



**INSTITUTO TECNOLÓGICO SUPERIOR  
DE SAN ANDRÉS TUXTLA  
INVESTIGACIÓN**



**OBJETIVOS Y APLICACIONES DE LAS BASES DE DATOS EN LA  
INTELIGENCIA ARTIFICIAL APLICADAS A LA INGENIERÍA  
MECATRÓNICA**

**CARRERA:**

**INGENIERO EN MECATRÓNICA**

**ALUMNO:**

**NAOMI ROSAS MINQUIZ**

**DOCENTE:**

**M.T.I. ROBERTO ESTEBAN GUERRERO HERNANDEZ**

**SAN ANDRÉS TUXTLA, 2025**





# **Objetivos y Aplicaciones de las Bases de Datos en la Inteligencia Artificial aplicadas a la Ingeniería Mecatrónica**

## **Resumen**

La Inteligencia Artificial (IA) ha adquirido un papel fundamental en el desarrollo de sistemas inteligentes dentro de la Ingeniería Mecatrónica. Uno de los elementos esenciales para su correcto funcionamiento es el uso de bases de datos, las cuales permiten almacenar, organizar y gestionar grandes volúmenes de información. El presente trabajo tiene como objetivo analizar la importancia de las bases de datos en la IA, describiendo sus objetivos y principales aplicaciones dentro del ámbito universitario y su impacto en la Ingeniería Mecatrónica. A través de una investigación documental, se examinan los beneficios que aportan las bases de datos en el aprendizaje automático, la automatización de procesos, el mantenimiento predictivo y el desarrollo de sistemas autónomos.

**Palabras clave:** Bases de datos, Inteligencia Artificial, Ingeniería Mecatrónica, Automatización, Aprendizaje automático.

## **1. Introducción**

El avance tecnológico ha propiciado la integración de diversas disciplinas para el desarrollo de sistemas inteligentes capaces de analizar información, aprender de ella y tomar decisiones autónomas. La Inteligencia Artificial se apoya en grandes volúmenes de datos para entrenar modelos y generar conocimiento, lo que hace indispensable el uso de bases de datos eficientes y bien estructuradas.

En la Ingeniería Mecatrónica, las bases de datos permiten gestionar información proveniente de sensores, sistemas de control, robots y procesos industriales. Estos datos, al ser procesados mediante técnicas de IA, contribuyen a la mejora de la eficiencia, seguridad y precisión de los sistemas mecatrónicos. Por ello, resulta relevante estudiar los objetivos y aplicaciones de las bases de datos en la IA desde una perspectiva académica y aplicada.



## **2. Metodología**

La metodología empleada en este trabajo corresponde a una **investigación documental**, basada en el análisis y revisión de libros especializados, artículos científicos, publicaciones académicas y documentos técnicos relacionados con bases de datos, inteligencia artificial e ingeniería mecatrónica. Las fuentes consultadas permiten identificar conceptos clave, aplicaciones prácticas y tendencias actuales en la integración de estas tecnologías.

## **3. Objetivos de las Bases de Datos en la Inteligencia Artificial**

### **3.1 Objetivo General**

Analizar la función de las bases de datos como elemento fundamental en el desarrollo y aplicación de la Inteligencia Artificial en la Ingeniería Mecatrónica.

### **3.2 Objetivos Específicos**

- Organizar y estructurar la información necesaria para el entrenamiento de algoritmos de inteligencia artificial.
- Facilitar el acceso rápido y confiable a grandes volúmenes de datos utilizados por sistemas inteligentes.
- Garantizar la integridad, seguridad y consistencia de los datos empleados en procesos de aprendizaje automático.
- Permitir la actualización continua de información para sistemas de IA adaptativos.
- Apoyar la toma de decisiones automatizadas en sistemas mecatrónicos.



## **4. Aplicaciones de las Bases de Datos en la Inteligencia Artificial**

### **4.1 Bases de Datos y Aprendizaje Automático**

Las bases de datos son esenciales para almacenar los conjuntos de datos utilizados en el entrenamiento y validación de algoritmos de aprendizaje automático. En la Ingeniería Mecatrónica, estos datos pueden provenir de sensores, actuadores y sistemas de monitoreo.

### **4.2 Sistemas Inteligentes y Automatización**

La integración de bases de datos con sistemas de IA permite el desarrollo de procesos automatizados capaces de adaptarse a cambios en el entorno. Los sistemas mecatrónicos utilizan datos históricos y en tiempo real para optimizar su desempeño.

### **4.3 Mantenimiento Predictivo**

Mediante el análisis de datos almacenados en bases de datos, los sistemas de IA pueden identificar patrones que indiquen fallas futuras en maquinaria o robots, reduciendo costos y tiempos de inactividad.

### **4.4 Internet de las Cosas (IoT) y Sistemas Mecatrónicos**

Las bases de datos permiten almacenar información generada por dispositivos IoT, la cual es procesada por algoritmos de IA para mejorar el control y la toma de decisiones en sistemas mecatrónicos inteligentes.

### **4.5 Sistemas Autónomos y Robótica**

En robótica mecatrónica, las bases de datos facilitan el aprendizaje de comportamientos y la adaptación del sistema a distintos escenarios mediante el uso de inteligencia artificial.



## 5. Importancia de las Bases de Datos en la Ingeniería Mecatrónica

El uso de bases de datos en combinación con la inteligencia artificial permite mejorar la eficiencia operativa, la precisión en el control de sistemas, la seguridad en procesos industriales y el desarrollo de soluciones tecnológicas innovadoras. Asimismo, fortalece la formación académica de los estudiantes de Ingeniería Mecatrónica, preparándolos para enfrentar los retos de la industria 4.0.


## 6. Conclusiones

Las bases de datos constituyen un componente indispensable para el funcionamiento de la Inteligencia Artificial, ya que proporcionan la información necesaria para el aprendizaje y la toma de decisiones inteligentes. En la Ingeniería Mecatrónica, su aplicación permite el desarrollo de sistemas automatizados, autónomos y eficientes. A nivel universitario, el estudio de estas tecnologías resulta fundamental para la formación integral de futuros ingenieros, quienes deberán diseñar soluciones basadas en datos e inteligencia artificial.

## 7. Referencias

- Coronel, C., & Morris, S. (2019). *Database Systems: Design, Implementation, and Management*. Cengage Learning.
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach*. Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- IEEE. (s.f.). *Artificial Intelligence and Mechatronics Applications*. IEEE Xplore Digital Library.





INSTITUTO TECNOLÓGICO SUPERIOR  
DE SAN ANDRÉS TUXTLA



**ARQUITECTURA DE BASE DE DATOS  
PARA LA INTELIGENCIA ARTIFICIAL**



**ALUMNA:**

NAOMI ROSAS MINQUIZ

**DOCENTE:**

M.T.I. ROBERTO ESTEBAN GUERRERO HERNÁNDEZ

AGOSTO – DICIEMBRE 2025





# Agenda

- Interconexión IA y Arquitectura de Datos
  - Componentes Clave de la Arquitectura
  - Bases de Datos: Relacionales y NoSQL
  - Optimización y Calidad de Datos
  - Arquitecturas RAG, Agentes y Ética
- 
- 



# IA y Arquitectura de Datos



*Sala de control de análisis de datos: monitoreo y análisis de big data.*

La *Inteligencia Artificial* (IA) depende intrínsecamente de una arquitectura de datos robusta para el procesamiento eficiente y el análisis de grandes volúmenes de volúmenes de información. Una base de datos bien diseñada es crucial para el entrenamiento de modelos, la toma de decisiones algorítmicas y la escalabilidad de de soluciones de IA.

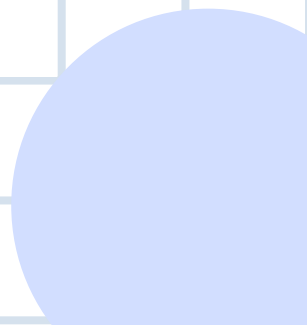





# Cimientos para la IA Escalable

## Escalable


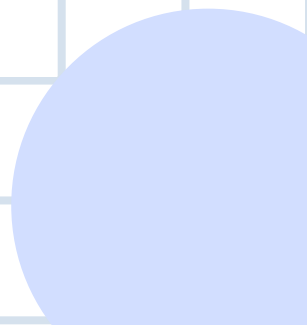
Una arquitectura de datos robusta es crucial para el éxito de la IA. Permite la **escalabilidad** y fiabilidad de los modelos. Líderes como Elida Godínez Godínez (IBM) enfatizan su rol en la transformación del negocio. Sin ella, los beneficios de la IA son limitados. Es la base para una IA real y sostenible.







