se usa en la generación de datos reales (destacando, imágenes sintéticas y de tipo real). Como resultado indica que al usar imágenes sintéticas no se necesita etiquetar los datos por parte de un experto, la nitidez dependerá del equipo que se use para capturar las imágenes. Como conclusión el problema de la clasificación de granos alimenticios está relacionado con el tipo de datos a procesar y es importante delinear este aspecto.

El presente estudio, tiene justificación en el aspecto teórico porque su aplicación es de utilidad para posteriores investigaciones para un adecuado procesamiento de imágenes en la detección de síntomas visuales de deficiencias nutricionales que permitirá un mayor control eficiente sobre las mismas que afectan a las plantaciones de palta, ayudando de esta manera a la empresa Agrícola Mapa

S.A.C. Asimismo, desde el aspecto económico se justifica, dado que servirá a la empresa para llevar un mayor control en la detección de síntomas visuales que muestre algún tipo de deficiencia nutricional en las plantaciones de palta, lo cual redundará en la disminución de costos. De esta manera se justifica socialmente, dado que el producto permitirá llegar en mejores condiciones a los consumidores recibiendo productos de mejor calidad, en cuanto a la justificación aplicada los agricultores disminuirán sus procesos repetitivos en la detección de deficiencias nutricionales, de tal manera que los operarios o personas expertas puedan encargarse de poner su esfuerzo en otros procesos. Asimismo, desde el enfoque ambiental se justifica, dado que la detección se enfocará en cuidado del agua y ambiente, ya que, debido a los recientes cambios ecológicos en el agua producidos por la actividad económica humana, el desarrollo de las plantaciones de palta se ha visto afectado, además, de ofrecer una mirada integral sobre el daño ambiental producido por el crecimiento económico no sustentable, ayudando a la concientización de la población local.

Se identificaron las limitantes siguientes, para desarrollar el proyecto:

Se tomó como limitación con respecto a la variable síntomas visuales la parte de deficiencias nutricionales que englobará solo la evaluación del nitrógeno(N), hierro (Fe) y fósforo (P) como principales nutrientes. Además de todos los tipos de plantaciones que existen en el lugar de estudio, solo se realizará a las plantaciones de palta hass (*Persea americana*).

Se definieron las siguientes restricciones para desarrollar el estudio: La seguridad de la empresa Agrícola Mapa S.A.C impide el correcto cumplimiento de la toma de medidas, por lo que se coordinó con el vigilante para el acceso a la empresa y el control de los animales (perros) del cuidado.

En conjunto, este estudio incluye los conceptos:

**Visión computacional:** también denominada visión artificiales considerada una parte de la inteligencia artificial que busca el diseño de sistemas informáticos con capacidad para comprender los componentes y características de real imagen. Estas aplicaciones ayudan en la extracción de datos numéricos y simbólicos, partiendo del reconocimiento de elementos y estructuras que se presentan en la imagen (Valencia et al., 2020)

Para llevarlo a cabo se comprende cuatro actividades principales (Díaz y Kurka, 2020):

- **Captura:** Adquirir imágenes, con cámara fotográfica u otro dispositivo a fin.
- **Pre-procesamiento:** se trata las imágenes destacando probables zonas de interés, eliminando información sin relevancia.
- **Segmentación:** Aislar regiones de interés para un análisis e interpretación.
- **Reconocimiento:** Identificar y clasificar elementos y estructuras en las regiones relevantes.

La visión artificial se relaciona de manera estrecha, con técnicas de proceso de imágenes y para reconocer patrones. Las primeras son usada para ayudar a localizar y detectar áreas útiles en imágenes; las segundas ayudan a la identificación y clasificación de elementos y estructuras que se detectan de acuerdo a sus características (Sánchez et. al, 2016).

**Procesamiento de imágenes:** Las esferas de aplicación primordial se centran en optimizar la representación visual para facilitar su interpretación por parte de los seres humanos, así como en el procesamiento de datos de imágenes para la percepción computacional. Este proceso implica la captura de imágenes o fotogramas

de videos, donde se extraen características específicas para generar un nuevo elemento (imagen) como resultado. (Ramírez, 2006).

**Fases para el procesamiento de imágenes:** El procesamiento digital de imágenes (PDI) está dividido en seis áreas principales (Herra, 2018)

- La adquisición implica el procedimiento mediante el cual se adquiere una imagen digital mediante el uso de una cámara digital, videocámara, satélite, entre otros.
- El preprocesamiento abarca técnicas que incluyen reducir el ruido, mejora del contraste, resalte de detalles específicos o propiedades de la imagen.
- La segmentación consiste en dividir imágenes en objetos que interesen al estudio.
- La descripción es un proceso de obtener propiedades útiles para distinguir un tipo de elemento de otros, en base al tamaño, forma, área, etc.
- La clasificación es el proceso para identificar elementos, como: llaves, tornillos, monedas, un automóvil, etc.
- La interpretación es el proceso que asigna significado a un conjunto de objetos reconocidos (llaves, tornillos, herramientas, etc.) y busca emular la cognición.

**Imagen digital:** Se muestra como una función bidimensional  $f(x, y)$ ,  $-x$  e  $y$  representan coordenadas del plano-, y la amplitud  $f$  se identifica como la intensidad en dicho punto. Cuando  $(x, y)$  y  $f$  son valores finitos (valores discretos), la función se denomina imagen digital. En términos simples, una imagen digital se compone de un conjunto limitado de elementos conocidos como píxeles, cada uno tiene valor y una posición específica. Este valor se asocia a alguna propiedad del punto que representa, como su brillo o matiz. (Herra, 2018).

**Píxel:** Abreviación de Picture element o componente de imagen, es la cantidad mínima de información en una imagen y se visualiza como punto en pantalla o en un dispositivo de impresión. (Herra, 2018).

**Formatos de Imagen Digital:** Los de mayor uso se consideran: TIFF, BMP, GIF, JPEG y PNG.

**Clasificación de las imágenes digitales:** Dentro de esta clasificación se menciona: Imágenes RGB, que emplean tres canales para mostrar colores de pantalla, con 8 bits por canal, totalizando 24 bits de color por píxel y permitiendo hasta 16.7 millones de colores. Imágenes en escala de grises, que utilizan varios tonos de gris en un rango de 0 a 255. Imágenes binarias, que consideran como profundidad de color 1 bit (blanco o negro) para representar la imagen. (Herra, 2018).

**Modelo RGB:** cada uno de los colores se desglosa en sus elementos espectrales principales de rojo, verde y azul. Las imágenes que siguen este modelo consisten en tres componentes de imagen, uno para cada color primario. La cantidad de bits utilizados para representar cada píxel en el espacio RGB se conoce como profundidad de píxel. Por lo tanto, una imagen RGB en la que cada componente de rojo, verde y azul tiene una profundidad de 8 bits tiene una profundidad total de 24 bits, ya que cada píxel se representa como una tripleta de valores (R, G, B), lo que permite un total de  $2^{24} = 16,777,216$  colores (Herra Gómez 2018).

**Modelo HSV:** Los modelos RGB y CMY carecen de utilidad práctica para describir colores de manera comprensible para la interpretación humana. Por ejemplo, al describir el color de un automóvil, las personas no utilizan porcentajes de los colores primarios, sino que emplean términos como tono (H), saturación (S) e intensidad o brillo (I). Aunque este modelo no es comúnmente usado para

descripciones cotidianas, tiene aplicaciones prácticas en el diseño de sistemas automáticos para evaluar la madurez de frutas y verduras, así como en sistemas para comparar muestras de color o inspeccionar la calidad de productos coloreados. (Herra, 2018).

También tenemos información de la variable Detección de sistemas visuales:

**Detección de síntomas visuales:** generalmente, es realizada mediante la evaluación visual para el diagnóstico. En este proceso, se observa y compara visualmente el aspecto de las plantas que muestran síntomas de deficiencia o exceso de uno o más elementos con respecto a las plantas que se consideran "normales" en términos de su nutrición. Para este propósito, las hojas son comúnmente utilizadas y, en algunas ocasiones, se pueden examinar otros órganos como las raíces o los frutos, dependiendo del elemento en cuestión (Sadeghian, 2017).

**Deficiencias nutricionales:** En los estudios agrícolas, se han llevado a cabo diversos estudios mediante la técnica de deficiencia de nutrientes. A través de esta metodología, se ha identificado la presencia de más de 100 elementos químicos, de los cuales 17 se consideran esenciales para el desarrollo de las plantas. Estos elementos esenciales son indispensables para el ciclo de vida de las plantas, ya que desempeñan un papel crucial en las funciones de crecimiento y reproducción. Su ausencia impide que las plantas completen su ciclo vital y resulta vital para la supervivencia de la mayoría de las especies vegetales. Los nutrientes minerales se dividen en macronutrientes y micronutrientes. (Gorziglia et al., 2019)

En cuanto a las dimensiones de la visión computacional tenemos:

**Ejecución del proceso:** permite medir el rendimiento en que se ejecutarán las actividades programadas. Determina el tiempo invertido que se inicia con la actividad hasta que termina la actividad programa (Zaman et al., 2019);

Se tiene los siguientes indicadores

- **Detección:** donde la formula usada para realizar el cálculo es la siguiente:
- **Satisfacción:** donde la formula usada para realizar el cálculo es la siguiente

**Eficiencia:** es una comparación entre el resultado obtenido a partir de un conjunto de actividades programadas (Gorziglia et al., 2019)

En cuanto a los indicadores tenemos:

- Indicador del Tiempo (ITP)
- Indicador del Costo (ICT)

## **Metodologías Ágiles**

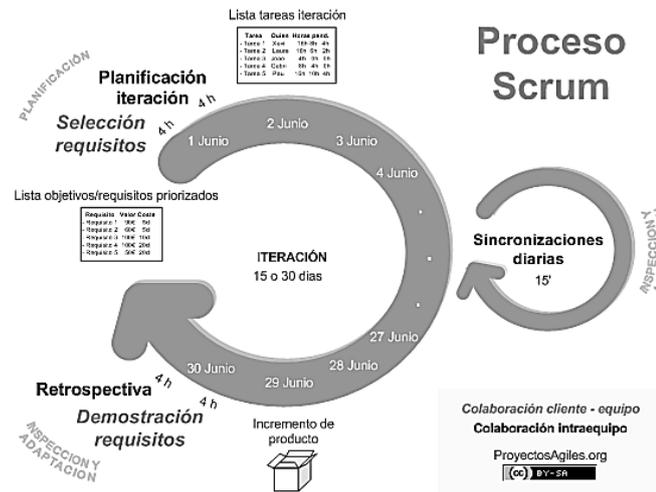
La fortaleza de metodologías ágiles se encuentra en llevar a cabo un proyecto de desarrollo mediante la aplicación de una estructura que define pasos a seguir, con entregas parciales del proyecto. Estas metodologías asignan roles clave a cada miembro del equipo de desarrollo, buscan optimizar el uso del tiempo y los recursos, emplean un enfoque de desarrollo por iteraciones y persiguen obtener una comprensión total de las expectativas del cliente. El objetivo final es entregar un producto final que se asemeje lo más posible a lo deseado por el cliente (Flores-Cerna et al. ,2021).

## **Metodología de desarrollo SCRUM**

Es un método ágil para el desarrollo de software que adopta un enfoque incremental. Establece roles y utiliza un conjunto de reglas y elementos que forman parte de una

estructura esencial para su eficaz implementación. Durante cada iteración, se manejan los siguientes elementos (Flores et al. ,2021):

**Figura 1. Fases de SCRUM**



*Nota:* datos extraídos de Chantit y Essebaa (2021)

**Product Backlog:** Inventario de requerimientos delineados y especificados por el cliente, organizado en términos de valor y prioridad. Esta lista se modifica a lo largo del proyecto y se construye en base a las narrativas que el usuario propone en relación con las funciones del producto.

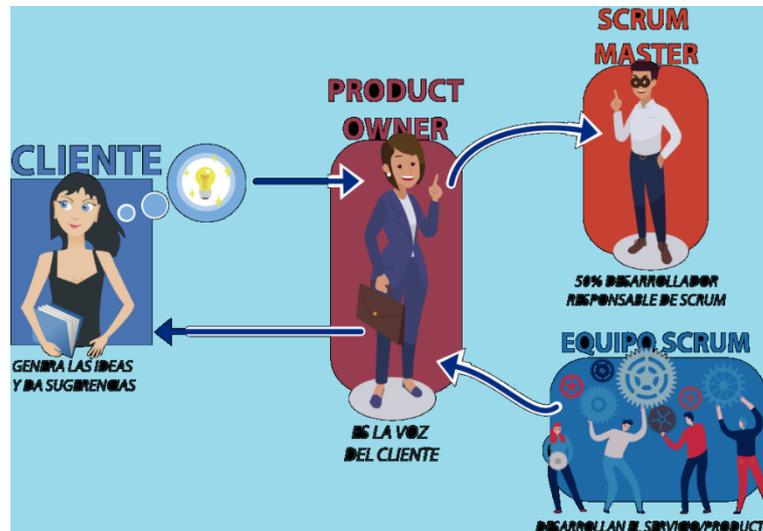
**Sprint Backlog:** Constituye una parte más detallada del Product Backlog, comprendiendo un subconjunto de tareas. Cada modificación necesaria se incorpora en el próximo Sprint Backlog según su nivel de prioridad.

**Monitoreo de Progreso:** Es la suma del trabajo que falta realizar en el Sprint. Permite evaluar el progreso del proyecto.

**Incremento:** Corresponde a la acumulación de todas las tareas completadas en el Sprint Backlog. Se considera que una tarea está finalizada si es funcional y cumple con los requisitos establecidos por el cliente.

SCRUM divide su equipo de trabajo en los siguientes grupos (García et al.,2022)

**Figura 2** Equipo de Trabajo SCRUM.



Nota: información de García et al. (2022)

**Prueba de Normalidad:** sirve para conocer si los datos recolectados, que forma para de una investigación provienen de una población distribuida normalmente o no, y sobre su resultado se aplicará una prueba estadística inferencial respectivo (Hernández y Mendoza ,2018).

**Prueba t-student:** ayuda a verificar las diferencias de dos muestras independientes con una distribución normal y homogeneidad de sus varianzas (Sánchez, 2015)

**Prueba de Wilcoxon:** es usada para la comparación de medias dos grupos independientes, que siguen una distribución no normal (Turcios, 2015).

## 1.2 Formulación del problema

¿De qué manera influye una aplicación de visión computacional en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023?

### Preguntas específicas

- ¿De qué manera influye una aplicación de visión computacional en la ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023?
- ¿De qué manera influye una aplicación de visión computacional en la eficiencia de la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023?

## 1.3 Objetivos

### 1.3.1. Objetivo general

Establecer la influencia de la aplicación de visión computacional en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.

### 1.3.2. Objetivos específicos

- Determinar la influencia de una aplicación de visión computacional en la eficiencia de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.
- Determinar la influencia de una aplicación de visión computacional en la ejecución del proceso de detección de síntomas visuales de las plantaciones de palta para la Agrícola Mapa SAC, 2023.

## 1.4. Hipótesis

La aplicación de visión computacional influye positivamente en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Las hipótesis específicas son:

- La aplicación de visión computacional no influye positivamente en la ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023
- La aplicación de visión computacional influye positivamente en la eficiencia de la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.

## CAPÍTULO II. METODOLOGÍA

### 2.1. Tipo de investigación

**Según el enfoque:** es cuantitativo, dado que los datos recolectados fueron de forma objetiva, que ayudaron a la respuesta de la pregunta de investigación

**Según el propósito:** es aplicada, dado que percibió la generación de nuevo conocimiento, para aplicarse a solucionar el problema organizacional

**Según su alcance:** es explicativa, dado que explica la ocurrencia de un fenómeno específico y determinando la influencia de la visión computacional en la detección de síntomas de las plantaciones.

**Diseño de investigación:** experimental, pre-experimental, dado que se manipula la variable independiente (visión computacional) sobre la variable dependiente (detección de síntomas). Sigue el esquema:

$$G: O_A \times O_B$$

Donde:

**G<sub>A</sub>:** grupo imágenes de plantones de palta.

**O<sub>A</sub>:** Observación previa sin la aplicación.

**O<sub>B</sub>:** Observación posterior con aplicación.

**X:** Aplicación de visión computacional.

### 2.2. Población y muestra

#### Población

Todas las hectáreas de la empresa Agrícola Mapa SAC que hace un total de 140 hectáreas.