# Componentes: Ingesta de Datos

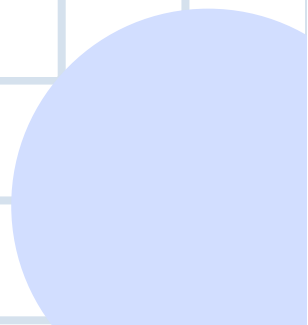

- Recolección de datos de múltiples fuentes.
  - Integración de datos heterogéneos y variados.
  - Transformación para compatibilidad y calidad.
  - Fundamental para el entrenamiento de IA.
- 
- 





# Componentes: Almacenamiento Estratégico


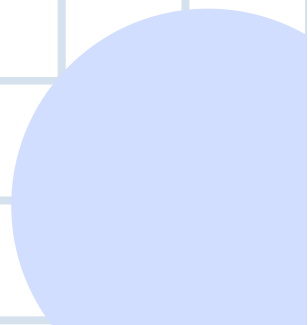
El almacenamiento estratégico es fundamental para la IA, ya que las estructuras de datos (ej., grafos, árboles, tensores) permiten a los sistemas computacionales construir **representaciones eficientes** del conocimiento. Estas representaciones son artefactos clave para el razonamiento algorítmico y el aprendizaje automático. La selección de la estructura de datos impacta directamente la eficiencia y escalabilidad de los modelos.








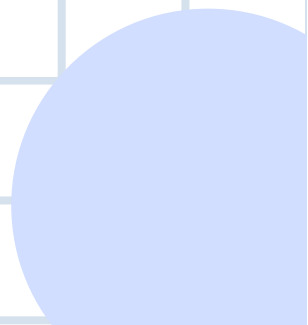
# Componentes: Procesamiento y Transformación

- Limpieza: Elimina ruido y datos inconsistentes.
  - Normalización: Escala datos a un rango uniforme.
  - Ingeniería de Características: Crea nuevas variables predictivas.
  - Optimiza calidad y formato para IA.
- 
- 






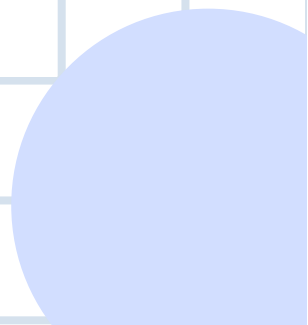
# Bases de Datos Relacionales en IA

- Modelan datos estructurados con tablas y relaciones.
  - Garantizan ACID: Atomicidad, Consistencia, Aislamiento, Durabilidad.
  - Vitales para datos de entrenamiento etiquetados.
  - Soportan sistemas de IA que exigen alta integridad.
- 
- 





# Bases de Datos NoSQL en IA

- Flexibilidad para datos no estructurados/semiestructurados.
  - Escalabilidad horizontal para grandes volúmenes.
  - Ideal para la diversidad de datos en IA.
  - Ejemplos: MongoDB, Cassandra, Neo4j.
- 
- 


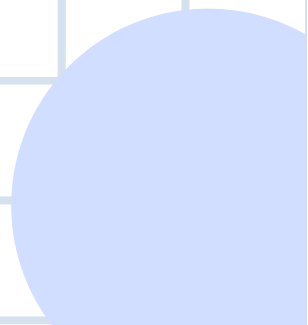


Tipo de NoSQL	Descripción	Casos de Uso en IA	Ejemplos
Documento	Almacena datos semiestructurados en formato de documentos (JSON, BSON). Flexible para esquemas cambiantes.	Gestión de perfiles de usuario y datos de sensores para modelos de <i>machine learning</i> , catalogación de contenido para NLP.	MongoDB, Couchbase
Clave-Valor	Almacena datos como un diccionario simple de clave-valor. Alta velocidad y escalabilidad horizontal.	Caché de características para modelos de inferencia, almacenamiento de estados de sesiones de usuario para personalización en tiempo real.	Redis, DynamoDB
Columna	Almacena datos en familias de columnas, optimizado para grandes volúmenes de datos y consultas analíticas.	Almacenamiento de series temporales para entrenamiento de modelos (ej. IoT), análisis de <i>logs</i> para detección de anomalías.	Cassandra, HBase
	Almacena datos como	Sistemas de recomendación (productos,	






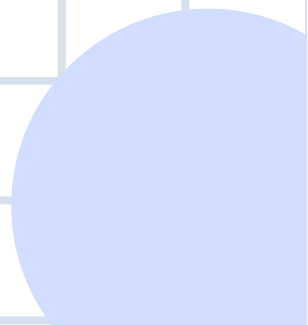
# Optimización: Calidad y Preparación Preparación

- Datos de calidad: base del éxito del modelo.
  - Detección de anomalías: identifica errores y sesgos.
  - Valores faltantes: impacto crítico en el rendimiento.
  - Preparación de datos: esencial para IA robusta.
- 
- 





# Optimización: Escalabilidad y Rendimiento

- Bases de datos distribuidas: Cassandra, Hadoop.
  - Almacenamiento en caché: Redis, Memcached.
  - Indexación avanzada: B-trees, hash tables.
  - Particionamiento y fragmentación de datos.
- 
- 





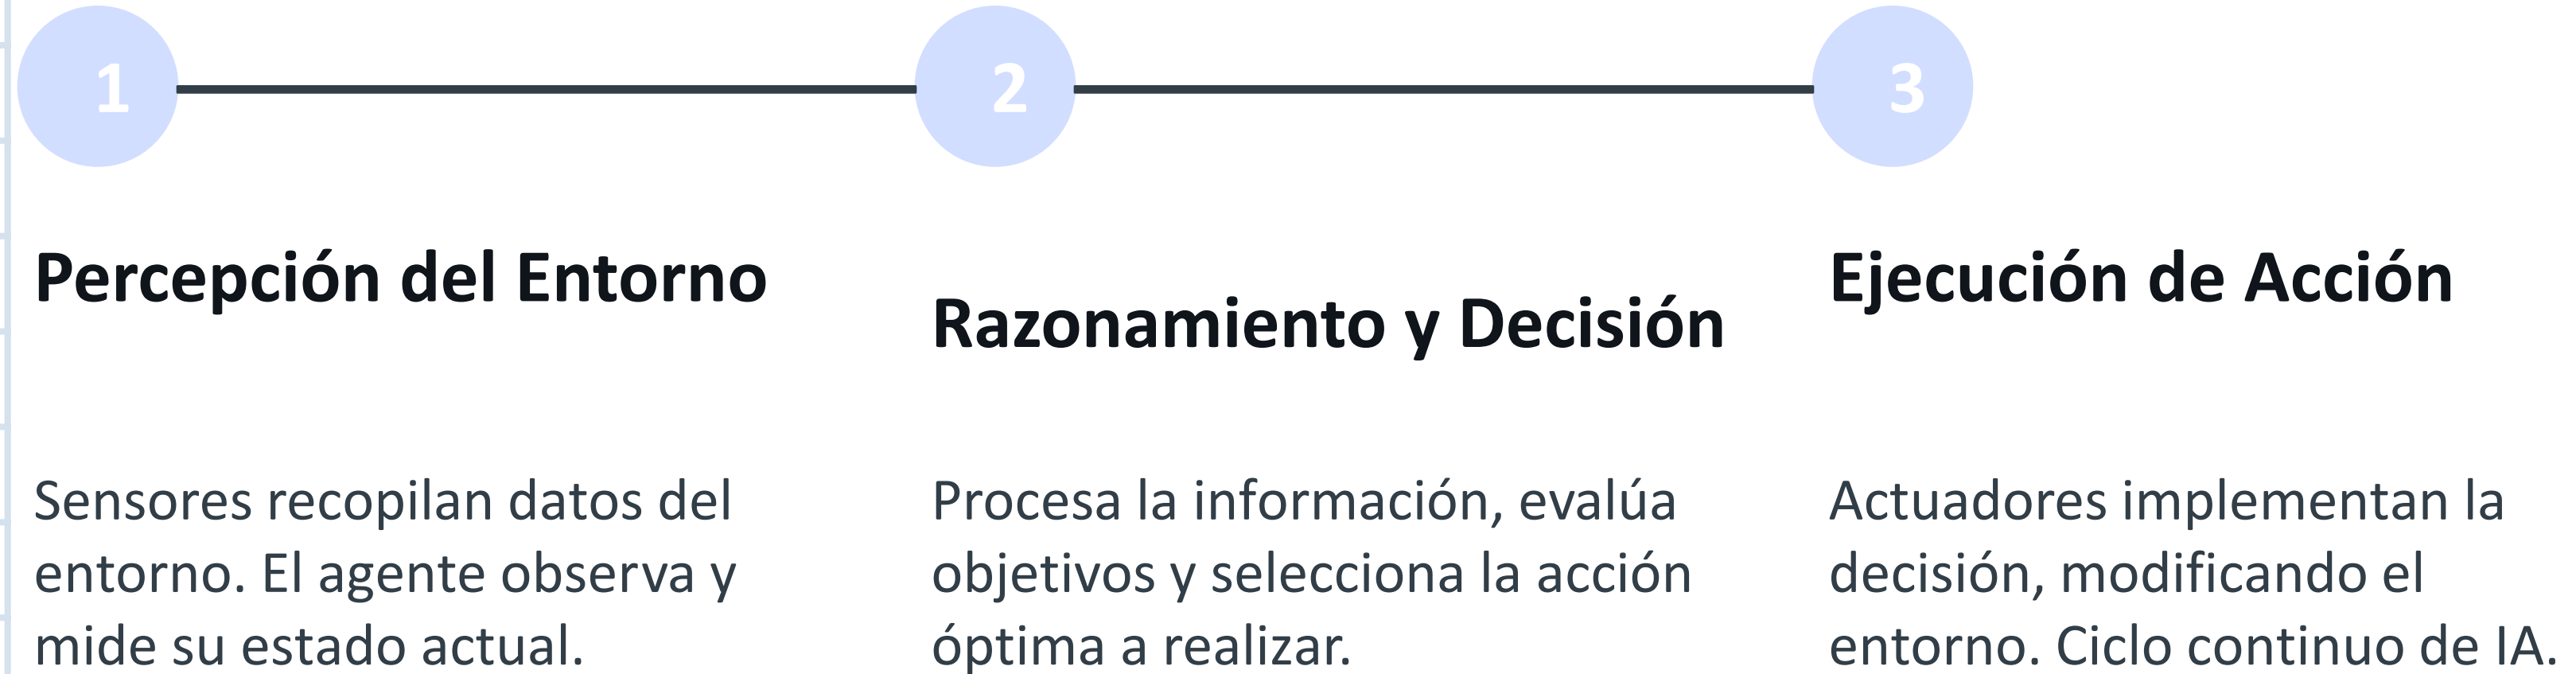
# Arquitectura RAG para IA Generativa

La arquitectura *Retrieval-Augmented Generation* (RAG) mejora la IA generativa al anclar las respuestas en documentos específicos. Esto limita las





# Arquitectura de Agentes de IA







# Consideraciones Éticas en Datos de IA

## Mitigación de Sesgos

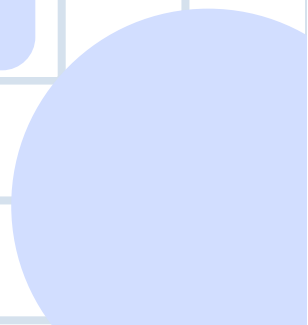

La diversidad en los datos de entrenamiento es crucial para evitar sesgos algorítmicos. Un modelo sesgado puede perpetuar o amplificar desigualdades.

## Privacidad y Seguridad

La protección de datos personales es fundamental. Implementar anonimización y cifrado resguarda la información sensible del usuario.

## Transparencia y Confianza


Comprender cómo y por qué la IA toma decisiones es vital. No debemos confiar ciegamente en sus resultados sin validación humana.





# Transformación Tecnológica por IA

La IA impulsa una **reestructuración radical** de la arquitectura tecnológica. Exige una reevaluación profunda de la infraestructura y los procesos. Esto incluye la adaptación de bases de datos, redes y sistemas operativos. La escalabilidad y la eficiencia son fundamentales para sostener cargas de trabajo de IA. Esta transformación es vital para la competitividad.



*Entorno industrial futurista: máquinas interconectadas y tecnología avanzada.*





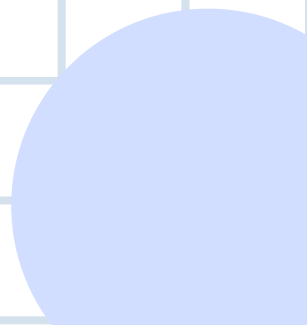

## Desafíos Actuales

La gestión de *datos masivos* y heterogéneos, la optimización de consultas complejas y la necesidad de baja latencia son desafíos clave. La integración de datos en tiempo real y la privacidad son obstáculos persistentes. La escalabilidad y la eficiencia energética también son preocupaciones importantes.



## Tendencias Futuras


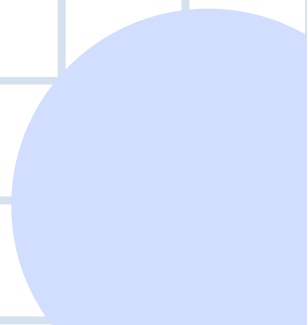
Se observa una evolución hacia bases de datos *vectoriales* y *grafos* para el aprendizaje profundo. La federación de datos y el procesamiento distribuido serán cruciales. La IA explicable y la gobernanza de datos impulsarán nuevas arquitecturas y estándares. La automatización de la gestión de bases de datos es una tendencia clave.







# Conclusion

- Una arquitectura de datos robusta es esencial para la IA, permitiendo la escalabilidad y el análisis profundo, como enfatiza Elida Godínez de IBM, cimentando sistemas efectivos.
  - La ingesta, almacenamiento estratégico y transformación de datos son componentes críticos, asegurando la calidad y el formato óptimo para el entrenamiento de modelos de IA.
  - Las bases de datos SQL y NoSQL ofrecen soluciones diversas; las NoSQL (documento, grafo) son ideales para datos no estructurados, cruciales en el procesamiento de lenguaje natural.
  - La optimización de datos, la mitigación de sesgos y la transparencia son imperativos éticos, transformando la infraestructura tecnológica para una IA responsable y confiable.
- 
- 





**GRACIAS**





**INSTITUTO TECNOLÓGICO SUPERIOR DE  
SAN ANDRÉS TUXTLA**



**PROYECTO:**

**“SISTEMA AUTOMATIZADO DE CLASIFICACIÓN DE NARANJAS POR ESTADO  
DE MADUREZ Y CALIDAD USANDO VISIÓN ARTIFICIAL”**

**CARRERA:**

**INGENIERÍA MECATRÓNICA**

**ALUMNA:**

**NAOMI ROSAS MINQUIZ**

**DOCENTE:**

**MTI. ROBERTO ESTEBAN GUERRERO HERNÁNDEZ**

ÚÜUÿÒÔVU

HÍ Æ

**SAN ANDRÉS TUXTLA, 2025**



## **Resumen**

El presente informe tiene como objetivo principal desarrollar un algoritmo que permita clasificar naranjas según atributos clave como tamaño, forma, color y presencia de defectos externos. Este proceso se basa en criterios establecidos por normas técnicas de calidad, buscando garantizar un control estandarizado acorde a la creciente demanda del cítrico en los mercados nacionales e internacionales.

El desarrollo propuesto utiliza técnicas de procesamiento digital de imágenes (HSV), implementadas mediante la biblioteca OpenCV en Python. El sistema realiza la captura de imágenes en tiempo real a través de una cámara web, seguido de etapas de preprocesamiento, segmentación basada en características visuales, análisis morfológico y clasificación de los frutos.

Además, el proyecto incluye el diseño e implementación de una cabina con iluminación controlada para garantizar condiciones óptimas en la adquisición de imágenes. La etapa de clasificación se complementa con un sistema de salida física controlado por una placa Arduino, que opera dos servomotores encargados de redirigir las naranjas según su categoría de calidad, permitiendo así un proceso automatizado y eficiente.

## **Introducción**

La creciente demanda de cítricos en los mercados nacionales e internacionales ha intensificado la necesidad de implementar sistemas de control de calidad más precisos, rápidos y eficientes. En particular, la clasificación de naranjas representa un desafío relevante dentro de la agroindustria, dado que factores como tamaño, forma, color y presencia de defectos externos inciden directamente en el valor comercial y en la aceptación del producto por parte de los consumidores. Tradicionalmente, este proceso se ha llevado a cabo de forma manual, lo que introduce variabilidad, limita la estandarización y disminuye la productividad frente a volúmenes de exportación cada vez mayores.



Ante este panorama, la aplicación de metodologías basadas en procesamiento digital de imágenes y automatización mecatrónica constituye una alternativa viable y de alto impacto. Estas tecnologías permiten no solo incrementar la precisión en la clasificación, sino también garantizar un proceso repetible, escalable y adaptable a diferentes condiciones operativas. En este contexto, el uso del modelo de color HSV, combinado con técnicas de segmentación y análisis morfológico implementadas en la biblioteca OpenCV de Python, ofrece una base robusta para identificar con fiabilidad las características visuales de los frutos.

El presente trabajo propone un sistema integral que combina la visión artificial con la automatización física, integrando hardware y software en una solución mecatrónica orientada al sector agroalimentario. Para asegurar la consistencia en la adquisición de datos, se diseñó una cabina con iluminación controlada que reduce variaciones ambientales en la captura de imágenes. La etapa de clasificación se vincula directamente con un módulo de salida gobernado por una placa Arduino y servomotores, responsables de redirigir los frutos según su categoría de calidad. De esta manera, se plantea un prototipo capaz de ejecutar la clasificación en tiempo real, garantizando un desempeño eficiente y estandarizado.

Este desarrollo no solo contribuye a optimizar la trazabilidad y la calidad en la producción citrícola, sino que también sienta las bases para la implementación de tecnologías avanzadas en la agroindustria, alineándose con la tendencia global hacia sistemas inteligentes, automatizados y sustentables.