## Muestra

La muestra del estudio fue no probabilística y consistió en todas las hectáreas que eran parte únicamente la zona Salitre las que hicieron un total de 10 hectáreas. Los elementos de la muestra fueron seleccionados teniendo en cuenta aquellas entradas ubicadas en la entrada del terreno, así que fueron acogidas por conveniencia.

### 2.3. Técnicas e instrumentos de recolección y análisis de datos

#### Recolección de datos

##### Técnicas

Para la recolección de datos se usó la técnica de observación.

##### Instrumentos

De acuerdo con la técnica aplicada, el instrumento utilizado fue la ficha de observación.

VARIABLE	DIMENSIÓN	INDICADOR	INSTRUMENTO	DESCRIPCIÓN
<b>Detección síntomas visuales</b>	Ejecución del proceso	% Detección	Ficha de observación	Esta ficha buscó la recolección de la eficacia que tomó cada visualización de la planta. Los datos fueron tomados por los investigadores
		%Satisfacción	Cuestionario	Este cuestionario buscó la recolección de la satisfacción de las personas respecto a la solución propuesta. Los datos fueron tomados por los investigadores
	Eficiencia	Tiempo	Fichas de observación	Esta ficha buscó conocer el tiempo que tomó cada visualización de la planta. Los datos fueron tomados por los investigadores
		Costo	Fichas de observación	Esta ficha buscó la recolección del costo que tomó la visualización de las plantas. Los datos fueron tomados por los investigadores

## **Análisis de datos**

Para el análisis de datos se tabularon los datos en Excel y luego la herramienta estadística SPSS, donde trabajó la estadística descriptiva, para preparar cuadros con sus sumatorias, valores máximos y mínimos. Posteriormente se desarrolló la estadística inferencial, donde luego de aplicar la prueba de normalidad, se aplicó la prueba de comparación de muestras T student.

### **2.4. Procedimiento**

A fin de poder preparar los instrumentos respectivos, se elaboró previamente la matriz de operacionalización (Anexo 02), en la cual se definieron las dimensiones con los indicadores respectivos, procediéndose elaborar los instrumentos bajos las consideraciones respectivas.

- Para el indicador del tiempo, fueron considerados los datos siguientes: el número de hectárea, la fecha de toma, la hora de inicio de la tarea y la hora final de la misma, incluyendo adicionalmente una columna para observaciones. El fin del instrumento es determinar los tiempos que duran el realizar la tarea de detectar los síntomas visuales; el instrumento elaborado fue la Ficha de Registro de Tiempos, la misma que se puede observar en el anexo 03 – instrumento 1
- Para el indicador del costo, fueron considerados los datos siguientes: el número de hectárea, la fecha de toma, la hora de inicio de la tarea y la hora final de la misma, y el costo hora hombre, incluyendo adicionalmente una columna para observaciones. El fin del instrumento es determinar el costo que demanda la tarea de detectar los síntomas visuales; el instrumento elaborado fue la Ficha de Registro de Costo, la misma que se puede observar en el anexo 03 – instrumento 2
- Para el indicador de detección fueron considerados los datos siguientes: el número de hectárea, la fecha de toma, la cantidad de plantaciones y la cantidad de

plantaciones detectadas, incluyendo adicionalmente una columna para observaciones. El fin del instrumento es determinar detectar el porcentaje de síntomas visuales que tiene una determinada área; el instrumento elaborado fue la Ficha de Registro de detección, la misma que se puede observar en el anexo 03 – instrumento 3

- Para el indicador de satisfacción, fueron considerados los datos siguientes: la interrogante, y las preguntas, a modo de escala de Likert (que fueron de 1 a 5 ). El fin del instrumento fue determinar el nivel de satisfacción con respecto a cómo se detectan los síntomas visuales, se elaboró el Cuestionario de Satisfacción, la misma que se puede observar en el anexo 03 – instrumento 4.

Los instrumentos fueron validados por el ingeniero Gustavo Sosa Calderón en el documento de matriz de validación, en este documento se verificó que la variable dependiente tenga relación con sus dimensiones y estas con sus indicadores identificados.

Luego de tener la conformidad de los instrumentos respectivos, se procedió a su aplicación y recolección de datos como parte del pre-test, de acuerdo a los indicadores definidos, el área de trabajo asignada fue la zona “El Salitre”, propiedad de la empresa “Agrícola Mapa S.A.C”, el cual tiene un área de extensión de 10 hectáreas, asimismo, el cual cumple con las mismas condiciones de suelo dedicadas al cultivo de palta Hass (persea americana). Se recolectan los datos antes de la aplicación, es decir, la forma tradicional, como se viene trabajando con la ayuda del especialista agrónomo, quien detecta a base de su experiencia, los síntomas que pueden alcanzar las plantaciones de palta, y partir de los mismos se realiza el cálculo de los indicadores.

- Para determinar los tiempos asociados a la tarea de detección de síntomas visuales, se registraron los datos, en la ficha de registro de tiempos. Estos datos fueron obtenidos a partir de las labores realizadas por un ingeniero agrónomo, experto del negocio, que la empresa le encomienda la responsabilidad, y que realiza los recorridos respectivos.

Para el cálculo del indicador del tiempo, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 – A

$$TPAI = \frac{\sum_{i=1}^n TAI}{n}$$

TPAI = Tiempo promedio de tarea realizada

TAI: Tiempo total de tarea realizada

n: Número de tomas realizadas

Estos fueron los valores obtenidos

**Tabla 1.**

*Indicador del Tiempo- Pretest*

Hectárea	Nro tomas n	Tiempo total TAI (min)	Tiempo Promedio TPAI (min)
1	3	351	117
2	3	346	115
3	3	340	113
4	3	280	93
5	3	284	95
6	3	322	107
7	3	358	119
8	3	263	88
9	3	331	110
10	3	292	97

- Para determinar los costos asociados a la tarea de detección de síntomas visuales, se registraron los datos, en la ficha de registro de costos, a partir de los datos

recolectados en la hoja de tiempos. Estos datos obtenidos fueron valorizados a partir del costo hora hombre usado que se paga al experto al realizar esta tarea de visualización. El costo de mano de obra se ha realizado en base al ingreso de S/. 3500.0 que percibe al mes el responsable de esta labor, además se considera 26 días, 8 horas por días y 60 minutos la hora, lo que hace un valor de S/. 0.280449/min.

Para el cálculo del indicador del tiempo, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 - B

$$CTR = \frac{\sum_{i=1}^n TAI * CT}{\dots}$$

CTR = Costo de tarea realizada

TAI: Tiempo total de tarea realizada

CT = Costo de mano de obra

Estos fueron los valores obtenidos

**Tabla 2.**

*Indicador de Costo. Pretest*

Hectárea	Nro tomas	Tiempo (min)	Costo (S/.)
1	3	351	98.44
2	3	346	97.04
3	3	340	95.35
4	3	280	78.53
5	3	284	79.65
6	3	322	90.30
7	3	358	100.40
8	3	263	73.76
9	3	331	92.83
10	3	292	81.89

- Para determinar el indicador de detección de síntomas visuales, se registraron los datos, en la ficha de registro de detección, a partir de los datos recolectados en la hoja de detección. Estos datos fueron analizados por el experto, ingeniero

agrónomo, en donde a partir de la cantidad de plantaciones, detectó síntomas en las plantaciones, el indicador de detección fue calculado a partir de las plantaciones detectadas y el total de plantaciones de cada hectárea.

Para el cálculo del indicador de detección, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 - C

**Ecuación 1.** *Indicador de detección (IDE)*

$$IDE = \frac{\text{Número Plantaciones Detectadas}}{\text{Total de Plantaciones}}$$

Estos fueron los valores obtenidos

**Tabla 3.**

*Indicador de Detección de Síntomas. Pretest*

Hectárea	Nro tomas	Promedio Total de Plantaciones	Promedio Plantaciones Detectadas	% Detección (IDE)
1	3	1000	53.3	5.33%
2	3	1000	60.0	6.00%
3	3	1000	50.0	5.00%
4	3	1000	56.7	5.67%
5	3	1000	50.0	5.00%
6	3	1000	53.3	5.33%
7	3	1000	50.0	5.00%
8	3	1000	53.3	5.33%
9	3	1000	36.7	3.67%
10	3	1000	60.0	6.40%

- Para determinar el indicador de satisfacción, se registraron los datos, en la ficha de cuestionario, la misma que fue aplicado al personal del área; esta encuesta estuvo conformada por 6 preguntas, la cual estuvo basada en la escala de Likert, los resultados se basaron en la elección de estas 5 opciones: Muy Bueno (MB) equivalente a puntaje 5, Bueno (BN) equivalente a puntaje 4, Regular (RG)

equivalente a puntaje 3, Malo (ML) equivalente a puntaje 2 y Muy Malo (MM) equivalente a puntaje 1.

Para el cálculo del indicador de detección, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 - C

### Ecuación 2.

*Indicador de satisfacción (ISA)*

$$INS = \frac{\sum(\text{nroElección} * \text{Puntaje})}{n}$$

nroElección: son la cantidad de encuestados que elige una de las 5 opciones

n: número de encuestados, en este caso equivale a 5 personas

Tabla 4. Indicador del nivel de satisfacción

Nº	Pregunta	Opción(O) y Puntajes (P)					Puntaje Total (P) * (O)	Nivel Satisfacción (INS)
		MB	BN	RG	ML	MM		
		5	4	3	2	1		
1	¿Considera Usted, que es eficiente, la forma de detectar síntomas de anomalías en las plantaciones?	0	0	2	3	0	12	2.4
2	¿Cómo califica usted, la precisión de detectar anomalías en las plantaciones de palta?	0	0	3	2	0	13	2.6
3	¿Cómo considera el proceso de detección de síntomas de anomalías en las plantaciones de palta?	0	0	2	2	1	11	2.2
4	¿Cómo calificaría la gestión de la información para detectar anomalías en las plantaciones de palta?	0	0	1	4	0	11	2.2
5	¿Cómo considera usted, la dependencia a las personas en la detección de síntomas de anomalías en las plantaciones de palta?	0	0	1	4	0	11	2.2
6	¿Cómo califica usted, la forma de almacenamiento de los datos en la detección de síntomas de anomalías en las plantaciones de palta?	0	0	0	4	1	9	1.8

Para preparar la aplicación de visión computacional, se trabajaron los siguientes pasos, que se describen:

- 1) Se determinó la metodología de desarrollo de la aplicación, la cual es parte de la solución, mediante el siguiente cuadro comparativo:

**Tabla 5.**

*Comparación de metodologías de desarrollo de software.*

<b>Criterios</b>	<b>SCRUM</b>	<b>XP</b>	<b>RUP</b>
<b>Se aplica a proyectos de mediano o corto plazo</b>	SI	SI	NO
<b>Son elegibles las secuencias y prioridades de las actividades</b>	SI	SI	NO
<b>Flexibilidad</b>	SI	SI	NO
<b>Comunicación con el cliente</b>	SI	SI	SI
<b>Es usado por la rapidez al presentar avances</b>	SI	NO	SI
<b>Posee amplia documentación</b>	SI	NO	SI

Nota: Datos de (Navarro et al,2013)

De acuerdo a la evaluación realizada para definir la metodología de trabajo, se eligió SCRUM, entre otras razones principalmente por el tiempo corto que se tiene para la implementación del proyecto y satisfacer la necesidad del cliente.

## 2) Aplicación de la metodología

Al ir aplicando la metodología, se preparó la documentación respectiva, de acuerdo a las fases que propone SCRUM, la cual puede verse, detalladamente, en el anexo 05

El desarrollo metodológico incluyó la preparación del producto Backlog, desde el cual se definió la lista de requerimientos, y actividades principales, que se requieren para poder preparar la aplicación.

Luego, las actividades y funciones identificadas, fueron divididas en Sprints Backlogs, los mismo que fueron ejecutados y permitieron ver los avances y también los documentos entregables del producto, hasta que luego de terminar el desarrollo de los mismos, permitieron la implementación de la aplicación de visión computacional. Para el diseño de los prototipos se usó como herramienta el software Balsamic Mockups, en donde se indicó a los involucrados como serían las versiones finales del producto. Así mismo, luego de haber realizado el desarrollo de la aplicación, se procedió a preparar las pruebas respectivas, incluyendo los métodos y técnicas en las distintas fases del procesamiento de imagen, y realizando los ajustes respetivos que llevaron a tener una versión del producto más estable, que haga más efectiva las labores del proceso de detección de anomalías a los involucrados y tener una mejora en los indicadores establecidos.

Luego del desarrollo de la aplicación, se procedió a la medición de los indicadores establecidos, para ello se establecieron los recorridos en las 10 hectáreas, y con el uso de la aplicación de visión computacional en la detección de síntomas visuales. A continuación, se detallan las pruebas de Post-Test:

- 1) Para determinar los tiempos asociados a la tarea de detección de síntomas visuales, se registraron los datos, en la ficha de registro de tiempos. Estos datos fueron obtenidos a partir de los vuelos realizados, por el drón.

Para el cálculo del indicador del tiempo, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 –B (Indicador tiempo.Postest)

$$TPAI = \frac{\sum_{i=1}^n TAI}{n}$$

TPAI = Tiempo promedio de tarea realizada

TAI: Tiempo total de tarea realizada

n: Número de tomas realizadas

Estos fueron los valores obtenidos

Tabla 6.

*Indicador del Tiempo- Pretest*

Hectárea	Nro tomas n	Tiempo total TAI (min)	Tiempo Promedio TPAI (min)
1	3	70	23
2	3	76	25
3	3	77	26
4	3	76	25
5	3	71	24
6	3	69	23
7	3	81	27
8	3	82	27
9	3	85	28
10	3	73	24

- Para determinar los costos asociados a la tarea de detección de síntomas visuales, se registraron los datos, en la ficha de registro de costos, a partir de los datos recolectados en la hoja de tiempos. Estos datos obtenidos fueron valorizados a

partir del costo hora hombre usado que se paga al experto al realizar esta tarea de visualización.

Para el cálculo del indicador del tiempo, se aplicó la formula siguiente, a partir de los datos recolectados del Anexo 04 - B

$$CTR = \frac{\sum_{i=1}^n TAI * CT}{\square}$$

CTR = Costo de tarea realizada

TAI: Tiempo total de tarea realizada

CT = Costo de mano de obra

Estos fueron los valores obtenidos

### Tabla 7.

#### *Indicador de Costo. Pretest*

Hectárea	Nro tomas	Tiempo (min)	Costo (S/.)
1	3	70	19.63
2	3	76	21.31
3	3	77	21.59
4	3	76	21.31
5	3	71	19.91
6	3	69	19.35
7	3	81	22.72
8	3	82	23.00
9	3	85	23.84
10	3	73	20.47

- Para determinar el indicador de detección de síntomas visuales, se registraron los datos, en la ficha de registro de detección, a partir de los datos recolectados en la hoja de detección. Estos datos fueron analizados por el experto, ingeniero agrónomo, en donde a partir de la cantidad de plantaciones, detectó síntomas en las plantaciones, el indicador de detección fue calculado a partir de las plantaciones detectadas y el total de plantaciones de cada hectárea.

Para el cálculo del indicador de detección, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 - C

$$IDE = \frac{\text{Número Plantaciones Detectadas}}{\text{Total de Plantaciones}}$$

Estos fueron los valores obtenidos

**Tabla 8.**

*Indicador de Detección de Síntomas. Pretest*

Hectárea	Nro tomas	Promedio Total de Plantaciones	Promedio Plantaciones Detectadas	% Detección (IDE)
1	3	1000	73.3	7.33%
2	3	1000	66.7	6.67%
3	3	1000	46.7	4.67%
4	3	1000	63.3	6.53%
5	3	1000	53.3	5.53%
6	3	1000	70.0	7.00%
7	3	1000	73.3	7.33%
8	3	1000	70.0	7.00%
9	3	1000	60.0	6.00%
10	3	1000	74.7	7.47%

- Para determinar el indicador de satisfacción, se registraron los datos, en la ficha de cuestionario, la misma que fue aplicado al personal del área; esta encuesta estuvo conformada por 6 preguntas, la cual estuvo basada en la escala de Likert, los resultados se basaron en la elección de estas 5 opciones: Muy Bueno (MB) equivalente a puntaje 5, Bueno (BN) equivalente a puntaje 4, Regular (RG) equivalente a puntaje 3, Malo (ML) equivalente a puntaje 2 y Muy Malo (MM) equivalente a puntaje 1.