## **Descripción del problema**

En la región de Los Tuxtlas, Veracruz, la producción de naranja representa una importante actividad económica para numerosos pequeños y medianos productores. Sin embargo, uno de los desafíos persistentes en esta cadena productiva es la clasificación eficiente y precisa de los frutos según su estado de madurez y calidad. Actualmente, este



proceso se realiza de forma manual, lo cual no solo consume tiempo y mano de obra, sino que también incrementa la posibilidad de errores humanos, afectando la uniformidad del producto final que llega al mercado.

La falta de tecnologías accesibles para automatizar esta etapa crítica del proceso productivo limita la competitividad de los agricultores locales frente a mercados que exigen estándares de calidad más rigurosos. Además, los sistemas industriales existentes de clasificación automatizada suelen ser costosos, complejos y diseñados para operaciones a gran escala, lo que los vuelve inadecuados para contextos de menor capacidad productiva como el de Los Tuxtlas.

Ante este panorama, surge la necesidad de desarrollar una solución tecnológica adaptable, de bajo costo y eficiente, que permita automatizar la clasificación de naranjas en función de parámetros visuales fácilmente detectables como el color y el estado físico del fruto.

### **Antecedentes teóricos**

La idea de la clasificación óptica surgió como una solución para automatizar el proceso de selección industrial de productos agrícolas, tales como frutas y verduras. Antes de que esta tecnología se desarrollara en la década de 1930, empresas como Unitec fabricaban máquinas de madera que facilitaban la clasificación mecánica durante el procesamiento de frutas. En 1931, se fundó la empresa "The Electric Sorting Company", la cual comenzó a diseñar las primeras clasificadoras de color, que fueron utilizadas por primera vez en la industria del frijol en Michigan en 1932. Para 1937, la tecnología de clasificación óptica ya había avanzado lo suficiente para incorporar sistemas basados en la selección de dos colores. A lo largo de las siguientes décadas, se mejoraron los mecanismos de clasificación, incorporando sistemas de alimentación por gravedad y extendiendo la aplicación de la clasificación óptica a diferentes sectores agrícolas.

Hacia finales de los años 60, esta tecnología comenzó a emplearse en industrias fuera del ámbito agrícola, como la clasificación de metales ferrosos y no ferrosos. En la década de 1990, la clasificación óptica se popularizó en la gestión de residuos sólidos. Con el



avance tecnológico a finales de los 90 y principios del 2000, los clasificadores ópticos lograron una mayor eficiencia gracias a la incorporación de sensores avanzados, como cámaras CCD, ultravioleta e infrarrojos. Actualmente, la clasificación óptica es ampliamente utilizada en diversos sectores, utilizando diferentes mecanismos según los requerimientos específicos de cada tarea de selección.

### **“Sistema de visión artificial para la identificación del estado de madurez de fruta (granadilla)”**

En el 2016 se desarrolló un sistema de visión artificial orientado a la identificación del estado de madurez de la fruta granadilla. Para la adquisición de imágenes se utilizó un módulo Pi-camera de Raspberry Pi con una resolución de 5 megapíxeles, capturando un total de 90 imágenes en el espacio de color RGB. Se implementó un sistema de iluminación direccional con luces LED y fondo negro opaco para asegurar uniformidad y calidad en las imágenes.

La metodología empleada incluyó las siguientes etapas: adquisición de imágenes, preprocesamiento (para reducir variaciones entre píxeles), segmentación (para extraer la fruta del fondo), y clasificación (según el color o la forma). El algoritmo fue validado mediante una matriz de confusión comparando los resultados automáticos con la evaluación manual de un técnico experto. El sistema logró una clasificación precisa del estado de madurez, utilizando datos de color en el espacio BGR, con un 70% de los datos usados para entrenamiento y el 30% para validación.

Este trabajo constituye un antecedente importante para el presente estudio, ya que aplica técnicas similares de visión artificial y procesamiento digital de imágenes en la clasificación de frutas por madurez. Aunque se enfoca en granadillas, las estrategias de captura, segmentación y clasificación son comparables y sirven como base metodológica para la implementación del sistema automatizado propuesto en esta tesis, orientado a la clasificación de naranjas.

Este estudio propuso un sistema automatizado de visión artificial para clasificar granadillas según su estado de madurez. Se empleó un módulo Pi-camera de Raspberry



Pi con resolución de 5 megapíxeles, obteniendo 90 imágenes en el espacio de color RGB, bajo condiciones controladas de iluminación LED y fondo negro opaco, lo cual permitió una adquisición precisa de las características visuales de la fruta.

La metodología consistió en varias etapas: adquisición de imágenes, preprocesamiento (para reducir las variaciones abruptas entre píxeles), segmentación (para separar la fruta del fondo), y clasificación de las frutas según su estado de madurez (verde, intermedio o maduro) en base al análisis de componentes de color BGR. Para el entrenamiento del algoritmo se utilizó el 70% de los datos, y el 30% restante se destinó a validación.

El sistema logró una precisión del 93% en la clasificación de las imágenes y una probabilidad de 92,6% de acierto en la detección del estado de madurez. El uso del color como atributo principal permitió separar fácilmente las clases, siendo representadas por colores predominantes en las regiones segmentadas: verde, amarillo y combinaciones de ambos en estados intermedios. Además, se evidencia que la herramienta computacional supera la evaluación convencional, la cual puede estar influenciada por el cansancio, la experiencia del técnico o la iluminación ambiental.

Este trabajo constituye un antecedente relevante para la presente investigación, ya que utiliza visión artificial y análisis de color para clasificar frutas, al igual que el sistema propuesto para naranjas. Aunque la especie de fruta difiere, los enfoques técnicos, los desafíos de segmentación y los criterios de clasificación son comparables, sirviendo de base metodológica y validando la factibilidad de automatizar este tipo de procesos en la agroindustria.

[1]

### **Diseño de un sistema por visión artificial para determinar la calidad de mandarinas**

En 2020 En el ámbito agroindustrial, la necesidad de mejorar los procesos de selección y clasificación de frutas ha impulsado el desarrollo de tecnologías que permitan automatizar dichas tareas. Un ejemplo relevante se encuentra en la clasificación de



mandarinas, donde se han implementado sistemas de visión artificial para evaluar parámetros de calidad como forma, color y presencia de defectos.

Una investigación relevante orientada a la automatización del control de calidad en productos cítricos fue el desarrollo de un sistema por visión artificial para la clasificación de mandarinas, alineado con la Norma Técnica Peruana NTP 011.023:2014 . Esta normativa establece criterios específicos para la comercialización de mandarinas, donde se consideran aspectos como la forma, el color y la detección de defectos físicos visibles.

En cuanto a la forma , el sistema fue diseñado para identificar que cada mandarina presenta una apariencia redonda y saludable, cumpliendo con los estándares visuales mínimos exigidos para su clasificación comercial. Respecto al color , se definieron cuatro categorías en función del porcentaje de superficie verde presente en la fruta: muy bien coloreada, bien coloreada, razonablemente coloreada y pobremente coloreada. Esta clasificación se llevó a cabo mediante la conversión de imágenes del espacio RGB al modelo HSV , lo que permitió una mejor segmentación y detección de tonalidades.

Para el procesamiento de imágenes , se utilizó el software MATLAB , aprovechando su capacidad para generar gráficos, utilizar cajas de herramientas especializadas en visión artificial y realizar cálculos científicos avanzados. Se aplicarán filtros y máscaras en el espacio HSV para destacar regiones de interés, facilitando así el reconocimiento de daños y defectos, además de evaluar el nivel de madurez de la fruta. Estos procesos se apoyaron en algoritmos de segmentación basados en regiones que permitieron identificar áreas similares en textura y color afectadas por imperfecciones.

Este trabajo demuestra cómo un enfoque sistemático, sustentado en normas técnicas nacionales y soportado por herramientas digitales como MATLAB, puede lograr una clasificación automatizada confiable de productos agrícolas, siendo una base metodológica relevante para investigaciones similares en frutas como las naranjas.

En este contexto, diversas investigaciones han optado por emplear el software MATLAB para implementar algoritmos de procesamiento de imágenes, dada su capacidad para manejar matrices, su compatibilidad con librerías especializadas en visión artificial y su



operatividad en tiempo real. Las funciones de segmentación en el espacio de color HSV permiten una evaluación más precisa de la madurez del fruto, al aislar regiones según sus características cromáticas. La conversión de imágenes RGB a HSV, combinada con técnicas de umbralización y segmentación por regiones, ha demostrado ser efectiva para la detección tanto de zonas verdes como de daños superficiales.

Además, se han reportado antecedentes en los que, mediante el uso del toolbox “Thresholder” de MATLAB, se determinan umbrales de color para identificar defectos o enfermedades presentes en la superficie del fruto. Estos métodos, basados en redes neuronales o segmentación tradicional, han logrado una alta precisión en la clasificación de mandarinas, sentando las bases para su aplicación en otros frutos cítricos como la naranja.

La integración de normas técnicas con herramientas computacionales ha permitido desarrollar sistemas cada vez más robustos para el aseguramiento de la calidad en la producción agrícola, especialmente en la postcosecha. Estos antecedentes justifican y respaldan el uso de visión artificial en el presente proyecto, orientado a la clasificación automatizada de naranjas según su estado de madurez y calidad externa.

### **Generalidades y estado actual de los sistemas de Visión Artificial**

La clasificación óptica representa una técnica avanzada para la inspección no destructiva de productos en línea, permitiendo evaluar el 100% de la producción en tiempo real, incluso en grandes volúmenes. Este método automatizado optimiza la eficiencia del proceso al detectar y separar productos con defectos sin necesidad de intervención manual.

Un sistema típico de clasificación óptica se compone de cuatro módulos principales: el mecanismo de alimentación, el sistema óptico de captura, el software encargado del procesamiento de imágenes y el sistema de separación o expulsión. El módulo de alimentación tiene la función de distribuir los productos en una sola capa uniforme, asegurando que los objetos lleguen al sistema óptico de manera homogénea y continua, evitando acumulaciones o interrupciones en el flujo.



El sistema óptico se compone de dispositivos de iluminación y sensores, ubicados estratégicamente alrededor del producto para captar imágenes desde diferentes ángulos. Las imágenes capturadas son procesadas por software especializado, el cual compara las características de cada objeto con parámetros previamente establecidos para determinar su aceptación o rechazo. Finalmente, el sistema de separación, que puede ser neumático para objetos pequeños o mecánico para productos voluminosos, actúa para retirar los elementos que no cumplen con las especificaciones, garantizando que solo el producto conforme continúe en la línea de producción.

### **Componentes Específicos del Sistema Óptico**

La elección de los sensores y las tecnologías de captura depende en gran medida de las características del producto a clasificar y de los objetivos del usuario. Por ejemplo, los sensores pueden combinar cámaras, láseres o ambos, y operan en diferentes rangos del espectro electromagnético, incluyendo luz visible, infrarroja y ultravioleta. Esta variedad permite maximizar el contraste entre productos buenos y defectuosos, mejorando la precisión de la clasificación.

#### **Cámaras**

Las cámaras juegan un papel fundamental en la clasificación basada en la forma, color y textura. Las cámaras monocromáticas son eficaces para detectar diferencias de contraste alto en productos con defectos evidentes, ya que capturan imágenes en tonos de gris. En contraste, las cámaras a color de alta resolución pueden distinguir millones de tonalidades, lo que facilita la identificación de defectos sutiles relacionados con cambios en el color.

Además, las cámaras tricromáticas segmentan la luz en tres bandas específicas (usualmente rojo, verde y azul), lo que amplía la capacidad de análisis del sistema, permitiendo detectar anomalías que no serían visibles a simple vista. Combinado con software avanzado, el sistema puede identificar no solo defectos individuales, sino también cuantificar la superficie total afectada de un producto para decidir si debe ser rechazado.



## **Láseres**

A diferencia de las cámaras, los sistemas láser exploran propiedades estructurales del material, como textura y composición, además del color. Esto permite detectar contaminantes o cuerpos extraños orgánicos e inorgánicos (vidrio, metal, insectos, piedras) que podrían tener el mismo color que el producto principal, pero difieren en su estructura física.

Los láseres pueden ser ajustados para operar en distintas longitudes de onda, optimizando la detección de ciertas sustancias específicas. Por ejemplo, se puede detectar la clorofila en vegetales verdes mediante fluorescencia inducida por láser, técnica que mejora significativamente la eliminación de material no deseado en líneas de productos agrícolas.

## **Sistemas Combinados**

El uso simultáneo de cámaras y láseres en un solo sistema permite aprovechar las fortalezas de ambos métodos, logrando una clasificación más completa. Mientras que las cámaras evalúan el color y la forma, los láseres aportan información estructural, aumentando la sensibilidad y especificidad del proceso de detección y rechazo.

## **Imágenes Multiespectrales e Hiperspectrales**

Recientemente, han surgido tecnologías de clasificación que emplean imágenes multiespectrales e hiperspectrales. Estas técnicas capturan información en múltiples bandas del espectro electromagnético, desde el visible hasta el infrarrojo, proporcionando un nivel de detalle mucho mayor que las cámaras tradicionales. A diferencia de las cámaras tricromáticas, que trabajan con tres bandas, los sistemas hiperspectrales pueden capturar cientos de bandas estrechas, creando una "firma espectral" única para cada tipo de producto o defecto.

Este tipo de análisis es especialmente útil para detectar defectos que no se aprecian con tecnologías convencionales, así como para clasificar productos basándose en su



composición química, una práctica que está en crecimiento dentro de la quimiometría aplicada a la industria alimentaria.

## **Procesamiento e Inteligencia Artificial**

El procesamiento de imágenes es el núcleo que transforma los datos capturados en decisiones útiles para la clasificación. Los algoritmos extraen características específicas, como color, forma, textura y ubicación de defectos, y aplican criterios definidos por el usuario para clasificar los productos. El desarrollo de software inteligente ha permitido que los sistemas no solo detecten defectos individuales, sino que puedan evaluar la calidad global del producto, mejorando la precisión y reduciendo errores.

Las técnicas modernas incluyen aprendizaje automático y redes neuronales que pueden adaptarse y mejorar con el tiempo, aprendiendo a reconocer patrones de defectos nuevos o cambiantes sin necesidad de reprogramación manual. Esto representa un avance significativo en la automatización de la inspección visual.

## **Aplicación del Sistema**


La última etapa integra hardware/actuadores (robots, desviadores, alarmas, interfaces), cerrando el lazo de acción. Ejemplos: sistemas de inspección automatizada (montaje), robótica con visión (pick & place), control de niveles de llenado, sistemas ADAS o monitoreo de salud ambiental, o manejo de mecanismos de selección operados con actuadores o servo motores.

El procesamiento en sistemas de visión artificial se basa en el uso de algoritmos diseñados para analizar imágenes digitales, con el fin de extraer información relevante, realizar evaluaciones automáticas y generar decisiones conforme a los criterios establecidos por la aplicación. Posteriormente, los resultados del análisis suelen transmitirse mediante señales discretas de entrada/salida (E/S) o a través de protocolos de comunicación como puertos seriales, hacia dispositivos encargados de registrar o actuar en función de dicha información. Actualmente, la mayoría de los elementos físicos que componen un sistema de visión artificial, como fuentes de iluminación, sensores

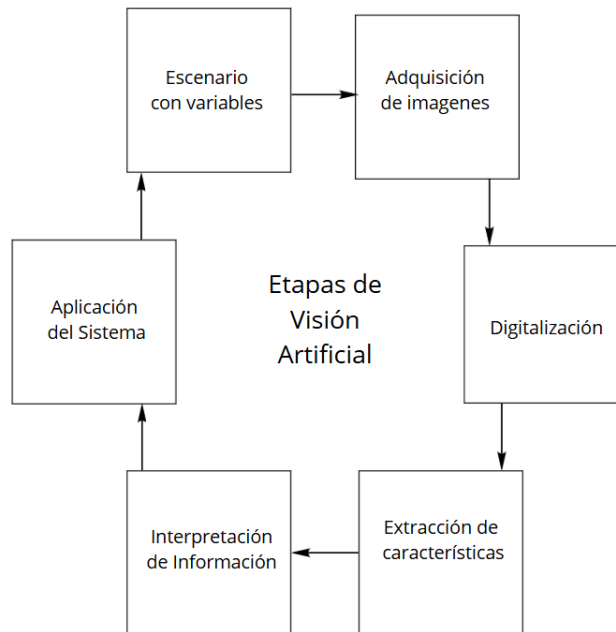


ópticos y unidades de procesamiento, se encuentran disponibles comercialmente bajo el concepto COTS ( *Commercial Off-The-Shelf* ). Esto permite tanto la construcción de soluciones personalizadas a partir de componentes individuales como la adquisición de sistemas integrados que reúnen todos los módulos necesarios en un solo dispositivo compacto.

En la siguiente figura se presentan los componentes fundamentales de un sistema de visión artificial, entre los cuales destacan la iluminación, las lentes, los sensores de imagen, los procesadores, el módulo de procesamiento visual y las interfaces de comunicación. Estos elementos trabajan en conjunto para garantizar la correcta captura, análisis y transmisión de información visual.







## Procesamiento Digital de Imágenes

El procesamiento digital de imágenes (PDI) es una disciplina que comprende un conjunto de técnicas aplicadas a imágenes digitales con el fin de mejorar su calidad, extraer información relevante y facilitar la toma de decisiones automatizadas.