Para el cálculo del indicador de detección, se aplicó la fórmula siguiente, a partir de los datos recolectados del Anexo 04 - C

$$INS = \frac{\sum(\text{nroElección} * \text{Puntaje})}{n}$$

nroElección: son la cantidad de encuestados que elige una de las 5 opciones

n: número de encuestados, en este caso equivale a 5 personas

**Tabla 9.**

*Indicador del nivel de satisfacción*

Nº	Pregunta	Opción(O) y Puntajes (P)					Puntaje Total (P) * (O)	Nivel Satisfacción (INS)
		MB	BN	RG	ML	MM		
		5	4	3	2	1		
1	¿Considera Usted, que es eficiente, la forma de detectar síntomas de anomalías en las plantaciones ?	2	3	0	0	0	22	4.4
2	¿Cómo califica usted, la precisión de detectar anomalías en las plantaciones de palta?	2	3	0	0	0	22	4.4
3	¿Cómo considera el proceso de detección de síntomas de anomalías en las plantaciones de palta?	4	1	0	0	0	24	4.8
4	¿Cómo calificaría la gestión de la información para detectar anomalías en las plantaciones de palta?	4	1	0	0	0	24	4.8
5	¿Cómo considera usted, la dependencia a las personas en la detección de síntomas de anomalías en las plantaciones de palta?	4	1	0	0	0	24	4.8
6	¿Cómo califica usted, la forma de almacenamiento de los datos en la detección de síntomas de anomalías en las plantaciones de palta?	2	3	0	0	0	22	4.4

Para finalizar, se trabajaron los resultados por medio de la estadística descriptiva e inferencial a fin de determinar la aceptación de las hipótesis.

### CAPÍTULO III. RESULTADOS

#### Análisis de la Dimensión Ejecución del Proceso

- Indicador de Tiempo

**Tabla 10.**

*Datos del Indicador Tiempo. Pretest - Postest*

Hectárea	Pretest	Postest	Diferencia (d)	(Di - d)	(Di - d) <sup>2</sup>
1	117.00	23	93.7	13.43	180.45
2	115.33	25	90.0	9.77	95.39
3	113.33	26	87.7	7.43	55.25
4	93.33	25	68.0	-12.23	149.65
5	94.67	24	71.0	-9.23	85.25
6	107.33	23	84.3	4.10	16.81
7	119.33	27	92.3	12.10	146.41
8	87.67	27	60.3	-19.90	396.01
9	110.33	28	82.0	82.0	6,724.0
10	97.33	24	73.0	73.0	5,329.0
Media	105.57	25.33	<b>80.2</b>	Varianza	<b>118.07</b>

Se trabajaron con las 10 hectáreas de la zona “Salitre”, en donde el promedio del indicador del tiempo antes de la aplicación de visión computacional, correspondió a 105.57

Los datos se procesaron y se obtuvieron los valores descriptivos siguientes, en las 2 mediciones realizadas:

**Tabla 11.**

*Descriptivos Indicador Tiempo.*

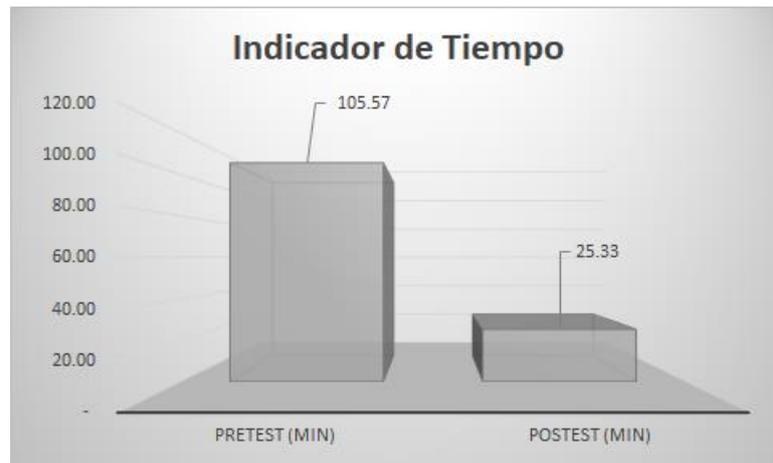
	N	Mínimo	Máximo	Media	Desviación estándar
Tiempo_Pre	10	87,67	119,33	105,5667	11,34536
Tiempo_Post	10	23,00	28,33	25,3333	1,79849

*Nota:* elaboración propia

Visto de formar gráfica, tenemos los valores siguientes:

**Figura 3.**

*Comparativo del Indicador de Tiempo*



*Nota:* elaboración propia

Se observa una mejora de 80.23 minutos, inició en el pretest con 105.57 (antes de la aplicación de visión computacional) y se redujo hasta 25.33 (después de la aplicación de visión computacional)

### **Hipótesis Estadística**

Ho: La aplicación de visión computacional NO influye positivamente en el tiempo de ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Ha : La aplicación de visión computacional influye positivamente en el tiempo de ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Nivel de Confiabilidad: 95%

Valor  $t_{\alpha} = 1.8331$  (grado libertad=9),

Prueba: t-student

Al aplicar la prueba t-student, con los parámetros indicados, se obtuvieron los valores:

**Tabla 12.**

*Prueba t-student. Indicador tiempo*

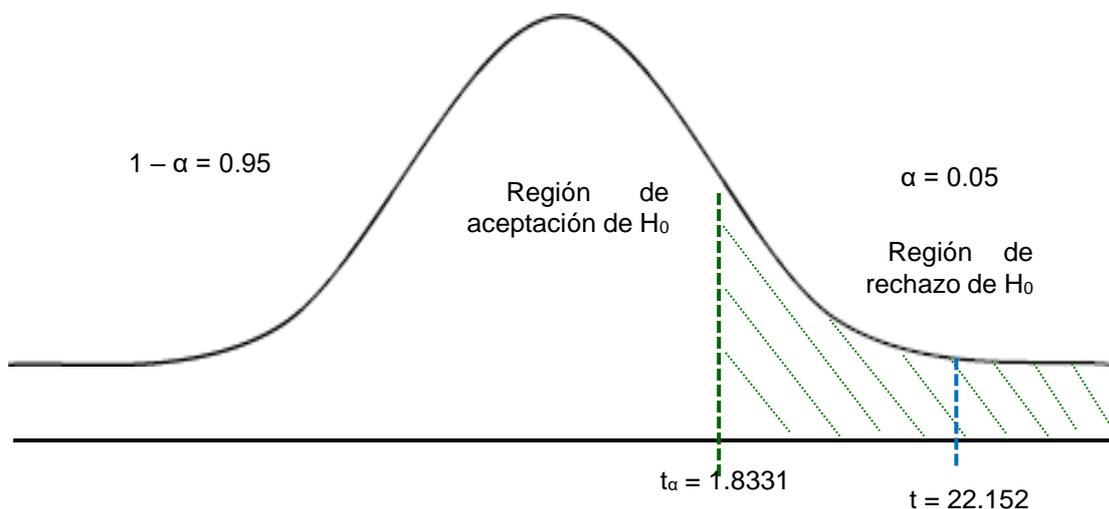
	Diferencias emparejadas					T	gl	Sig. (bilateral)
	Media	Desviación estándar	Media de error estándar	95% de intervalo de confianza de la diferencia				
				Inferior	Superior			
Tiempo_Pre - Tiempo_Post	80,23333	11,45366	3,62197	72,03988	88,42679	22,152	9	,000

*Nota:* elaboración propia

El t calculado logrado fue de 22.152, el cual determinará el rechazo o aceptación de la hipótesis planteada. Esto se observa en el gráfico siguiente:

**Figura 4.**

*Aceptación o rechazo indicador tiempo*



*Nota:* elaboración de acuerdo a datos calculados por el SPSS

De acuerdo a los valores obtenidos para se obtuvo un  $t = 22.152$ , mayor del valor crítico así mismo se obtuvo un valor sig. de 0.00, se rechaza la hipótesis nula; por lo tanto, se acepta

la hipótesis alterna, concluyendo que: La aplicación de visión computacional influye positivamente en el tiempo de ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.

- Indicador de Costo

**Tabla 13.**

*Datos del Indicador Costo. Pretest - Postest*

Hectárea	Pretest	Postest	Diferencia (d)	(Di - d)	(Di - d) <sup>2</sup>
1	98.44	20	78.8	-1.43	2.04
2	97.04	21	75.7	-4.51	20.36
3	95.35	22	73.8	-6.48	41.93
4	78.53	21	57.2	-23.02	530.00
5	79.65	20	59.7	-20.50	420.16
6	90.30	19	71.0	-9.28	86.11
7	100.40	23	77.7	-2.55	6.50
8	73.76	23	50.8	-29.47	868.61
9	92.83	24	69.0	-11.24	126.40
10	81.89	20	61.4	-18.82	354.01
Media	88.82	21.31	67.50	<b>Varianza</b>	<b>83.58</b>

*Nota:* elaboración propia

Se trabajaron con las 10 hectáreas de la zona “Salitre”, en donde el promedio del indicador del costo se redujo hasta 21.31 luego realizar las tomas realizadas y analizadas por la aplicación visual.

Los datos se procesaron y se obtuvieron los valores descriptivos siguientes, en las 2 mediciones realizadas:

**Tabla 14.**

*Descriptivos Indicador Costo.*


	N	Mínimo	Máximo	Media	Desviación estándar
Costo_Pre	10	73,76	100,40	88,8181	9,54538
Costo_Post	10	19,35	23,84	21,3141	1,51315

*Nota:* elaboración propia

Visto de forma gráfica, tenemos los valores siguientes:

**Figura 5.**

*Comparativo del Indicador de Tiempo*



*Nota:* elaboración propia

Se observa una mejora de S/. 66.90, inició en el pretest con 88.82 (antes de la aplicación de visión computacional) y se redujo hasta 21.31 (después de la aplicación de visión computacional)

### **Hipótesis Estadística**

Ho: La aplicación de visión computacional no influye positivamente en el costo de ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Ha : La aplicación de visión computacional influye positivamente en el costo de ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Nivel de Confiabilidad: 95%

Valor  $t_{\alpha} = 1.8331$  (grado libertad=9),

Prueba: t-student

Al aplicar la prueba t-student, con los parámetros indicados, se obtuvieron los valores:

**Tabla 15.**

*Prueba t-student. Indicador costo*

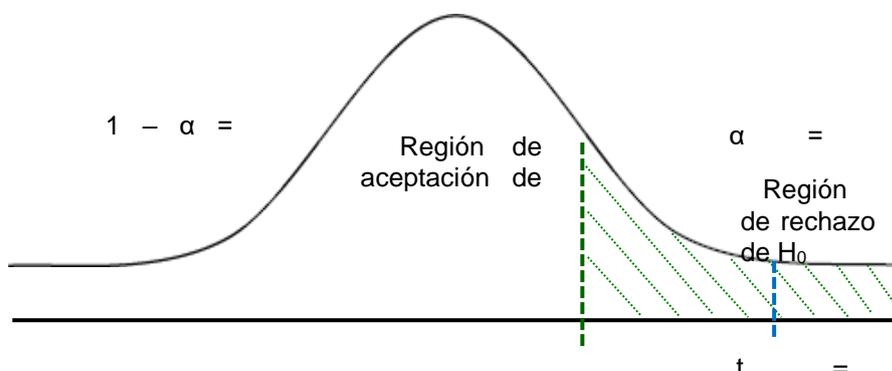
	Diferencias emparejadas					t	gl	Sig. (bilateral)
	Media	Desviación estándar	Media de error estándar	95% de intervalo de confianza de la diferencia				
				Inferior	Superior			
Costo_Pre - Costo_Post	67,50401	9,63650	3.04733	60,61047	74,39754	22,152	9	,000

*Nota:* elaboración propia

El t calculado logrado fue de 22.152, el cual determinará el rechazo o aceptación de la hipótesis planteada. Esto se observa en el gráfico siguiente:

**Figura 6.**

*Aceptación o rechazo indicador costo*



*Nota:* elaboración de acuerdo a datos calculados por el SPSS

De acuerdo a los valores obtenidos para se obtuvo un  $t = 22.152$ , mayor del valor crítico así mismo se obtuvo un valor sig. de 0.00, se rechaza la hipótesis nula; por lo tanto, se acepta la hipótesis alterna, concluyendo que: La aplicación de visión computacional influye positivamente en el costo de ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.

### Análisis de la Dimensión Ejecución

- Indicador de detección

Se presentan los datos obtenidos en los 2 momentos de medición para el indicador

**Tabla 16.**

*Datos del Indicador de detección. Pretest - Postest*

Hectárea	Pretest	Postest	Diferencia (d)	(Di - d)	(Di - d) <sup>2</sup>
1	5.33	7.33	-2.00	-82.23	6762.32
2	6.00	6.67	-0.67	-80.90	6544.81
3	5.00	4.67	0.33	-79.90	6384.01
4	5.67	6.53	-0.87	-81.10	6577.21
5	5.00	5.53	-0.53	-80.77	6523.25
6	5.33	7.00	-1.67	-81.90	6707.61
7	5.00	7.33	-2.33	-82.57	6817.25
8	5.33	7.00	-1.67	-81.90	6707.61
9	3.67	6.00	-2.33	-2.33	5.44
10	6.40	7.47	-1.07	-1.07	1.14
Media	5.15	6.55	-1.28	<b>Varianza</b>	<b>0.68</b>

*Nota:* elaboración propia

Se trabajaron con las 10 hectáreas de la zona “Salitre”, en donde el promedio del indicador de detección, aumentó hasta 6.55, luego realizar las tomas realizadas y analizadas por la aplicación visual.

Los datos se procesaron y se obtuvieron los valores descriptivos siguientes, en las 2 mediciones realizadas:

**Tabla 17.**

*Descriptivos Indicador Detección.*

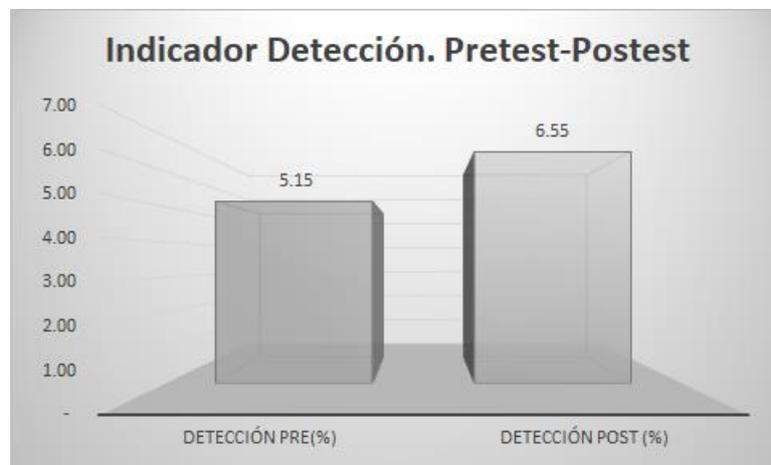
	N	Mínimo	Máximo	Media	Desviación estándar
Deteccion_Pre	10	0,04	0,06	0.0527	0,00728
Deteccion_Post	10	0.05	0.07	0.0655	0,00905

*Nota:* elaboración propia

Visto de formar gráfica, tenemos los valores siguientes:

**Figura 7.**

*Comparativo del Indicador de Detección*



*Nota:* elaboración propia

Se observa una mejora de 1.40%, inició en el pretest con 5.15% (antes de la aplicación de visión computacional) y aumentó hasta 6.55% (después de la aplicación de visión computacional)

### **Hipótesis Estadística**

Ho : La aplicación de visión computacional reduce la eficiencia en la detección del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Ha : La aplicación de visión computacional incrementa la eficiencia en la detección de proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Nivel de Confiabilidad: 95%

Valor  $t_{\alpha} = -1.8331$  (grado libertad=9),

Prueba: t-student

Al aplicar la prueba t-student, con los parámetros indicados, se obtuvieron los valores:

**Tabla 18.**

*Prueba t-student. Indicador detección de síntomas*

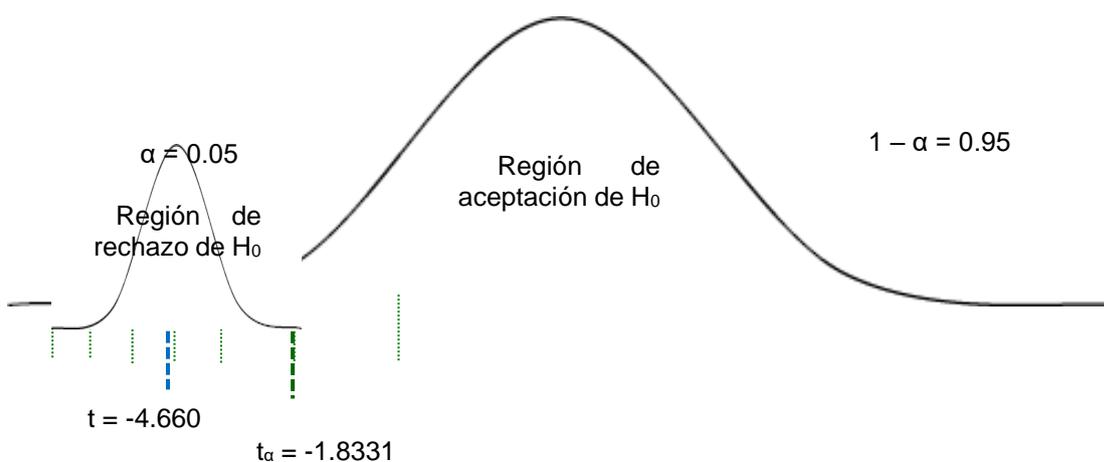
	Diferencias emparejadas						T	gl	Sig. (bilateral)
	Media	Desviación estándar	Media de error estándar	95% de intervalo de confianza de la diferencia					
				Inferior	Superior				
Tiempo_Pre - Tiempo_Post	-,01280	,00869	,00275	-,01901	-,00659	-4,660	9	,001	

*Nota:* elaboración propia

El t calculado logrado fue de -4.660, el cual determinará el rechazo o aceptación de la hipótesis planteada. Esto se observa en el gráfico siguiente:

**Figura 8.**

*Aceptación o rechazo indicador detección de síntomas*



*Nota:* elaboración de acuerdo a datos calculados por el SPSS

De acuerdo a los valores obtenidos para se obtuvo un  $t = -4.660$ , menor al valor crítico ( $-1.8331$ ) así mismo se obtuvo un valor sig. de  $0.01 (<0.05)$ , se rechaza la hipótesis nula; por lo tanto, se acepta la hipótesis alterna, concluyendo que: La aplicación de visión computacional incrementa la eficiencia en la detección de proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.

- Indicador de satisfacción

Se presentan los datos obtenidos en los 2 momentos de medición para el indicador

**Tabla 19.**

*Datos del Indicador de satisfacción. Pretest - Postest*

Pregunta	Pretest	Postest	Diferencia (d)	(Di - d)	(Di - d) <sup>2</sup>
1	2.4	4.4	-2	0.37	0.13
2	2.6	4.4	-1.8	0.57	0.32
3	2.2	4.8	-2.6	-0.23	0.05
4	2.2	4.8	-2.6	-0.23	0.05
5	2.2	4.8	-2.6	-0.23	0.05
6	1.8	4.4	-2.6	-0.23	0.05
Media	2.23	4.60	-2.37	<b>Varianza</b>	<b>0.11</b>

*Nota:* elaboración propia

Se trabajaron con 6 preguntas del cuestionario, en donde el promedio del indicador de satisfacción, aumentado a 4.60, luego de aplicar las preguntas antes y después de aplicar la aplicación visual computacional.

Los datos se procesaron y se obtuvieron los valores descriptivos siguientes, en las 2 mediciones realizadas:

**Tabla 20.**

*Descriptivos Indicador Satisfacción.*

N	Mínimo	Máximo	Media	Desviación estándar
---	--------	--------	-------	---------------------

Satisfacción_Pre	10	1,80	2,60	2,2333	,26583
Satisfacción_Post	10	4,40	4,80	4,6000	,21909

*Nota:* elaboración propia

Visto de formar gráfica, tenemos los valores siguientes:

**Figura 9.**

*Comparativo del Indicador de Satisfacción*



*Nota:* elaboración propia

Se observa una mejora de 2.37, inició en el pretest con 2.23 (antes de la aplicación de visión computacional) y aumentó hasta 4.60 (después de la aplicación de visión computacional)

### **Hipótesis Estadística**

Ho : La aplicación de visión computacional reduce la satisfacción en la detección del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Ha : La aplicación de visión computacional incrementa la satisfacción en la detección de proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023

Nivel de Confiabilidad: 95%

Valor  $t_{\alpha} = -2.1318$  (grado libertad=4),

Prueba: t-student

Al aplicar la prueba t-student, con los parámetros indicados, se obtuvieron los valores:

**Tabla 21.**

*Prueba t-student.. Indicador de Satisfacción*

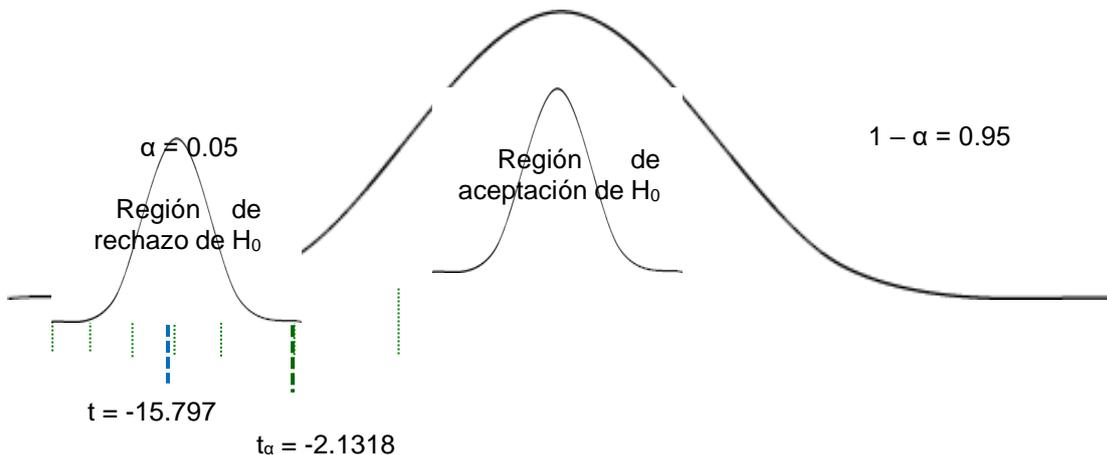
	Diferencias emparejadas						t	gl	Sig. (bilateral)
	Media	Desviación estándar	Media de error estándar	95% de intervalo de confianza de la diferencia					
				Inferior	Superior				
Satisfac_Pre - Satisfac_Post	-11,833	1,835	,749	-13,759	-9,908	-15,797	5	,000	

*Nota:* elaboración propia

El t calculado logrado fue de -15.797, el cual determinará el rechazo o aceptación de la hipótesis planteada. Esto se observa en el gráfico siguiente:

**Figura 10.**

*Aceptación o rechazo indicador Satisfacción*



*Nota:* elaboración de acuerdo a datos calculados por el SPSS

De acuerdo a los valores obtenidos para se obtuvo un  $t = -15.797$ , menor al valor crítico (-2.1318) así mismo se obtuvo un valor sig. de 0.01 ( $<0.05$ ), se rechaza la hipótesis nula; por lo tanto, se acepta la hipótesis alterna, concluyendo que: La aplicación de visión

computacional incrementa la satisfacción en la detección de proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023.

## CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES

### 4.1 Discusión

Se estableció un comparativo de los resultados que se obtuvieron en el presente estudio con otros que se registraron como antecedentes. Es necesario mencionar las *limitaciones* de orden inicial que se presentaron, resaltando el momento de recolectar los datos de los síntomas existentes de las plantaciones, las mismas que fueron obtenidas realizando las coordinaciones respectivas y ayudaron a continuar con el estudio.

La investigación tuvo el objetivo general de establecer la influencia de la aplicación de visión computacional en detección de síntomas visuales de plantaciones de palta para la Agrícola SAC, 2023. Según León y Menéndez (2018) la detección de síntomas visuales: es realizada mediante la evaluación visual para el diagnóstico. En este proceso, se observa y compara visualmente el aspecto de las plantas que muestran síntomas de deficiencia o exceso de uno o más elementos con respecto a las plantas que se consideran "normales" en términos de su nutrición. Para este propósito, las hojas son comúnmente utilizadas y, en algunas ocasiones, se pueden examinar otros órganos como las raíces o los frutos, dependiendo del elemento en cuestión (Sadeghian, 2017). Esta investigación, se realizó aplicando una serie de algoritmos de nivel medio luego de aplicar el estadístico descriptivo, lo cual guarda como significado que, la manera de interacción del personal da seguridad a los clientes y las instalaciones ayudan a brindar una adecuada y alta satisfacción. Con la finalidad de realizar el análisis comparativo, ese fue realizado por cada objetivo específico, tal como se aprecia en los párrafos siguientes.

Para el objetivo específico 1: Determinar la influencia de una aplicación de visión computacional en la eficiencia de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023. De acuerdo a Valencia et al. (2020) también denominada

visión artificial, reales y. En cuanto al resultado obtenido se tiene que la eficiencia de detección de síntomas mejoró en 76.01%, donde los tiempos promedio de detección se redujeron de 105.57 minutos a 25.33 minutos, así mismo el costo de redujo de S/. 88.82/Ha a S/. 21.31/ H, lo cual significó una reducción de S/. de 66.90. Existen coincidencias con el estudio desarrollado por los autores Amin y Awang (2018), quienes también aplicaron técnicas de procesamiento de imágenes logrando un 95% de precisión, así mismo existen coincidencias con el estudio de Donmez et al. (2021) quienes también aplicaron la computación visual para el análisis de cultivo de plantas, logrando un 95% de eficiencia al analizar la precisión y exactitud; así mismo existen coincidencias con la investigación de Dhanya et al. (2022) quienes al aplicar técnicas de computación visual, lograran una mejora en el proceso de 62.3%, en ambos casos la eficiencia del proceso tuvo mejoras significativas en los tiempos de procesamiento.

Para el objetivo específico 2: Para determinar la influencia de una aplicación de visión computacional en la ejecución del proceso de detección de síntomas visuales de las plantaciones de palta para la Agrícola Mapa SAC, 2023. De acuerdo a Valencia et al. (2020) también denominada visión artificial considerada una parte de la inteligencia artificial que busca el diseño de sistemas informáticos con capacidad para comprender los componentes y características de real imagen. Estas aplicaciones ayudan en la extracción de datos numéricos y simbólicos, partiendo del reconocimiento de elementos y estructuras que se presentan en la imagen. En cuanto a los resultados de la ejecución del proceso, se obtuvo que el indicador de detección, aumentó hasta 6.55 (inició con 5.15), lo que significó un aumento de 21.37% luego de aplicar la propuesta, mientras que el indicador de satisfacción de los usuarios, mejoró en 47.40%, pasando de 44.6% y llegando a 92.0%. Existen coincidencias con el estudio desarrollado por los autores Nadafzadeh y Mehdizadeh (2019), quienes también utilizaron el indicador de precisión, pero a diferencia de la presente investigación, usaron el

clasificador para tres situaciones de planta (fresca, al borde de la marchitez y marchita) así como su precisión total fueron 91,3, 77,8, 97,9 y 90,7%, respectivamente; así mismo existen coincidencias con el estudio de Donmez et al. (2021) quienes también aplicaron la computación visual para el análisis de cultivo de plantas, una precisión de 96.47% mejor precisión de clasificación y finalmente en el caso de la propuesta de existen coincidencias en la precisión logrando valores superiores al 95%.

En cuanto a las *implicancias*, que genera el presente estudio, desde el orden práctico, resaltan que la visión computacional incluyó en la detección de síntomas y para llegar a ello, se usó SCRUM como herramienta para elaborar la propuesta, la misma que puede ser de guía en estudios similares que pueda realizarse en el sector agrícola, que viene experimentando un crecimiento y presencia en mercados externos, donde la calidad del producto es vital para la aceptación del consumidor.

## 4.2 Conclusiones

- Se determinó la influencia de una aplicación de visión computacional en la eficiencia de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023, donde la detección de síntomas mejoró en 76.01%, a partir del tiempo promedio de detección pasando de 105.57 minutos a 25.33 minutos, así mismo el costo se redujo de S/. 88.82/Ha a S/. 21.31/ Ha, lo cual significó una reducción de S/. de 66.90
- Se determinó la influencia de una aplicación de visión computacional en la ejecución del proceso de detección de síntomas visuales de las plantaciones de palta para la Agrícola Mapa SAC, 2023; donde el indicador de detección, aumentó hasta 6.55 (inició con 5.15), lo que significó un aumento de 21.37% luego de aplicar la propuesta, mientras que el indicador de satisfacción de los usuarios, mejoró en 47.40%, pasando de 44.6% y llegando a 92.0%.

## REFERENCIAS

- AMIN, S.R.M. y AWANG, R., 2018. Automated Detection of Nitrogen Status on Plants: Performance of Image Processing Techniques. *2018 IEEE Student Conference on Research and Development (SCORED)* [en línea]. Selangor, Malaysia: IEEE, pp. 1-4. [consulta: 15 junio 2023]. ISBN 978-1-5386-9175-5. DOI 10.1109/SCORED.2018.8711334. Disponible en: <https://ieeexplore.ieee.org/document/8711334/>.
- CHANTIT, S. y ESSEBAA, I., 2021. Towards an automatic model-based Scrum Methodology. *Procedia Computer Science*, vol. 184, ISSN 18770509. DOI 10.1016/j.procs.2021.03.099.
- DAIRATH, M.H., AKRAM, M.W., MEHMOOD, M.A., SARWAR, H.U., AKRAM, M.Z., OMAR, M.M. y FAHEEM, M., 2023. Computer vision-based prototype robotic picking cum grading system for fruits. *Smart Agricultural Technology*, vol. 4, ISSN 27723755. DOI 10.1016/j.atech.2023.100210.
- DHANYA, V.G., SUBEESH, A., KUSHWAHA, N.L., VISHWAKARMA, D.K., NAGESH KUMAR, T., RITIKA, G. y SINGH, A.N., 2022. Deep learning based computer vision approaches for smart agricultural applications. *Artificial Intelligence in Agriculture*, vol. 6, ISSN 25897217. DOI 10.1016/j.aiia.2022.09.007.
- DÍAZ, A.A. y KURKA, P.R.G., 2020. Computer vision methods for automotive applications. *TECNIA*, vol. 30, no. 2, ISSN 2309-0413, 0375-7765. DOI 10.21754/tecnica.v30i2.801.
- DONMEZ, C., VILLI, O., BERBEROGLU, S. y CILEK, A., 2021. Computer vision-based citrus tree detection in a cultivated environment using UAV imagery. *Computers and Electronics in Agriculture*, vol. 187, ISSN 01681699. DOI 10.1016/j.compag.2021.106273.
- FLORES-CERNA, F., SANHUEZA-SALAZAR, V.-M., VALDÉS-GONZÁLEZ, H.-M. y REYES-BOZO, L., 2021. Metodologías ágiles: un análisis de los desafíos organizacionales para su implementación. *Revista Científica*, vol. 43, no. 1, ISSN 2344-8350, 0124-2253. DOI 10.14483/23448350.18332.
- FRACAROLLI, J.A., PAVARIN, F.F.A., CASTRO, W. y BLASCO, J., 2020. Computer vision applied to food and agricultural products. *REVISTA CIÊNCIA AGRONÔMICA* [en línea], vol. 51, no. 5, [consulta: 13 julio 2023]. ISSN 1806-6690. DOI 10.5935/1806-6690.20200087. Disponible en: <http://ccarevista.ufc.br/seer/index.php/ccarevista/issue/archive>.
- GARCIA, L.A., OLIVEIRAJR, E. y MORANDINI, M., 2022. Tailoring the Scrum framework for software development: Literature mapping and feature-based support. *Information and Software Technology*, vol. 146, ISSN 09505849. DOI 10.1016/j.infsof.2021.106814.
- GARCÍA VIGIL, M.E., 2019. Aplicación de visión por computadora en la clasificación según categorías de calidad de palta (persea americana mill) variedad hass. En: Accepted: 2019-10-30T14:30:42Z, *Universidad Privada Antenor Orrego* [en línea], [consulta: 13 julio 2023]. Disponible en: <https://repositorio.upao.edu.pe/handle/20.500.12759/5572>.
- GHERGAN, OANA, 2021. THE ROLE OF COMPUTER VISION IN SUSTAINABLE AGRICULTURE: EBSCOhost. [en línea]. [consulta: 15 junio 2023]. Disponible en: <https://web.s.ebscohost.com/ehost/detail/detail?vid=0&sid=5f4a8438-011c-435d-ab8e-23b05e047900%40redis&bdata=JmxhbmMc2l0ZT1laG9zdC1saXZl#AN=151690117&db=bth>.
- GORZIGLIA, C., YAGELLO, J. y RADIC, S., 2019. Evaluación de los síntomas por déficit de macronutrientes en cinco especies de importancia agropecuaria de la región de Magallanes

y Antártica Chilena. *Anales del Instituto de la Patagonia*, vol. 47, no. 3, ISSN 0718-686X. DOI 10.4067/S0718-686X2019000300019.