El procesamiento de imágenes digitales en un sistema de visión artificial representa la etapa en la que se extrae información significativa a partir de los datos capturados por el sensor. Esta operación puede llevarse a cabo mediante plataformas externas, como sistemas basados en PC, o directamente dentro del propio sistema de visión, cuando este cuenta con capacidad de procesamiento integrada. El procedimiento se realiza mediante software especializado y suele incluir varias fases. Inicialmente, se adquiere la imagen desde el sensor óptico. En ciertos casos, se requiere aplicar un preprocesamiento con el objetivo de mejorar la calidad visual, resaltar detalles importantes y facilitar el análisis posterior. A continuación, el sistema identifica características específicas, realiza mediciones y verifica si los resultados se ajustan a criterios previamente definidos. Con base en esta evaluación, se genera una decisión



automatizada y se comunican los resultados al sistema principal o a los dispositivos correspondientes.

Aunque muchos de los componentes físicos de los sistemas de visión como la iluminación o los sensores presentan características similares entre diferentes fabricantes, es el software de procesamiento el que determina en gran medida la eficacia del sistema. Por ello, al comparar soluciones de visión artificial, es esencial considerar tanto el rendimiento del hardware como la capacidad del algoritmo para identificar con precisión los parámetros críticos.

Además, el software de visión puede encargarse de configurar los parámetros operativos de la cámara, emitir decisiones de aceptación o rechazo según los criterios establecidos, integrarse a la red industrial para la automatización de procesos y facilitar el desarrollo de interfaces hombre-máquina (HMI) que permitan supervisar y controlar el sistema de forma eficiente.

A continuación, se detallan las principales etapas que componen este proceso, cada una de ellas con un rol fundamental en el análisis visual computarizado:

### **Adquisición de Imagen**

La adquisición de imagen constituye la primera etapa del procesamiento digital, y se refiere a la captura de la escena o del objeto mediante sensores ópticos, tales como cámaras digitales, cámaras multiespectrales o sistemas de visión artificial. En esta fase, se obtienen los datos en forma de una imagen digital, los cuales servirán de base para las etapas posteriores del procesamiento. La calidad de esta captura depende de factores como la resolución del sensor, el enfoque óptico, la iluminación del entorno y las condiciones físicas del objeto a analizar.

### **Pre-procesado**

El preprocesamiento es una etapa esencial cuyo objetivo es mejorar la calidad visual y analítica de la imagen. Se aplican técnicas que permiten reducir el ruido, mejorar el



contraste, corregir defectos ópticos o ajustar las condiciones de iluminación. Entre los métodos más comunes se encuentran los filtros espaciales (como el filtro de mediana y el Gaussiano), la ecualización de histograma, la conversión a otros espacios de color (como HSV o CIELab) y la normalización de intensidad. Estas operaciones permiten obtener imágenes más limpias y estables para un análisis más preciso.

## **Segmentación**

La segmentación es el proceso mediante el cual una imagen es dividida en regiones homogéneas que comparten ciertas características, como color, textura o intensidad. Su propósito principal es aislar los objetos de interés del fondo o de otras estructuras no relevantes. Las técnicas de segmentación pueden clasificarse en varios grupos: por umbralización, detección de bordes, crecimiento de regiones, agrupamiento (clustering), o mediante algoritmos avanzados basados en inteligencia artificial. Una segmentación precisa es crucial, ya que permite que las características de los objetos se analicen de forma individual y detallada.

Es un proceso de nivel medio de visión artificial, consiste en separar una imagen digital en regiones de interés del resto no importante, con respecto a una o más características, por ejemplo: brillo, color, tamaño, longitud y forma (Roguiguez y Sossa, 2012, p.155). Este proceso es clave en el procesamiento debido que se obtiene información correcta o incorrecta de la imagen procesada.

Ejemplos de segmentación son: localizar los ojos de una persona al enfocarse con una cámara, separar los caracteres de un texto en una imagen, localizar las placas de los vehículos, detectar enfermedades en base a imágenes médicas. (García, 2008, p.71)


En la figura 15 se observa de manera gráfica la representación del proceso de segmentación de una imagen simple, se aprecia que antes de ingresar al proceso de segmentación se tiene una imagen digital brutal con distintos niveles de intensidad luminosa, pero luego de la segmentación se obtiene una información de los objetos existentes.



## Segmentación por umbralización

La umbralización consiste en un supuesto que los objetos están formados de píxeles de intensidad homogéneos, cada píxel es comparado con un umbral prefijado, este valor separa en dos categorías a la imagen en nivel gris y depende del valor del umbral para obtener una calidad de segmentación.

La umbralización es una técnica de segmentación fundamental en el procesamiento de imágenes, especialmente utilizada en aplicaciones industriales debido a su simplicidad y eficiencia. Esta técnica resulta efectiva cuando existe una diferencia notable en los niveles de intensidad entre los objetos de interés y el fondo de la imagen. Su principio básico se basa en la homogeneidad de los píxeles que conforman un objeto y su contraste con los píxeles del entorno.



El método consiste en analizar una imagen en escala de grises y aplicar un valor de referencia denominado umbral. A partir de este umbral, se genera una nueva imagen binaria, en la que los píxeles correspondientes al objeto se codifican con el valor '1', mientras que los del fondo se asignan como '0'. Esto permite una separación clara entre regiones, facilitando procesos posteriores como la detección de bordes,



Matemáticamente, este proceso se puede expresar de la siguiente forma:

$$g(x, y) = \begin{cases} 1 & f(x, y) > T \\ 0 & f(x, y) \leq T \end{cases}$$

Para que esta técnica funcione de manera óptima, es necesario que la escena tenga un fondo relativamente uniforme y que los objetos presentados tengan características visuales.  $f(x,y)$  es la función que retorna el nivel de gris del píxel  $(x,y)$ ,  $g(x,y)$  será la función de la imagen binarizada y  $T$  es el umbral. En el caso de que los objetos sean oscuros respecto del fondo, la asignación sería a la inversa:

$$g(x, y) = \begin{cases} 1 & f(x, y) < T \\ 0 & f(x, y) \geq T \end{cases}$$

El problema es encontrar el umbral; operación nada sencilla ya que las imágenes están contaminadas con el ruido. Para acotar el estudio, sólo se centrará en las técnicas globales.

## **Modelos de colores de detección**

Los espacios de color son representaciones matemáticas que permiten describir los colores de una imagen mediante vectores en un sistema de coordenadas. Su uso es fundamental en el procesamiento digital de imágenes, ya que permite analizar y manipular las propiedades cromáticas de los objetos en diferentes aplicaciones como la visión artificial, la clasificación de frutas o la inspección de calidad. Generalmente, un espacio de color se define a partir de una base de tres componentes, cuya combinación genera todos los colores posibles dentro del sistema.

## **Modelo de color RGB**


El modelo **RGB** (Red, Green, Blue) es uno de los más utilizados en imágenes digitales. Cada color se representa como una combinación aditiva de tres componentes primarios: rojo, verde y azul. Este modelo se basa en un sistema de coordenadas



cartesianas tridimensional, donde cada componente toma un valor entre 0 y 255 (en formato de 8 bits), generando un total de  $256^3 = 16\,777\,216$  combinaciones posibles.

Por ejemplo:

- Rojo puro: (255, 0, 0)
- Verde puro: (0, 255, 0)
- Azul puro: (0, 0, 255)



### Modelo de color HSV

El modelo **HSV** (Hue, Saturation, Value) está diseñado para representar los colores de una forma más próxima a cómo los percibe el ojo humano.

- **Tono (Hue)** define el tipo de color (por ejemplo, rojo, amarillo o azul) y se mide en grados ( $0^\circ$ – $360^\circ$ ).
- **Saturación (S)** mide la pureza del color, es decir, cuán "intenso" o "apagado" se percibe (de 0 a 1).



- **Valor (V)** representa el brillo del color, donde 0 es negro y 1 es el color más claro posible.

Fórmula

$$H = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{1/2}} \right\}$$

$$S = 1 - \frac{3}{R+G+B}$$

$$V = \max(R, G, B)$$

Este modelo resulta útil para la segmentación de imágenes, ya que permite separar la información de color (tono) de la iluminación (valor), lo cual facilita tareas como la detección de objetos bajo condiciones de luz variables.

## Integración con el sistema mecatrónico

### DESCRIPCIÓN

En esta etapa se llevó a cabo la **integración del sistema de visión artificial con el sistema mecatrónico**, con el propósito de automatizar la **separación de las naranjas** según su estado de madurez. Esta integración permitió que las decisiones tomadas por el algoritmo de clasificación se tradujeran en acciones físicas, coordinando la **banda transportadora** y los **servomotores** para dirigir los frutos hacia sus respectivas áreas de clasificación.

El proceso asegura que el prototipo funcione de manera completa y autónoma, conectando la adquisición de imágenes, el procesamiento digital y la clasificación con la ejecución mecánica, garantizando así una **operación eficiente y sincronizada** de todo el sistema.



## Lista de materiales

- **2 servomotores Mg996r**
- 1 PROTOBOARD
- 1 PLACA DE DESARROLLO ARDUINO UNO
- CABLE USB
- 10 CABLES JUMPERS
- VIDEOCAM
- COMPUTADORA

Se realizaron pruebas de sincronización y calibración para asegurar que el tiempo de reacción de los servomotores coincidiera con el desplazamiento de las frutas en la cinta transportadora. Esta integración permitió validar que el sistema completo software y hardware trabaja de manera coordinada, logrando una **clasificación y separación automática confiable**.

## Procedimiento

El procedimiento comenzó con la interconexión del software desarrollado en Python y OpenCV con los componentes físicos del sistema. El procedimiento inició estableciendo la comunicación integral entre el software desarrollado en Python apoyado en la librería OpenCV para el procesamiento de imágenes y los componentes físicos que conforman el sistema de clasificación. Primero se verificó la correcta conexión de la webcam al entorno de trabajo, asegurando que el flujo de video en tiempo real se reconociera sin interrupciones. Paralelamente, se realizó la configuración inicial de la banda transportadora, ajustando su velocidad para garantizar un desplazamiento uniforme de las naranjas. Para este paso, nos enfocamos en armar y ajustar la banda, comprobando la estabilidad de su estructura, la alineación de los rodillos y la tensión adecuada del mecanismo para asegurar un movimiento fluido y constante. Este control era



fundamental, ya que permitía que cada fruto pasara por el campo de visión de la cámara de manera individual y bajo condiciones constantes de iluminación.



En el segundo procedimiento nos enfocamos en la construcción de la base principal del sistema y del compartimiento destinado a la separación de las naranjas. Para ello, se reutilizaron placas de acero inoxidable previamente recuperadas, las cuales fueron cortadas, limpiadas y acondicionadas para garantizar su resistencia y estabilidad estructural. Se diseñó la base con dimensiones adecuadas para soportar tanto la banda transportadora como los mecanismos de selección, asegurando una distribución uniforme del peso.

Posteriormente, se fabricó el compartimiento de separación, considerando el espacio necesario para la caída controlada de las naranjas dependiendo de su clasificación. Este compartimiento fue ensamblado cuidadosamente a la base mediante uniones firmes y alineaciones precisas, buscando evitar vibraciones o desplazamientos que pudieran afectar el desempeño del sistema. El uso de acero inoxidable reciclado no solo proporcionó durabilidad y rigidez, sino que también contribuyó a un enfoque más sostenible y económico dentro del desarrollo del prototipo.



Posteriormente, iniciamos con la integración del sistema electrónico, una fase crucial para garantizar la coordinación entre los componentes mecánicos y el procesamiento computacional. Comenzamos estableciendo la comunicación entre los servomotores, la placa Arduino y la fuente de alimentación de 5V. Para ello, se verificó la conectividad de cada elemento, asegurando que los servos recibieran tanto la señal de control como el voltaje adecuado para su funcionamiento sin sobrecargas.

Se procedió a organizar el cableado, identificando cada línea de señal, corriente y tierra para evitar interferencias o conexiones erróneas. La placa de alimentación de 5V se configuró como el suministro principal de energía para los servomotores, ya que estos requerían una corriente estable y separada del Arduino para prevenir fluctuaciones o reinicios inesperados. A continuación, se conectaron los pines de control del Arduino a cada servo siguiendo la numeración definida en el código, verificando que las señales PWM se detectaran correctamente.

Para asegurarnos de que el voltaje suministrado a los servomotores fuera el adecuado, realizamos una serie de pruebas preliminares utilizando un código fuente básico que permitía activar y mover los servos en rangos mínimos. Esta verificación inicial nos permitió observar su comportamiento, identificar posibles caídas de tensión y confirmar que el consumo de corriente no superara la capacidad de la fuente de 5V. Paralelamente, se revisó cuidadosamente el diagrama eléctrico del sistema, previamente mostrado en la figura (PON EL NUMERO DEL DIAGRAMA ELECTRICO), contrastando las especificaciones de los componentes con el diseño planteado para validar que las conexiones, valores de voltaje y distribución de energía fueran correctos antes de proceder con la integración completa.

Estas pruebas resultaron fundamentales para evitar fallos posteriores en el funcionamiento del sistema, ya que garantizaban que tanto la placa Arduino como los servomotores operaran bajo condiciones eléctricas seguras y estables. Con esta información confirmada, se continuó con la implementación de la electrónica sabiendo



que la alimentación era la apropiada y que no existirían riesgos de sobrecarga o pérdida de señal durante el uso continuo del prototipo.


Luego se procedió a implementar la comunicación directa entre el algoritmo de clasificación y los servomotores MG996R de 15 kg, los cuales, acoplados a una pieza mecánica diseñada específicamente para este proyecto, accionan el mecanismo de separación de las naranjas. Cada servo fue configurado para responder únicamente cuando el sistema de visión artificial determinara el estado de madurez del fruto. De esta manera, al detectar una naranja verde, madura o con manchas café, el algoritmo enviaba una señal precisa al servomotor correspondiente, que ejecutaba el movimiento necesario para desviar el fruto hacia la sección asignada dentro del compartimiento de clasificación.

Una vez que el sistema mecánico estuvo calibrado y funcional, se integró la lógica completa de detección de color dentro del algoritmo en Python. Para lograrlo, se definieron rangos cromáticos específicos que permitieran distinguir entre los tonos verde, naranja y las irregularidades asociadas a manchas café. Estos parámetros fueron ajustados y validados mediante pruebas iterativas, comparando los resultados y afinando los valores hasta obtener una detección estable y precisa en diversas condiciones de iluminación.

Con la banda transportadora operando de forma continua, la cámara comenzó a capturar imágenes cuadro por cuadro. Cada fotograma era analizado en tiempo real por el software, que evaluaba los valores de color y determinaba la categoría correspondiente para cada fruta que pasaba por el campo de visión. Esta clasificación automática se enviaba inmediatamente al Arduino a través de comunicación serial, permitiendo que la placa interpretara las decisiones del sistema de visión y activara los servomotores de acuerdo con la ruta asignada.

Gracias a esta integración, el flujo completo captura visual, análisis computacional y acción mecánica operó de manera sincronizada, logrando una clasificación eficiente, precisa y completamente automatizada en tiempo real.





## Evaluación del sistema

### DESCRIPCIÓN

En esta etapa se realizó la **evaluación del sistema completo de visión artificial**, con el objetivo de medir su rendimiento general y verificar su comportamiento en condiciones reales de operación. Se analizaron parámetros clave como la **precisión en la clasificación del estado de madurez**, la **velocidad de procesamiento por fruta**, la **robustez frente a variaciones de iluminación y fondo**, y la **tasa de error general** del sistema.



La evaluación permitió determinar la eficacia del sistema integrado —compuesto por la **webcam**, la **banda transportadora**, el **mecanismo de separación con servomotores** y el software desarrollado en **Python con OpenCV**— asegurando que cada componente funcionara de manera coordinada y eficiente. Esta fase validó el cumplimiento de los objetivos planteados y demostró que el prototipo es funcional y confiable.

## Procedimiento

El proceso de evaluación comenzó con la **ejecución del sistema en condiciones controladas**, procesando múltiples imágenes de naranjas en diferentes estados de madurez. Se registró un **tiempo promedio de procesamiento por fruta de 1.8 segundos**, desde la captura hasta la clasificación final.

Para medir la precisión, se compararon las **etiquetas de clasificación obtenidas por el modelo KNN** con las etiquetas reales de la base de datos. Los resultados arrojaron una **precisión del 93 %**, demostrando la eficacia del sistema en la identificación del estado de madurez.

Además, se realizaron pruebas bajo **variaciones de iluminación y color de fondo**, evaluando la **robustez** del sistema. Los resultados indicaron que el prototipo mantiene un desempeño confiable incluso ante ligeros cambios en las condiciones del entorno, confirmando su efectividad como **sistema automatizado de clasificación de frutas** basado en visión artificial.

## Documentación de resultados, análisis de errores y mejoras propuestas.

En esta etapa se realizó la **documentación completa de los resultados obtenidos** durante el desarrollo, implementación y pruebas del sistema de visión artificial para clasificación de naranjas. Se elaboraron informes técnicos y visuales que recopilan los hallazgos, el desempeño del algoritmo, la precisión del modelo, y la efectividad del sistema mecatrónico.



Además, se analizó cada error detectado durante las pruebas, identificando sus posibles causas y su impacto en el rendimiento general. Con base en este análisis, se propusieron **mejoras y ajustes** para futuras versiones del prototipo, con el objetivo de optimizar la precisión, la velocidad de procesamiento y la robustez frente a distintas condiciones de operación.

El procedimiento incluyó la **compilación de todos los datos obtenidos** en las etapas anteriores, incluyendo métricas de precisión (93 %), tiempo promedio de procesamiento (1.8 segundos por fruta), y resultados de pruebas bajo distintas condiciones de iluminación y fondo.