HERNÁNDEZ, R. y MENDOZA, C., 2018. Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta. [en línea]. [consulta: 13 julio 2023]. Disponible en: <https://virtual.cuautitlan.unam.mx/rudics/?p=2612>.

HERRA GÓMEZ, L.D., 2018. Conceptualización del procesamiento digital de imágenes para la evaluación de superficies de pavimento en Costa Rica. *Infraestructura Vial* [en línea], vol. 20, no. 35, [consulta: 19 junio 2023]. ISSN 2215-3705, 1409-4045. DOI 10.15517/iv.v20i35.34831. Disponible en: <https://revistas.ucr.ac.cr/index.php/vial/article/view/34831>.

LI, J., GREEN-MILLER, A.R., HU, X., LUCIC, A., MAHESH MOHAN, M.R., DILGER, R.N., CONDOTTA, I.C.F.S., ALDRIDGE, B., HART, J.M. y AHUJA, N., 2022. Barriers to computer vision applications in pig production facilities. *Computers and Electronics in Agriculture*, vol. 200, ISSN 01681699. DOI 10.1016/j.compag.2022.107227.

LU, Y. y YOUNG, S., 2020. A survey of public datasets for computer vision tasks in precision agriculture. *Computers and Electronics in Agriculture*, vol. 178, ISSN 01681699. DOI 10.1016/j.compag.2020.105760.

NADAFZADEH, M. y ABDANAN MEHDIZADEH, S., 2019. Design and fabrication of an intelligent control system for determination of watering time for turfgrass plant using computer vision system and artificial neural network. *Precision Agriculture*, vol. 20, no. 5, ISSN 1385-2256, 1573-1618. DOI 10.1007/s11119-018-9618-x.

*nota-de-prensa-no-140-2022-inei.pdf* [en línea], [sin fecha]. S.l.: s.n. [consulta: 19 junio 2023]. Disponible en: <https://m.inei.gob.pe/media/MenuRecursivo/noticias/nota-de-prensa-no-140-2022-inei.pdf>.

NOVOA, M.A., MIRANDA, D. y MELGAREJO, L.M., 2018. Efecto de las deficiencias y excesos de fósforo, potasio y boro en la fisiología y el crecimiento de plantas de aguacate (*Persea americana*, cv. Hass). *Revista Colombiana de Ciencias Hortícolas*, vol. 12, no. 2, ISSN 2422-3719, 2011-2173. DOI 10.17584/rcch.2018v12i2.8092.

OWINO, A., 2023. Challenges of Computer Vision Adoption in the Kenyan Agricultural Sector and How to Solve Them: A General Perspective. En: X. XIAO (ed.), *Advances in Agriculture*, vol. 2023, ISSN 2314-7539, 2356-654X. DOI 10.1155/2023/1530629.

PATRÍCIO, D.I. y RIEDER, R., 2018. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture*, vol. 153, ISSN 01681699. DOI 10.1016/j.compag.2018.08.001.

PAVEL, M.I., KAMRUZZAMAN, S.M., HASAN, S.S. y SABUJ, S.R., 2019. An IoT Based Plant Health Monitoring System Implementing Image Processing. *2019 IEEE 4th International Conference on Computer and Communication Systems (ICCCS)* [en línea]. Singapore: IEEE, pp. 299-303. [consulta: 15 junio 2023]. ISBN 978-1-72811-322-7. DOI 10.1109/CCOMS.2019.8821782. Disponible en: <https://ieeexplore.ieee.org/document/8821782/>.

Representatividad de palta hass peruana en Estados Unidos fue del 10% en campaña 2022. [en línea], [sin fecha]. [consulta: 19 junio 2023]. Disponible en: <https://agraria.pe/noticias/representatividad-de-palta-hass-peruana-en-estados-unidos-fu-29933>.

SADEGHIAN, R., 2017. Vision based control and simulation of a spherical rolling robot based on ROS and Gazebo. [en línea]. [consulta: 19 junio 2023]. Disponible en:

[https://scholar.google.com/citations?view\\_op=view\\_citation&hl=en&user=MU0A3h8AAAAJ&citation\\_for\\_view=MU0A3h8AAAAJ:YsMSGLbcyi4C](https://scholar.google.com/citations?view_op=view_citation&hl=en&user=MU0A3h8AAAAJ&citation_for_view=MU0A3h8AAAAJ:YsMSGLbcyi4C).

- SÁNCHEZ, ANA y NAVARRETE, VALENCIA, 2016. Repositorio Institucional ARAMARA: EFICIENCIA PRODUCTIVA EN LA NUTRICION DE LOS FRUTALES. [en línea]. [consulta: 19 junio 2023]. Disponible en: <http://dspace.uan.mx:8080/jspui/handle/123456789/2138>.
- SÁNCHEZ TURCIOS, R.A., 2015. t-Student: Usos y abusos. *Revista mexicana de cardiología*, vol. 26, no. 1, ISSN 0188-2198.
- SAPKOTA, R., STENGER, J., OSTLIE, M. y FLORES, P., 2023. Towards reducing chemical usage for weed control in agriculture using UAS imagery analysis and computer vision techniques. *Scientific Reports*, vol. 13, no. 1, ISSN 2045-2322. DOI 10.1038/s41598-023-33042-0.
- Senasa: La tristeza del palto y recomendaciones para su control - SENASA al día. [en línea], [sin fecha]. [consulta: 19 junio 2023]. Disponible en: <https://www.senasa.gob.pe/senasacontigo/senasa-la-tristeza-del-palto-y-recomendaciones-para-su-control/>.
- SHARAT, D, S., AKHILESH, KUMAR, S.A., M.G., R. y C., P., 2019. Image based Plant Disease Detection in Pomegranate Plant for Bacterial Blight. *2019 International Conference on Communication and Signal Processing (ICCSP)* [en línea]. Chennai, India: IEEE, pp. 0645-0649. [consulta: 15 junio 2023]. ISBN 978-1-5386-7595-3. DOI 10.1109/ICCSP.2019.8698007. Disponible en: <https://ieeexplore.ieee.org/document/8698007/>.
- SULISTYO, S.B., WU, D., WOO, W.L., DLAY, S.S. y GAO, B., 2018. Computational Deep Intelligence Vision Sensing for Nutrient Content Estimation in Agricultural Automation. *IEEE Transactions on Automation Science and Engineering*, vol. 15, no. 3, ISSN 1545-5955, 1558-3783. DOI 10.1109/TASE.2017.2770170.
- TIAN, H., WANG, T., LIU, Y., QIAO, X. y LI, Y., 2020. Computer vision technology in agricultural automation —A review. *Information Processing in Agriculture*, vol. 7, no. 1, ISSN 22143173. DOI 10.1016/j.inpa.2019.09.006.
- TRIPATHI, M.K. y MAKTEDAR, D.D., 2020. A role of computer vision in fruits and vegetables among various horticulture products of agriculture fields: A survey. *Information Processing in Agriculture*, vol. 7, no. 2, ISSN 22143173. DOI 10.1016/j.inpa.2019.07.003.
- TURCIOS, R.A.S., 2015. Prueba de Wilcoxon-Mann-Whitney: mitos y realidades. ,
- UNIVERSIDAD NACIONAL DE TRUJILLO, DEPARTAMENTO DE INGENIERÍA MECATRÓNICA. TRUJILLO, PERÚ, NARCISO HORNA, W.A., MANZANO RAMOS, E.A., y UNIVERSIDAD NACIONAL DE TRUJILLO, DEPARTAMENTO DE INGENIERÍA MECATRÓNICA. TRUJILLO, PERÚ, 2021. Sistema de visión artificial basado en redes neuronales convolucionales para la selección de arándanos según estándares de exportación. *Campus*, vol. 26, no. 32, ISSN 18126049, 25231820. DOI 10.24265/campus.2021.v26n32.01.
- VALENCIA-PAYAN, C., MUÑOZ-ORDÓÑEZ, J. y PENCUE-FIERRO, L., 2020. Sistema de asistencia a la conducción usando visión por computadora y aprendizaje máquina. *Revista Facultad de Ingeniería*, vol. 29, no. 54, ISSN 2357-5328, 0121-1129. DOI 10.19053/01211129.v29.n54.2020.11760.
- VELESACA, H.O., SUÁREZ, P.L., MIRA, R. y SAPPA, A.D., 2021. Computer vision based food grain classification: A comprehensive survey. *Computers and Electronics in Agriculture*, vol. 187, ISSN 01681699. DOI 10.1016/j.compag.2021.106287.

- XIANG, L. y WANG, D., 2023. A review of three-dimensional vision techniques in food and agriculture applications. *Smart Agricultural Technology*, vol. 5, ISSN 27723755. DOI 10.1016/j.atech.2023.100259.
- ZAMAN, S., COMBA, L., BIGLIA, A., RICAUDA AIMONINO, D., BARGE, P. y GAY, P., 2019. Cost-effective visual odometry system for vehicle motion control in agricultural environments. *Computers and Electronics in Agriculture*, vol. 162, ISSN 01681699. DOI 10.1016/j.compag.2019.03.037.

**ANEXOS:**

**1) Descripción del instrumento 1A**

Nombre	Ficha observación
Objetivo	<p>Recolección de datos asignando datos para medir en pre test y post test de los indicadores de la variable dependiente.</p> <p>Estos son los pasos:</p> <ol style="list-style-type: none"> <li>1. Detectar coloración inusual más eficiente por medio de casos de prueba definidos.</li> </ol>
Procedimiento	<ol style="list-style-type: none"> <li>2. Se procede a calcular y asignar un valor para el indicador de la coloración inusual encontrada.</li> <li>3. A través de una Ficha de observación, se detalla un valor para el cálculo de los indicadores.</li> </ol>
Público Objetivo	Investigador

Aplicación de visión computacional en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa sociedad anónima cerrada				
PROBLEMA	HIPÓTESIS	OBJETIVO GENERAL	VARIABLE 1	METODOLOGÍA
¿De qué manera influye una <b>aplicación de visión computacional</b> en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023?	Una <b>aplicación de visión computacional</b> influye positivamente en la <b>detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023</b>	Establecer la influencia de la <b>aplicación de visión computacional</b> en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023	Variable Independiente: <b>Aplicación de visión computacional</b>	<p><b>Diseño</b></p> <p>Diseño pre-experimental</p> <p><b>G: O<sub>A</sub> x O<sub>B</sub></b></p> <p><b>G<sub>A</sub></b>: grupo de imágenes.</p> <p><b>O<sub>A</sub></b>: Observación previa sin aplicación.</p> <p><b>X</b>: Aplicación de visión computacional.</p> <p><b>O<sub>B</sub></b>: Observación posterior sin aplicación</p>
PROBLEMAS ESPECÍFICOS	HIPÓTESIS ESPECIFICAS	OBJETIVOS ESPECÍFICOS	VARIABLE 2	
<p>¿De qué manera influye una aplicación de visión computacional en la ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023?</p> <p>¿De qué manera influye una aplicación de visión computacional en la eficiencia de la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023?</p>	<p>Una aplicación de visión computacional influye positivamente en la <b>ejecución del proceso</b> de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023</p> <p>Una aplicación de visión computacional influye positivamente <b>en la</b> eficiencia de la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023</p>	<p>Determinar la influencia de una aplicación de visión computacional en la ejecución del proceso de detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023</p> <p>Determinar la influencia de una aplicación de visión computacional en la eficiencia de la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa SAC, 2023</p>	<p>Variable dependiente:</p> <p>Detección de síntomas visuales</p>	<p><b>Población</b></p> <p>Plantaciones de palta de la empresa Agrícola Mapa SAC, zona el salitre</p> <p><b>Muestra</b></p> <p>10 hectáreas</p>

**Anexo 03. Matriz de operacionalización**

<b>VARIABLE INDEPENDIENTE/VARIABLE 1</b>	<b>DEFINICIÓN CONCEPTUAL</b>	<b>DEFINICIÓN OPERACIONAL</b>	<b>DIMENSIONES</b>	<b>INDICADORES</b>
Visión computacional	También denominada visión artificial considerada una parte de la inteligencia artificial que busca el diseño de sistemas informáticos con capacidad para comprender los componentes y características de real imagen. Estas aplicaciones ayudan en la extracción de datos numéricos y simbólicos, partiendo del reconocimiento de elementos y estructuras que se presentan en la imagen (Valencia et al., 2020)	Se relaciona en forma estrecha con las técnicas de proceso de imágenes y para reconocer patrones. (Sánchez y Navarrete, 2016)	<i>Usabilidad</i>	Nivel de usabilidad
				<i>Tasa de errores</i>
			<i>Funcionalidad</i>	Cubrimiento de funcionalidades
				Tiempo de funcionalidad
<b>VAR.DEPENDIENTE/VARIABLE 2</b>	<b>DEFINICIÓN CONCEPTUAL</b>	<b>DEFINICIÓN OPERACIONAL</b>	<b>DIMENSIONES</b>	<b>INDICADORES</b>
Detección síntomas visuales	es realizada mediante la evaluación visual para el diagnóstico. En este proceso, se observa y compara visualmente el aspecto de las plantas que muestran síntomas de deficiencia o exceso de uno o más elementos con respecto a las plantas que se consideran "normales" en términos de su nutrición. Para este propósito, las hojas son comúnmente utilizadas y, en algunas ocasiones, se pueden examinar otros órganos como las raíces o los frutos, dependiendo del elemento en cuestión (Sadeghian, 2016).	Los planes de fertilización deben analizarse en forma permanente por medio del estado nutrición de las plantas, es realizado en forma habitual diagnosticando en forma visual (Owino 2023)	<i>Eficiencia</i>	Tiempo
				<i>costo</i>
			<i>Ejecución del Proceso</i>	<i>Detección</i>
				<i>Satisfacción</i>







**INSTRUMENTO 4: Nivel de satisfacción**

FICHA DE REGISTRO						
<b>TESIS</b>		" Aplicación de visión computacional en la detección de síntomas visuales de plantaciones de palta para la Agrícola Mapa sociedad anónima cerrada "				
<b>VARIABLE</b>	<b>INDICADOR</b>			<b>TECNICA</b>	<b>INSTRUMENTO</b>	
Detección de síntomas	Satisfacción			Encuesta	Cuestionario	
<b>N°</b>	<b>PREGUNTAS</b>	<b>MUY MAL (MM)</b>	<b>MAL (ML)</b>	<b>REGULAR (RG)</b>	<b>BUENO (BN)</b>	<b>MUY BUENO (MB)</b>
1	¿Considera Usted, que es eficiente, la forma de detectar síntomas de anomalías en las plantaciones ?					
2	¿Cómo califica usted, la precisión de detectar anomalías en las plantaciones de palta?					
3	¿Cómo considera el proceso de detección de síntomas de anomalías en las plantaciones de palta?					
4	¿Cómo calificaría la gestión de la información para detectar anomalías en las plantaciones de palta?					
5	¿Cómo considera usted, la dependencia a las personas en la detección de síntomas de anomalías en las plantaciones de palta?					
6	¿Cómo califica usted, la forma de almacenamiento de los datos en la detección de síntomas de anomalías en las plantaciones de palta?					