Se documentaron visualmente los errores de clasificación y segmentación mediante imágenes y gráficos, señalando las posibles causas, como cambios bruscos de iluminación o variaciones en la forma de los frutos. Finalmente, se elaboraron **recomendaciones de mejora**, que incluyen ajustes en la calibración del sistema mecatrónico, optimización de los parámetros del algoritmo KNN, y ampliación de la base de datos para aumentar la robustez del modelo.

## **Preparación de presentación, pruebas finales y cierre del proyecto**

En la fase final se llevó a cabo la **preparación de los materiales de presentación** del proyecto, incluyendo informes, videos, exposiciones y demostraciones funcionales del prototipo. Esta etapa tuvo como objetivo mostrar de manera clara y profesional los resultados obtenidos, así como el funcionamiento completo del sistema de visión artificial y su integración con la mecatrónica.

También se realizaron las **pruebas finales de validación** para asegurar que el prototipo funcionara de manera consistente y confiable antes de la entrega oficial del proyecto.



Se prepararon **videos demostrativos y presentaciones** que ilustran la captura de imágenes, la segmentación de las naranjas, la clasificación por KNN y la separación automática mediante servomotores.

Se realizaron **pruebas finales con la banda transportadora**, evaluando nuevamente la precisión del 93 % y el tiempo promedio de procesamiento de 1.8 segundos por fruta, verificando que el sistema respondiera correctamente ante diferentes condiciones de luz y fondos.

Finalmente, se compiló toda la documentación técnica y visual, asegurando que el informe estuviera completo y que el prototipo estuviera listo para **presentación y entrega oficial**, concluyendo así el desarrollo del proyecto.

## **Descripción de los resultados del trabajo**

El proyecto se enfocó en el diseño e implementación de un sistema automatizado de clasificación de naranjas por estado de madurez y calidad empleando técnicas de visión artificial.

Se construyó un prototipo funcional que integra:

- Sistema de adquisición de imágenes: cámara de alta resolución que captura en tiempo real.
- Algoritmo de procesamiento de imagen: desarrollado en Python y basado en OpenCV.
- Clasificador automático: que determina si la naranja está verde, madura o en mal estado.
- Sistema mecatrónico de separación física: banda transportadora y actuador neumático controlado en tiempo real.

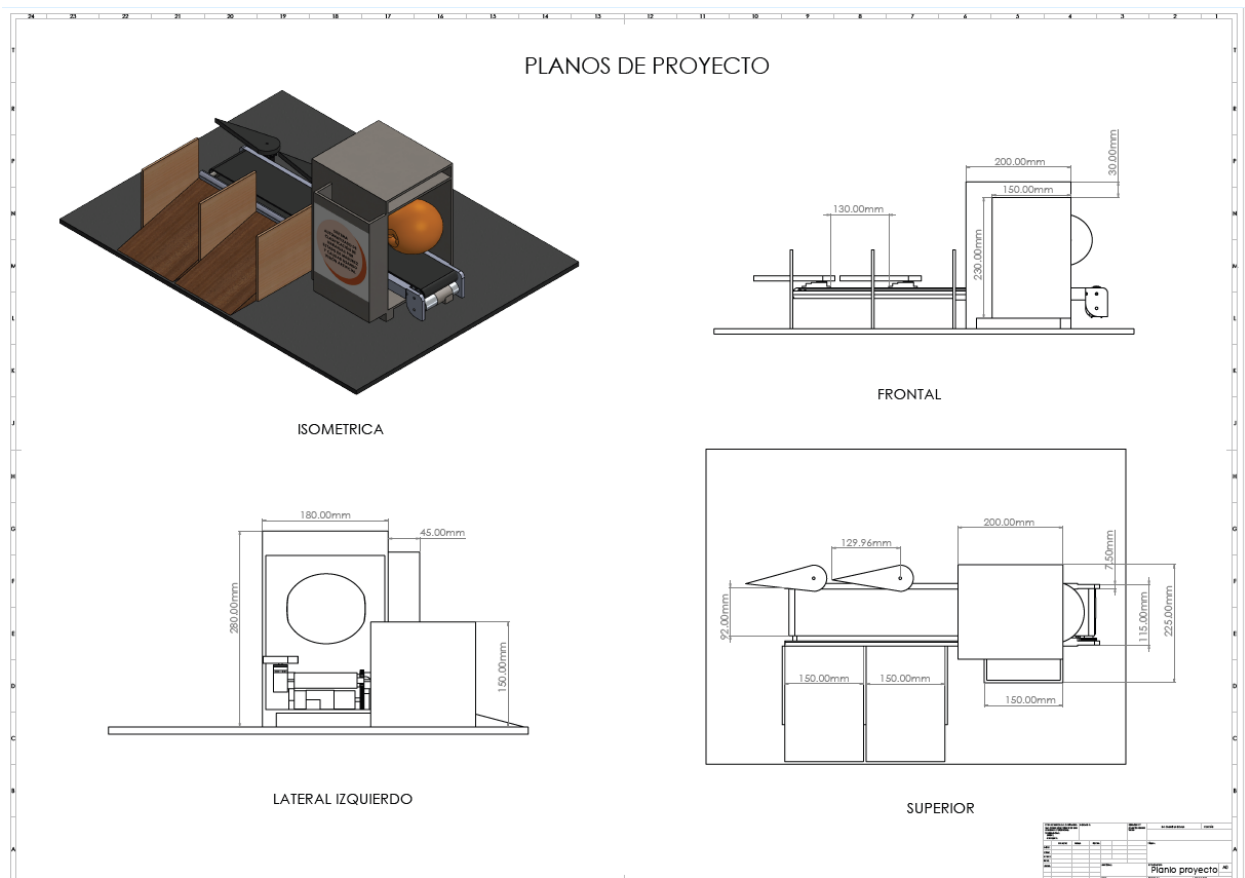
Se realizaron pruebas experimentales con 300 naranjas, registrando datos de precisión de clasificación, tiempo de procesamiento y respuesta del sistema.

## **4.2 RESULTADOS**



Planos y Diseño del Sistema

Se generaron planos en SolidWorks de la banda transportadora, ubicación de la cámara y del actuador mecánico conformado por 2 servomotores y una pieza de filamento en forma de flecha que ayuda a direccionar las naranjas por el cesto de separación, asegurando la correcta disposición de los componentes para la clasificación en línea.

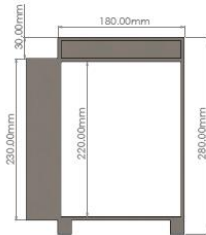




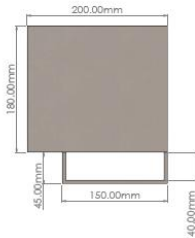
### CAJA DE REVISIÓN




ISOMETRICA



FRONTAL



SUPERIOR



LATERAL


Hoja		Proyecto		Fecha	
Nº	Descripción	Nº	Descripción	Nº	Descripción
1	Hoja de título	1	Hoja de título	1	Hoja de título
2	Hoja de especificaciones	2	Hoja de especificaciones	2	Hoja de especificaciones
3	Hoja de detalles	3	Hoja de detalles	3	Hoja de detalles
4	Hoja de montaje	4	Hoja de montaje	4	Hoja de montaje
5	Hoja de mantenimiento	5	Hoja de mantenimiento	5	Hoja de mantenimiento

Plano proyecto


[illegible]




ENGRANE BANDA




ISOMETRICA



FRONTAL




LATERAL IZQUIERDO




LATERAL DERECHO

PROYECTO	FECHA	PROYECTISTA	REVISOR
1.0	15/05/2023	ALVARO	ALVARO
Pág. 1 de 1			


Cilindro Banda




ISOMETRICA



FRONTAL



LATERAL DERECHO




LATERAL IZQUIERDO

PROYECTO	FECHA	PROYECTISTA	REVISOR
1.0	15/05/2023	ALVARO	ALVARO
Pág. 2 de 1			






Isométrica




Lateral izquierda





Lateral derecha



superior



## **Fuentes de información**

- [1] C. S. Gonzales, «Desarrollo de un algoritmo de visión artificial para artificial para detectar la enfermedad Huanglongbing (HLB) en la planta citrus limón del Fundo Amada,» Universidad Privada del Norte Perú, pp. 2-10, 2023.
- [2] D. E. Figueroa, «Sistema de Visión artificial para la identificación del estado de madurez de fruta (granadilla),» Redes de Ingeniería , vol. 4, nº 144, p. 84, 2016.
- [3] A. E. G. Chanco, «Diseño de un sistema por visión artificial para determinar la calidad de mandarinas,» Lima, 2020.

## **ANEXOS**

Anexos (carta de autorización por parte de la empresa u organización para la titulación y otros si son necesarios).

Registros de Productos (patentes, derechos de autor, compraventa del proyecto, etc.).