## Anexo 04. Datos recolectados – PreTest

### Anexo 04 - A. Pretest

#### a. Indicador Tiempo. Pretest

**Tabla 22.**

*Datos indicador tiempo. Pretest*

Fecha	Hectárea	Hora Inicio	Hora Final	Tiempo (hr)	Tiempo(min)
5/06/2023	1	07:30	09:25	01:55	115
5/06/2023	2	10:00	11:52	01:52	112
6/06/2023	3	07:30	09:20	01:50	110
6/06/2023	4	10:00	11:32	01:32	92
7/06/2023	5	07:30	09:00	01:30	90
7/06/2023	6	10:00	11:44	01:44	104
8/06/2023	7	07:30	09:26	01:56	116
8/06/2023	8	10:00	11:23	01:23	83
9/06/2023	9	07:30	09:17	01:47	107
9/06/2023	10	10:00	11:32	01:32	92
12/06/2023	1	07:30	09:29	01:59	119
12/06/2023	2	10:00	11:59	01:59	119
13/06/2023	3	07:30	09:27	01:57	117
13/06/2023	4	10:00	11:36	01:36	96
14/06/2023	5	07:30	09:09	01:39	99
14/06/2023	6	10:00	11:51	01:51	111
15/06/2023	7	07:30	09:33	02:03	123
15/06/2023	8	10:00	11:32	01:32	92
16/06/2023	9	07:30	09:24	01:54	114
16/06/2023	10	10:00	11:42	01:42	102
26/06/2023	1	07:30	09:27	01:57	117
26/06/2023	2	10:00	11:55	01:55	115
27/06/2023	3	07:30	09:23	01:53	113
27/06/2023	4	10:00	11:32	01:32	92
28/06/2023	5	07:30	09:05	01:35	95
28/06/2023	6	10:00	11:47	01:47	107
29/06/2023	7	07:30	09:29	01:59	119
29/06/2023	8	10:00	11:28	01:28	88
30/06/2023	9	07:30	09:20	01:50	110
30/06/2023	10	10:00	11:38	01:38	98

## b. Indicador de costo. Pretest

**Tabla 23.**

*Indicador de Costo. Pretest*

Fecha	Hectárea	Hora Inicio	Hora Final	Tiempo (hr)	Tiempo(min)	Costo (S./)
5/06/2023	1	07:30	09:25	01:55	115	32.25
5/06/2023	2	10:00	11:52	01:52	112	31.41
6/06/2023	3	07:30	09:20	01:50	110	30.85
6/06/2023	4	10:00	11:32	01:32	92	25.80
7/06/2023	5	07:30	09:00	01:30	90	25.24
7/06/2023	6	10:00	11:44	01:44	104	29.17
8/06/2023	7	07:30	09:26	01:56	116	32.53
8/06/2023	8	10:00	11:23	01:23	83	23.28
9/06/2023	9	07:30	09:17	01:47	107	30.01
9/06/2023	10	10:00	11:32	01:32	92	25.80
12/06/2023	1	07:30	09:29	01:59	119	33.37
12/06/2023	2	10:00	11:59	01:59	119	33.37
13/06/2023	3	07:30	09:27	01:57	117	32.81
13/06/2023	4	10:00	11:36	01:36	96	26.92
14/06/2023	5	07:30	09:09	01:39	99	27.76
14/06/2023	6	10:00	11:51	01:51	111	31.13
15/06/2023	7	07:30	09:33	02:03	123	34.50
15/06/2023	8	10:00	11:32	01:32	92	25.80
16/06/2023	9	07:30	09:24	01:54	114	31.97
16/06/2023	10	10:00	11:42	01:42	102	28.61
26/06/2023	1	07:30	09:27	01:57	117	32.81
26/06/2023	2	10:00	11:55	01:55	115	32.25
27/06/2023	3	07:30	09:23	01:53	113	31.69
27/06/2023	4	10:00	11:32	01:32	92	25.80
28/06/2023	5	07:30	09:05	01:35	95	26.64
28/06/2023	6	10:00	11:47	01:47	107	30.01
29/06/2023	7	07:30	09:29	01:59	119	33.37
29/06/2023	8	10:00	11:28	01:28	88	24.68
30/06/2023	9	07:30	09:20	01:50	110	30.85
30/06/2023	10	10:00	11:38	01:38	98	27.48

**c. Indicador de detección. Pretest**

**Tabla 24**

*Indicador de detección. Pretest*

Fecha	Hectárea	Nro		% Detección
		Plantas	Detectadas	
5/06/2023	1	1000	70	7%
5/06/2023	2	1000	70	7%
6/06/2023	3	1000	60	6%
6/06/2023	4	1000	30	3%
7/06/2023	5	1000	50	5%
7/06/2023	6	1000	60	6%
8/06/2023	7	1000	40	4%
8/06/2023	8	1000	50	5%
9/06/2023	9	1000	30	3%
9/06/2023	10	1000	60	6%
12/06/2023	1	1000	40	4%
12/06/2023	2	1000	40	4%
13/06/2023	3	1000	50	5%
13/06/2023	4	1000	70	7%
14/06/2023	5	1000	40	4%
14/06/2023	6	1000	40	4%
15/06/2023	7	1000	50	5%
15/06/2023	8	1000	40	4%
16/06/2023	9	1000	40	4%
16/06/2023	10	1000	60	6%
26/06/2023	1	1000	50	5%
26/06/2023	2	1000	70	7%
27/06/2023	3	1000	40	4%
27/06/2023	4	1000	70	7%
28/06/2023	5	1000	60	6%
28/06/2023	6	1000	60	6%
29/06/2023	7	1000	60	6%
29/06/2023	8	1000	70	7%
30/06/2023	9	1000	40	4%
30/06/2023	10	1000	60	6%

## Anexo 04 - B. Postest

### a. Indicador del Tiempo. Postest

**Tabla 25.**

*Indicador de Tiempo. Postest*

Fecha	Hectárea	Hora Inicio	Hora Final	Tiempo (hr)	Tiempo (min)
10/07/2023	1	08:00:00	08:24	00:24	24
10/07/2023	2	08:30:00	08:55	00:25	25
11/07/2023	3	09:00:00	09:24	00:24	24
11/07/2023	4	09:30:00	09:55	00:25	25
12/07/2023	5	10:00:00	10:22	00:22	22
12/07/2023	6	08:00:00	08:24	00:24	24
13/07/2023	7	08:30:00	09:00	00:30	30
13/07/2023	8	09:00:00	09:29	00:29	29
14/07/2023	9	09:30:00	10:00	00:30	30
14/07/2023	10	10:00:00	10:28	00:28	28
17/07/2023	1	08:00:00	08:21	00:21	21
17/07/2023	2	08:30:00	08:59	00:29	29
18/07/2023	3	09:00:00	09:25	00:25	25
18/07/2023	4	09:30:00	09:55	00:25	25
19/07/2023	5	10:00:00	10:22	00:22	22
19/07/2023	6	08:00:00	08:24	00:24	24
20/07/2023	7	08:30:00	08:56	00:26	26
20/07/2023	8	09:00:00	09:27	00:27	27
21/07/2023	9	09:30:00	09:58	00:28	28
21/07/2023	10	10:00:00	10:22	00:22	22
31/07/2023	1	08:00:00	08:25	00:25	25
31/07/2023	2	08:30:00	08:52	00:22	22
1/08/2023	3	09:00:00	09:28	00:28	28
1/08/2023	4	09:30:00	09:56	00:26	26
2/08/2023	5	10:00:00	10:27	00:27	27
2/08/2023	6	08:00:00	08:21	00:21	21
3/08/2023	7	08:30:00	08:55	00:25	25
3/08/2023	8	09:00:00	09:26	00:26	26
4/08/2023	9	09:30:00	09:57	00:27	27
4/08/2023	10	10:00:00	10:23	00:23	23

b. **Indicador de costo. Posttest**

**Tabla 26.**

*Indicador de Costo. Posttest*

Fecha	Hectárea	Hora Inicio	Hora Final	Tiempo (hr)	Tiempo (min)	Costo (S/.)
10/07/2023	1	08:00:00	08:24	00:24	24	6.73
10/07/2023	2	08:30:00	08:55	00:25	25	7.01
11/07/2023	3	09:00:00	09:24	00:24	24	6.73
11/07/2023	4	09:30:00	09:55	00:25	25	7.01
12/07/2023	5	10:00:00	10:22	00:22	22	6.17
12/07/2023	6	08:00:00	08:24	00:24	24	6.73
13/07/2023	7	08:30:00	09:00	00:30	30	8.41
13/07/2023	8	09:00:00	09:29	00:29	29	8.13
14/07/2023	9	09:30:00	10:00	00:30	30	8.41
14/07/2023	10	10:00:00	10:28	00:28	28	7.85
17/07/2023	1	08:00:00	08:21	00:21	21	5.89
17/07/2023	2	08:30:00	08:59	00:29	29	8.13
18/07/2023	3	09:00:00	09:25	00:25	25	7.01
18/07/2023	4	09:30:00	09:55	00:25	25	7.01
19/07/2023	5	10:00:00	10:22	00:22	22	6.17
19/07/2023	6	08:00:00	08:24	00:24	24	6.73
20/07/2023	7	08:30:00	08:56	00:26	26	7.29
20/07/2023	8	09:00:00	09:27	00:27	27	7.57
21/07/2023	9	09:30:00	09:58	00:28	28	7.85
21/07/2023	10	10:00:00	10:22	00:22	22	6.17
31/07/2023	1	08:00:00	08:25	00:25	25	7.01
31/07/2023	2	08:30:00	08:52	00:22	22	6.17
1/08/2023	3	09:00:00	09:28	00:28	28	7.85
1/08/2023	4	09:30:00	09:56	00:26	26	7.29
2/08/2023	5	10:00:00	10:27	00:27	27	7.57
2/08/2023	6	08:00:00	08:21	00:21	21	5.89
3/08/2023	7	08:30:00	08:55	00:25	25	7.01
3/08/2023	8	09:00:00	09:26	00:26	26	7.29
4/08/2023	9	09:30:00	09:57	00:27	27	7.57
4/08/2023	10	10:00:00	10:23	00:23	23	6.45

c. **Indicador de detección. Postest**

**Tabla 27.**

*Indicador de detección. Postest*

Fecha	Hectárea	Nro Plantas	Detectadas	% Detección
10/07/2023	1	1000	80	8%
10/07/2023	2	1000	70	7%
11/07/2023	3	1000	40	4%
11/07/2023	4	1000	62	6%
12/07/2023	5	1000	54	5%
12/07/2023	6	1000	80	8%
13/07/2023	7	1000	50	5%
13/07/2023	8	1000	90	9%
14/07/2023	9	1000	50	5%
14/07/2023	10	1000	74	7%
17/07/2023	1	1000	60	6%
17/07/2023	2	1000	80	8%
18/07/2023	3	1000	60	6%
18/07/2023	4	1000	64	6%
19/07/2023	5	1000	52	5%
19/07/2023	6	1000	60	6%
20/07/2023	7	1000	90	9%
20/07/2023	8	1000	70	7%
21/07/2023	9	1000	80	8%
21/07/2023	10	1000	70	7%
31/07/2023	1	1000	80	8%
31/07/2023	2	1000	50	5%
1/08/2023	3	1000	40	4%
1/08/2023	4	1000	70	7%
2/08/2023	5	1000	60	6%
2/08/2023	6	1000	70	7%
3/08/2023	7	1000	80	8%
3/08/2023	8	1000	50	5%
4/08/2023	9	1000	50	5%
4/08/2023	10	1000	80	8%

## Anexo 05. Desarrollo de Aplicación

### a. Roles.

Los roles que se identificaron son:

<b>Equipo SCRUM</b>			
<b>N°</b>	<b>Nombre y Apellidos</b>	<b>Rol</b>	<b>Descripción</b>
<b>1</b>	Ing. Gustavo Sosa Calderón	Product Owner	Define alcance del proyecto y los objetivos, determinando la priorización de las funciones del producto
<b>2</b>	Ing. Gustavo Sosa Calderón	Scrum Master	Jefe del equipo y ayuda tener una eficiencia adecuada a los miembros del equipo
<b>3</b>	Franz Kaiser Alba Mejía Luis Cristofer Mostacero Perez	Scrum Team	Responsables del desarrollo del producto

## b. Product Backlog

**Tabla 28.**
*Product Backlog*

Nro	Requerimiento	Tareas sprint	Duración Estimada	Orden de Prioridad	Responsable	Aceptada	Inicio	Fin
1	Seleccionar herramientas para el desarrollo de la aplicación.	1	1	1	Franz Alba Mejía Luis Mostacero Pérez	SI	2/05/2023	2/05/2023
2	Identificar un template de interface	1	2	2	Franz Alba Mejía Luis Mostacero Pérez	SI	3/05/2023	4/05/2023
3	Diseñar la base de datos	2	7	3	Franz Alba Mejía Luis Mostacero Pérez	SI	4/05/2023	11/05/2023
4	Login de seguridad	3	1	4	Franz Alba Mejía Luis Mostacero Pérez	SI	11/05/2023	12/05/2023
5	El aplicativo debe permitir registrar areas	3	3	5	Franz Alba Mejía Luis Mostacero Pérez	SI	12/05/2023	15/05/2023
6	El aplicativo debe permitir gestionar usuarios	4	1	6	Franz Alba Mejía Luis Mostacero Pérez	SI	15/05/2023	16/05/2023
7	El aplicativo debe permitir subir archivos	4	1	7	Franz Alba Mejía Luis Mostacero Pérez	SI	12/05/2023	20/05/2023
8	El aplicativo debe permitir crear video	4	1	7	Franz Alba Mejía Luis Mostacero Pérez	SI	17/05/2023	30/05/2023
9	El aplicativo debe mostrar video subidos	5	1	7	Franz Alba Mejía Luis Mostacero Pérez	SI	19/05/2023	10/06/2023
10	El aplicativo debe mostrar los tipos de síntomas detectados	5	1	7	Franz Alba Mejía Luis Mostacero Pérez	SI	26/05/2023	16/06/2023
11	El aplicativo debe de mostrar un reporte gráfico con los síntomas	5	1	7	Franz Alba Mejía Luis Mostacero Pérez	SI	17/06/2023	30/06/2023

## c. Sprints

Nro.	Requerimiento	Sprints					
		1	2	3	4	5	6
1	Seleccionar herramientas para el desarrollo de la aplicación.	1					
2	Identificar un template de interface	1					
3	Diseñar la base de datos		2				
4	Login de seguridad			3			
5	El aplicativo debe permitir registrar zonas			3			
6	El aplicativo debe permitir registrar hectáreas asociadas a la zona			3			
7	El aplicativo debe permitir leer video				4		
8	El aplicativo debe permitir leer síntomas				4		
9	El aplicativo debe resaltar la detección de los síntomas de las plantaciones.					5	
10	El aplicativo debe mostrar los tipos de síntomas detectados						6

Luego de la delimitación de sprints se capturó historias de usuario en base a los requerimientos, para tener un entendimiento más amplio de los requerimientos del cliente.

Tabla 29 . HU-004. Login de Seguridad

ID:		HU-001		Historia de Usuario:	
				<b>Login de seguridad</b>	
Usuario:	Cualquier Usuario que haga uso del sistema				
Deseo:	Acceso a la aplicación				
Para:	Interactuar con aplicación.				
Prerrequisitos:	Estar registrado como usuario del software				
<b>Criterios de Aceptación</b>					
<b>Funcionales</b>			<b>Técnicos</b>		
<ul style="list-style-type: none"> <li>• Ingreso exitoso.</li> <li>• Ingreso Fallido.</li> </ul>			* El usuario logueado genera la variable de sesión que almacena sus datos en un token único		
Tipo de Prioridad:	Alto	Medio	Bajo		
Persona Asignada:	X				

Tabla 30. HU-005

ID:		HU-005		Historia de Usuario:	
				<b>Registrar áreas</b>	
Usuario:	Rol de administrador				
Deseo:	Registrar áreas				
Para:	Registrar datos de áreas.				
Prerrequisitos:	Acceso previo al sistema Tener el rol de administrador				
<b>Criterios de Aceptación</b>					
<b>Funcionales</b>			<b>Técnicos</b>		
Formulario registro áreas. Validación de data Botón de guardado			Área ingresada manualmente.		
Tipo de Prioridad:	Alto	Medio	Bajo		
Persona Asignada:		X			

<b>ID:</b>	<b>HU-006</b>	<b>Historia de Usuario:</b> <b>Gestionar usuarios</b>		
<b>Usuario:</b>	Rol de administrador			
<b>Deseo:</b>	Gestionar usuarios			
<b>Para:</b>	Registrar datos de usuarios.			
<b>Prerrequisitos:</b>	Acceso previo al sistema			
<b>Criterios de Aceptación</b>				
<b>Funcionales</b>			<b>Técnicos</b>	
Formulario registro usuarios. Validación de data Botón de guardado			Usuarios se ingresan manualmente. Validar que no existan usuarios repetidos	
<b>Tipo de</b>	<b>Alto</b>	Medio	Bajo	
<b>Prioridad:</b>				
<b>Persona Asignada:</b>		x		

*Tabla 32. HU-007*

<b>ID:</b>	<b>HU-007</b>	<b>Historia de Usuario:</b> <b>Subir archivos</b>		
<b>Usuario:</b>	Rol de administrador			
<b>Deseo:</b>	Subir archivos de videos			
<b>Para:</b>	Lectura de plantaciones.			
<b>Prerrequisitos:</b>	Acceso previo al sistema			
<b>Criterios de Aceptación</b>				
<b>Funcionales</b>			<b>Técnicos</b>	
Formulario de lectura de archivos (vídeos). Validación de data			Leer formato MP4, VID.	
<b>Tipo de</b>	<b>Alto</b>	Medio	Bajo	
<b>Prioridad:</b>				
<b>Persona Asignada:</b>	x			

Tabla 33. HU008. Crear vídeo

<b>ID:</b>	<b>HU-008</b>	<b>Historia de Usuario:</b> <b>Crear video</b>		
<b>Usuario:</b>	Rol de administrador			
<b>Deseo:</b>	Leer imágenes			
<b>Para:</b>	Lectura de archivos para crear video.			
<b>Prerrequisitos:</b>	Acceso previo al sistema			
<b>Criterios de Aceptación</b>				
<b>Funcionales</b>			<b>Técnicos</b>	
Formulario leer imágenes. Validación de data Botón de guardado			Creación de video a partir de imágenes.	
<b>Tipo de</b>	<b>Alto</b>	<b>Medio</b>	<b>Bajo</b>	
<b>Prioridad:</b>				
<b>Persona Asignada:</b>	X			

Tabla 34. HU-009. Mostrar videos subidos

<b>ID:</b>	<b>HU-009</b>	<b>Historia de Usuario: Mostrar vídeos subidos</b>		
<b>Usuario:</b>	Rol de operador			
<b>Deseo:</b>	Mostrar videos subidos o creados			
<b>Para:</b>	Visualizar imágenes.			
<b>Prerrequisitos:</b>	Acceso previo al sistema			
<b>Criterios de Aceptación</b>				
<b>Funcionales</b>			<b>Técnicos</b>	
Formulario muestra videos subidos. Mostrar resaltado de colores Botón de guardado			Mostar video para ser analizados	
<b>Tipo de</b>	<b>Alto</b>	<b>Medio</b>	<b>Bajo</b>	
<b>Prioridad:</b>				
<b>Persona Asignada:</b>	X			

Tabla 35. HU-010. Mostrar tipos de síntomas

<b>ID:</b>	<b>HU-010</b>	<b>Historia de Usuario: Mostrar tipos de síntomas</b>		
<b>Usuario:</b>	Rol de administrador			
<b>Deseo:</b>	Mostrar tipos de síntomas			
<b>Para:</b>	Visualizar tipos síntomas para identificar inconvenientes.			
<b>Prerrequisitos:</b>	Acceso previo al sistema			
<b>Criterios de Aceptación</b>				
<b>Funcionales</b>			<b>Técnicos</b>	
Formulario visualizar tipos de síntomas. <i>Mostrar valores en % de acuerdo a tipo de síntoma</i> Botón de guardado			Aparecer como leyenda valores de acuerdo a % síntoma	
<b>Tipo de</b>	<b>Alto</b>	<b>Medio</b>	<b>Bajo</b>	
<b>Prioridad:</b>				
<b>Persona Asignada:</b>	x			

Tabla 36. HU-011. Mostrar reporte gráfico

<b>ID:</b>	<b>HU-011</b>	<b>Historia de Usuario: Mostrar reporte gráfico de síntomas</b>		
<b>Usuario:</b>	Rol de operador			
<b>Deseo:</b>	Mostrar reporte gráfico de síntomas			
<b>Para:</b>	Visualizar reporte de tipos de síntomas para identificar inconvenientes.			
<b>Prerrequisitos:</b>	Acceso previo al sistema			
<b>Criterios de Aceptación</b>				
<b>Funcionales</b>			<b>Técnicos</b>	
Formulario visualizar en forma gráfica <i>por tipo de síntoma</i> Botón de consulta			Mostrar gráficamente con porcentajes saludable, nitrógeno, fósforo y hierro.	
<b>Tipo de</b>	<b>Alto</b>	<b>Medio</b>	<b>Bajo</b>	
<b>Prioridad:</b>				
<b>Persona Asignada:</b>	x			

e. Interfaces

Figura 11. HU-004. Login de Seguridad



**Tesis**

Ingrese a su cuenta

Inicia sesión para acceder a esta página.

Usuario

Admin

Contraseña

.....

Iniciar Sesión

Figura 12. HU-005. Registrar áreas



**Áreas**

- Área 1 [Eliminar](#)
- Área 2 [Eliminar](#)

area  Agregar

Figura 13. HU-006. Gestionar usuarios



**Usuarios**

- Admin [Eliminar](#)
- User [Eliminar](#)

Nombre del user  Contraseña  Agregar

Figura 14. HU007. Subir archivos (videos)

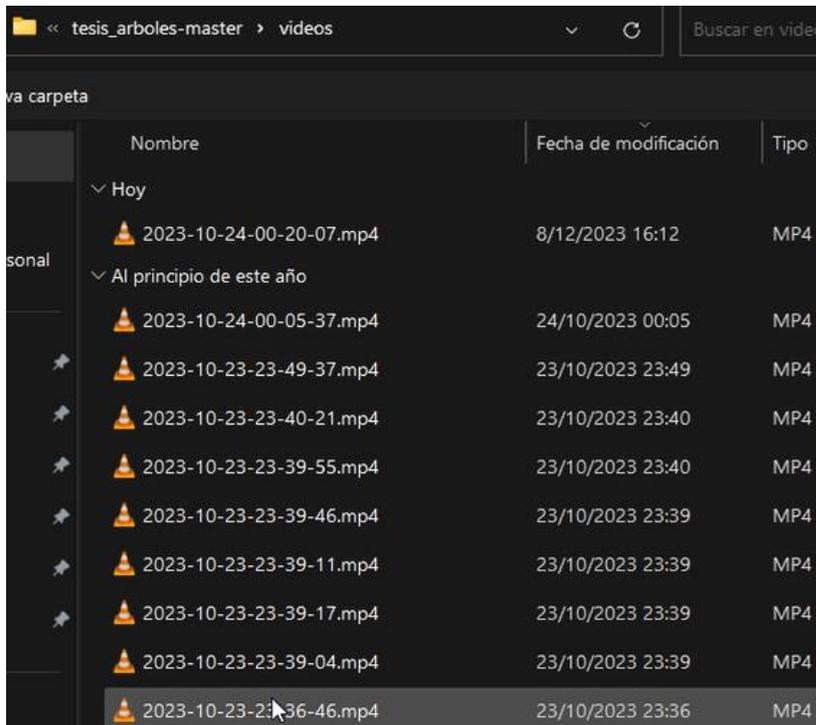
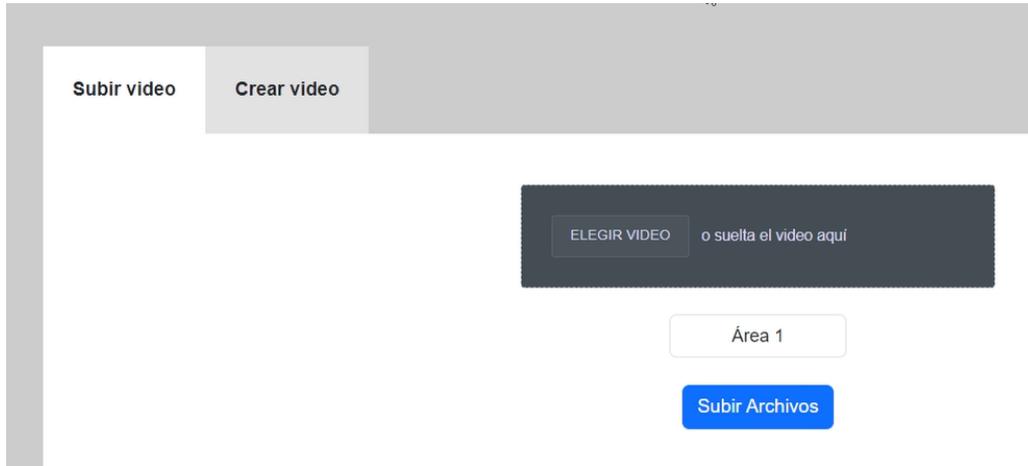
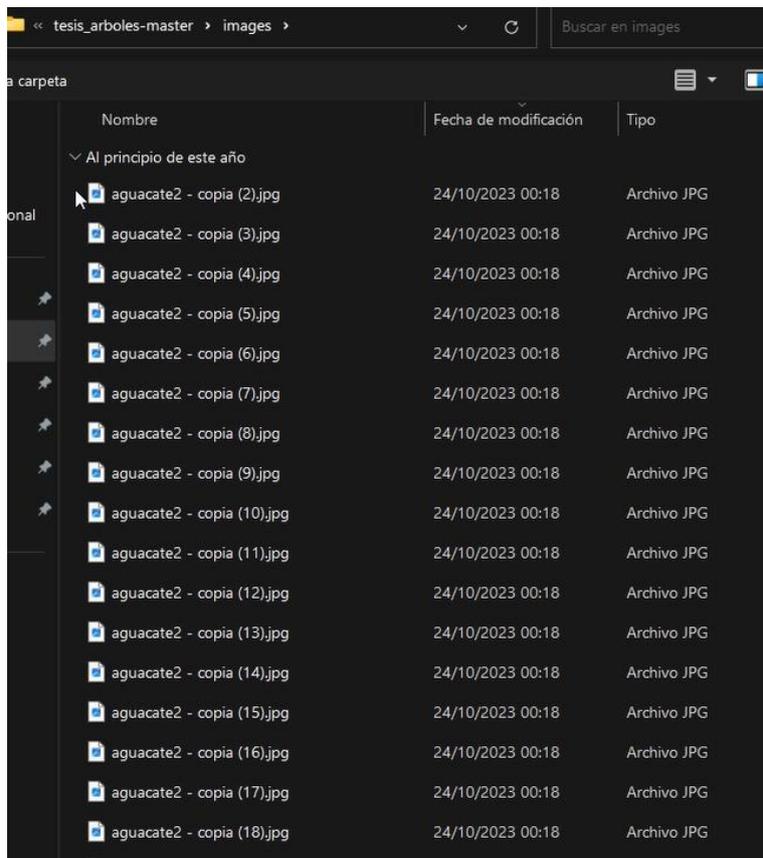


Figura 15. HU008. Crear Video



Subir imágenes



## Agregar Áreas

Figura 16. HU009. Mostrar videos subidos por área

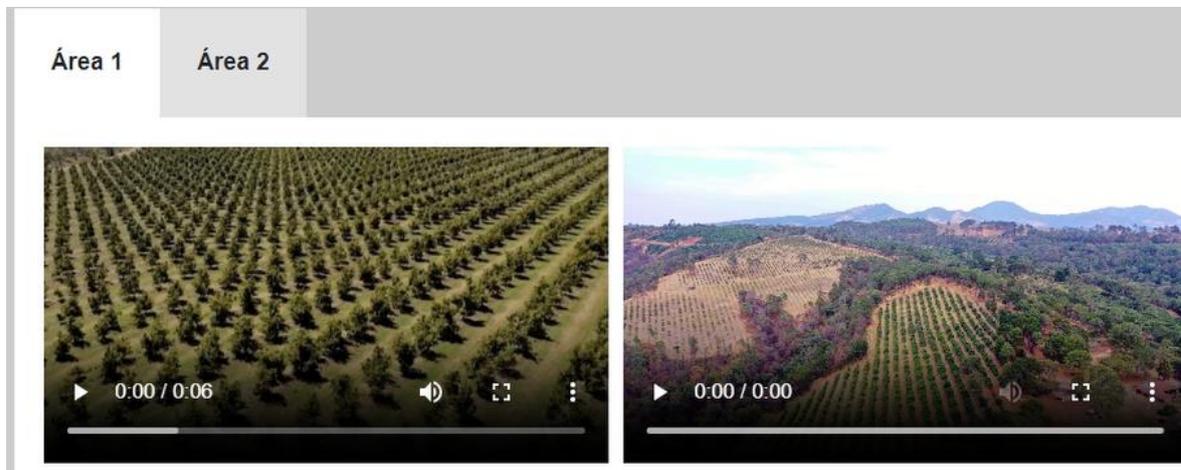


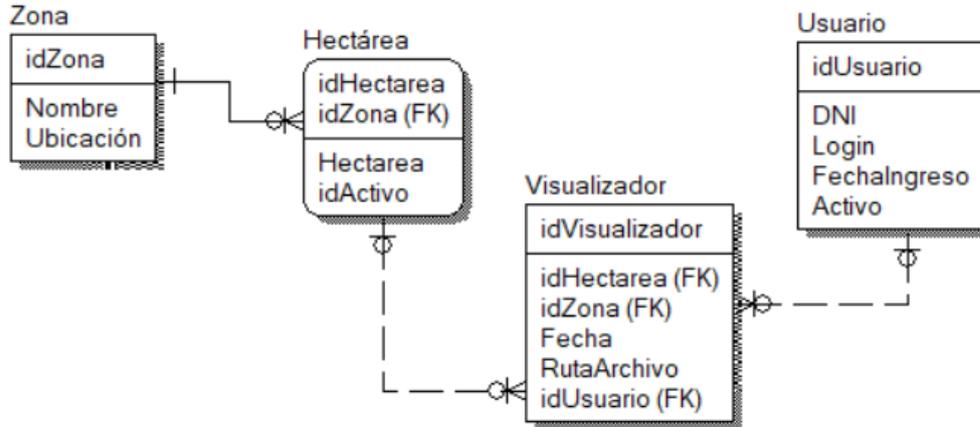
Figura 17. HU0010. Mostrar síntomas detectados



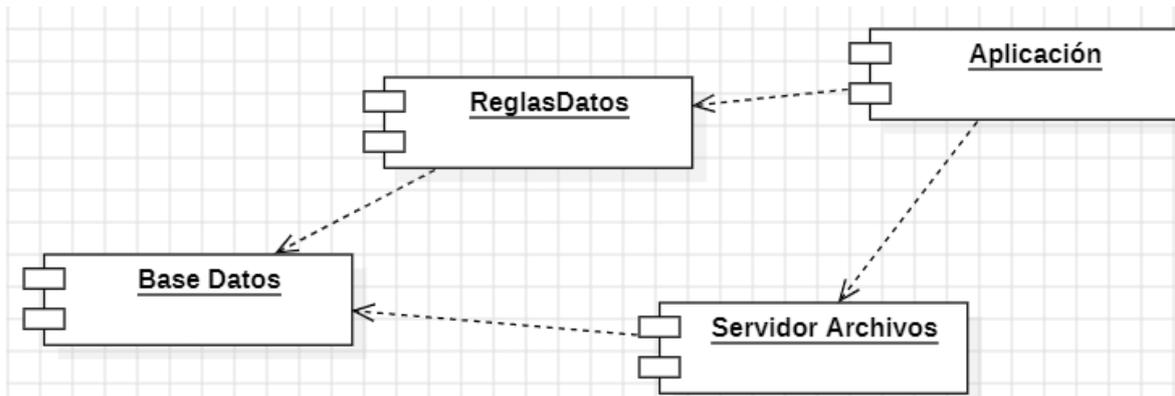
Figura 18. HU011. Reporte de síntomas



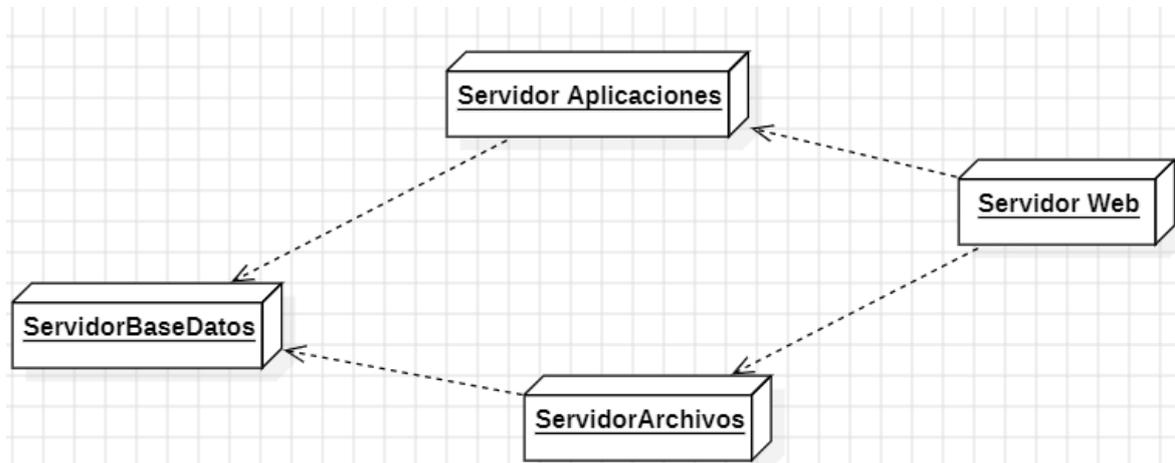
### Base de Datos



### Arquitectura

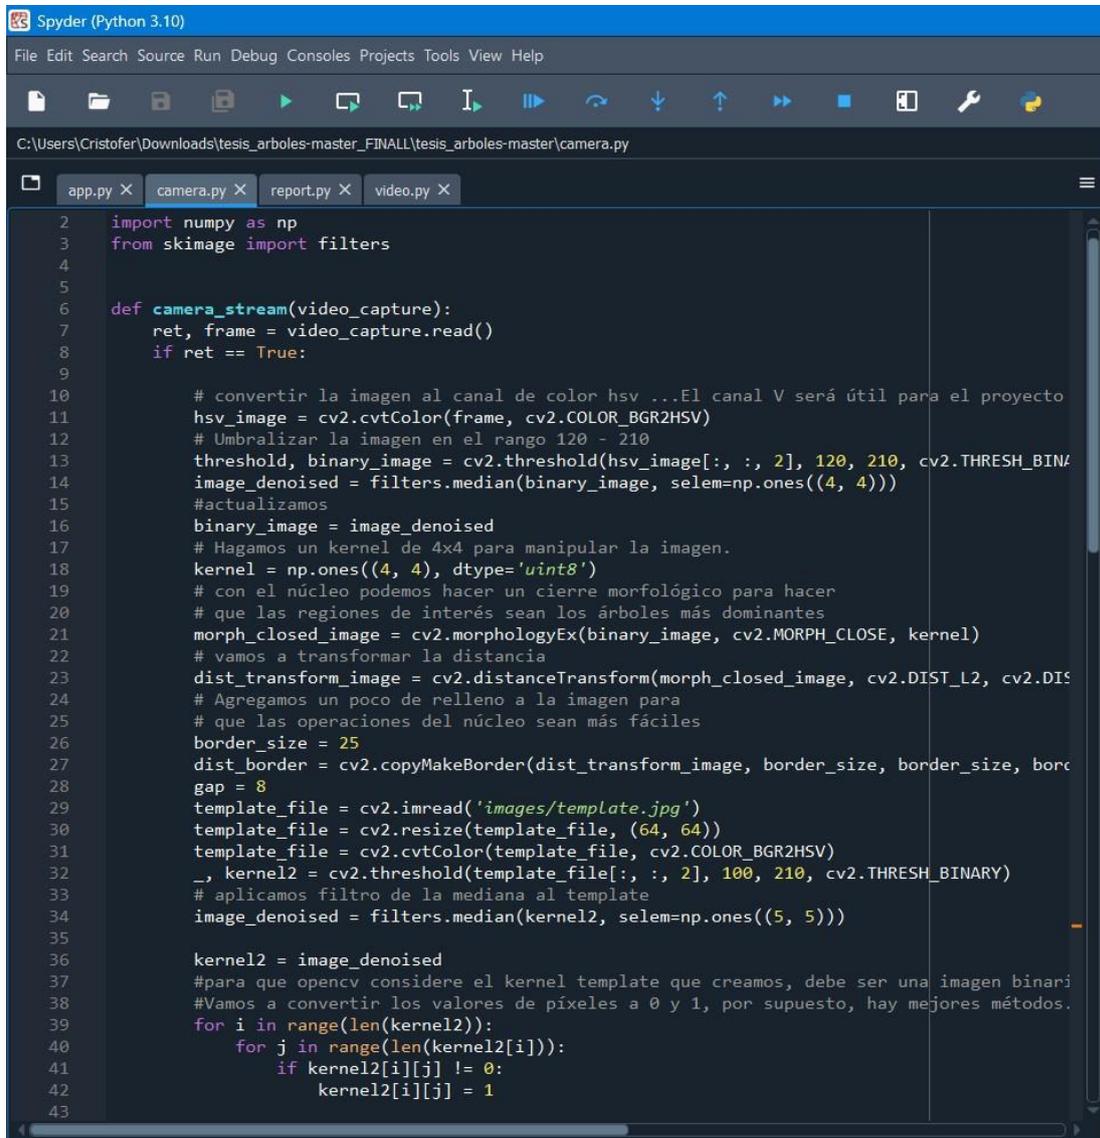


### Despliegue



## MUESTRA DE CODIGO FUENTE

### A. CODIGO MUESTRA PARA CAPTURAR VIDEO

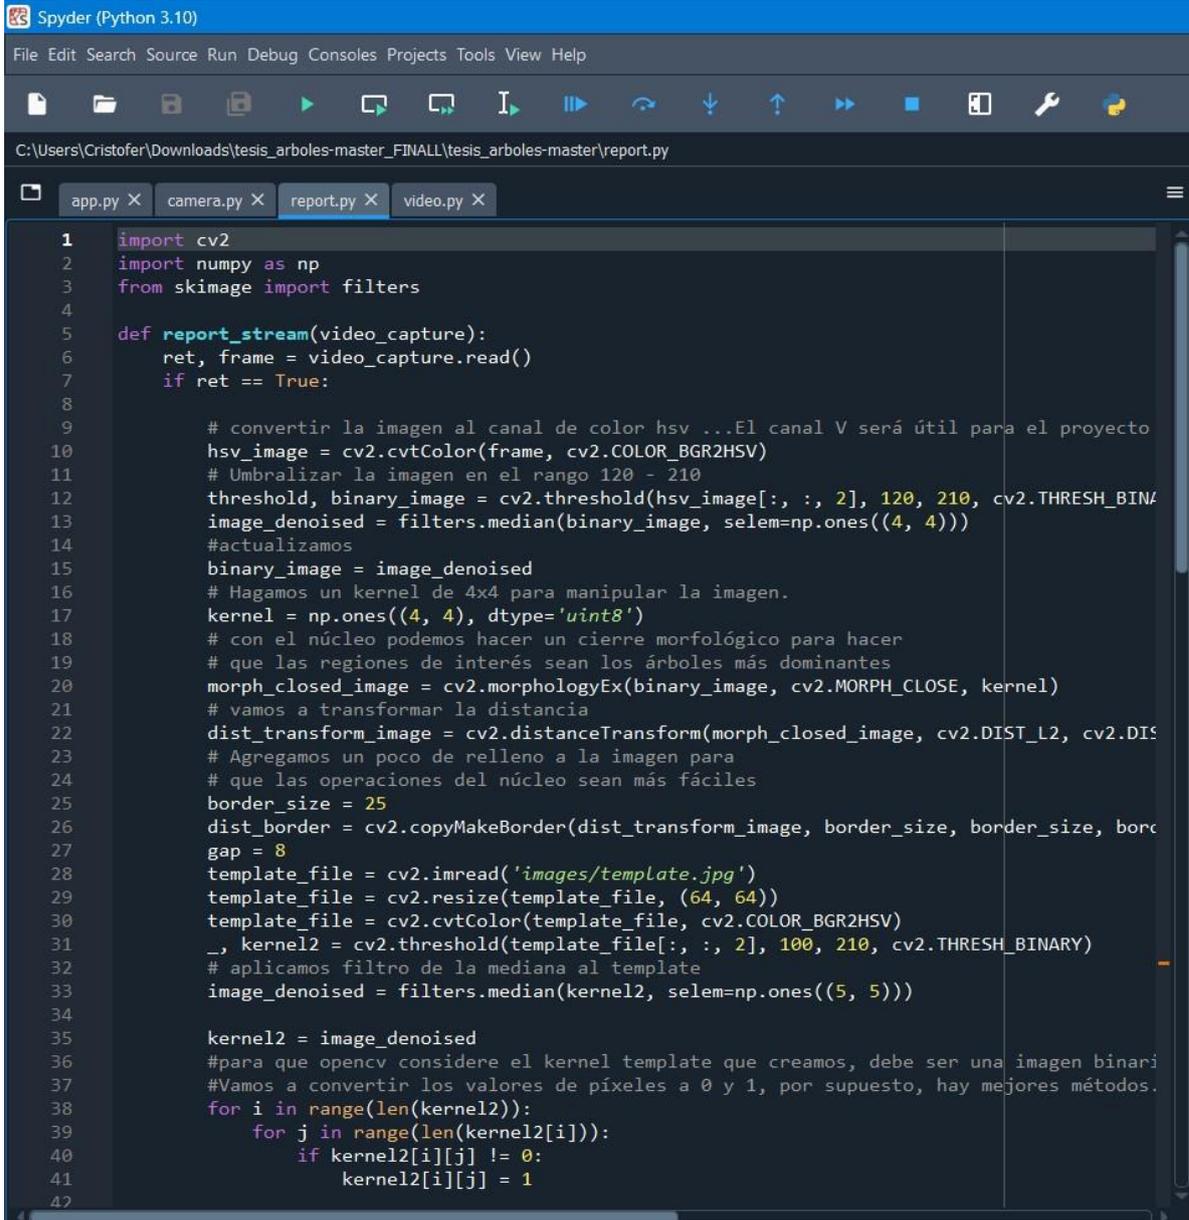


```

2 import numpy as np
3 from skimage import filters
4
5
6 def camera_stream(video_capture):
7     ret, frame = video_capture.read()
8     if ret == True:
9
10        # convertir la imagen al canal de color hsv ...El canal V será útil para el proyecto
11        hsv_image = cv2.cvtColor(frame, cv2.COLOR_BGR2HSV)
12        # Umbralizar la imagen en el rango 120 - 210
13        threshold, binary_image = cv2.threshold(hsv_image[:, :, 2], 120, 210, cv2.THRESH_BINARY)
14        image_denoised = filters.median(binary_image, selem=np.ones((4, 4)))
15        #actualizamos
16        binary_image = image_denoised
17        # Hagamos un kernel de 4x4 para manipular la imagen.
18        kernel = np.ones((4, 4), dtype='uint8')
19        # con el núcleo podemos hacer un cierre morfológico para hacer
20        # que las regiones de interés sean los árboles más dominantes
21        morph_closed_image = cv2.morphologyEx(binary_image, cv2.MORPH_CLOSE, kernel)
22        # vamos a transformar la distancia
23        dist_transform_image = cv2.distanceTransform(morph_closed_image, cv2.DIST_L2, cv2.DIST_MASK_CROSS)
24        # Agregamos un poco de relleno a la imagen para
25        # que las operaciones del núcleo sean más fáciles
26        border_size = 25
27        dist_border = cv2.copyMakeBorder(dist_transform_image, border_size, border_size, border_size, border_size, cv2.BORDER_CONSTANT, value=0)
28        gap = 8
29        template_file = cv2.imread('images/template.jpg')
30        template_file = cv2.resize(template_file, (64, 64))
31        template_file = cv2.cvtColor(template_file, cv2.COLOR_BGR2HSV)
32        _, kernel2 = cv2.threshold(template_file[:, :, 2], 100, 210, cv2.THRESH_BINARY)
33        # aplicamos filtro de la mediana al template
34        image_denoised = filters.median(kernel2, selem=np.ones((5, 5)))
35
36        kernel2 = image_denoised
37        #para que opencv considere el kernel template que creamos, debe ser una imagen binaria
38        #Vamos a convertir los valores de píxeles a 0 y 1, por supuesto, hay mejores métodos.
39        for i in range(len(kernel2)):
40            for j in range(len(kernel2[i])):
41                if kernel2[i][j] != 0:
42                    kernel2[i][j] = 1
43

```

## B. REPORTE



```
1 import cv2
2 import numpy as np
3 from skimage import filters
4
5 def report_stream(video_capture):
6     ret, frame = video_capture.read()
7     if ret == True:
8
9         # convertir la imagen al canal de color hsv ...El canal V será útil para el proyecto
10        hsv_image = cv2.cvtColor(frame, cv2.COLOR_BGR2HSV)
11        # Umbralizar la imagen en el rango 120 - 210
12        threshold, binary_image = cv2.threshold(hsv_image[:, :, 2], 120, 210, cv2.THRESH_BINARY)
13        image_denoised = filters.median(binary_image, selem=np.ones((4, 4)))
14        #actualizamos
15        binary_image = image_denoised
16        # Hagamos un kernel de 4x4 para manipular la imagen.
17        kernel = np.ones((4, 4), dtype='uint8')
18        # con el núcleo podemos hacer un cierre morfológico para hacer
19        # que las regiones de interés sean los árboles más dominantes
20        morph_closed_image = cv2.morphologyEx(binary_image, cv2.MORPH_CLOSE, kernel)
21        # vamos a transformar la distancia
22        dist_transform_image = cv2.distanceTransform(morph_closed_image, cv2.DIST_L2, cv2.DIST_MASK_CROSS)
23        # Agregamos un poco de relleno a la imagen para
24        # que las operaciones del núcleo sean más fáciles
25        border_size = 25
26        dist_border = cv2.copyMakeBorder(dist_transform_image, border_size, border_size, border_size, border_size, cv2.BORDER_CONSTANT, value=0)
27        gap = 8
28        template_file = cv2.imread('images/template.jpg')
29        template_file = cv2.resize(template_file, (64, 64))
30        template_file = cv2.cvtColor(template_file, cv2.COLOR_BGR2HSV)
31        _, kernel2 = cv2.threshold(template_file[:, :, 2], 100, 210, cv2.THRESH_BINARY)
32        # aplicamos filtro de la mediana al template
33        image_denoised = filters.median(kernel2, selem=np.ones((5, 5)))
34
35        kernel2 = image_denoised
36        #para que opencv considere el kernel template que creamos, debe ser una imagen binaria
37        #Vamos a convertir los valores de pixeles a 0 y 1, por supuesto, hay mejores métodos.
38        for i in range(len(kernel2)):
39            for j in range(len(kernel2[i])):
40                if kernel2[i][j] != 0:
41                    kernel2[i][j] = 1
42
```

**EJEMPLO DE ACTA DE REUNIÓN**
**ACTA DE REUNIÓN**

## 1. Características de la reunión

<b>Reunión</b>	Presencial		Virtual	X
<b>Tipo de reunión</b>	Daily Sprint			
<b>Propósito de la reunión</b>	Documentación			
<b>Lugar</b>	Google meet			
<b>Fecha</b>	04/06/2023			

## 2. Acuerdos de la reunión

Ítem	Acuerdos	Responsable	Fecha
1	Mostrar en diversos colores las plantaciones	Franz Alba, Luis Mostacero	28/05/2023-Cerrado
2	Analizar diferentes videos	Franz Alba, Luis Mostacero	30/05/2023-Cerrado
3	Mantener un reporte de manera porcentual	Franz Alba, Luis Mostacero	02/06/2023-Pendiente
4	Debe correr sobre un navegador	Franz Alba, Luis Mostacero	02/06/2023-Cerrado

## 3. Firma

Ítem	Acuerdos	Asistió	Firma
1	Franz Alba	Sí	
2	Luis Mostacero	Sí	
3		Sí	