

UNIVERSIDAD TÉCNICO FEDERICO SANTA
MARÍA

Ingeniería Civil Telemática

Automatización del Proceso de Inspección y Clasificación de Pallets

Tesis presentada por:

Leonardo Castillo Titichoca

Dirigida por

Marcos Zuñiga



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

Fecha de presentación: January 22, 2024

Abstract

This research focuses on the automation of the inspection and classification process of pallets. The proposed system employs a machine equipped with cameras to inspect pallets and utilizes computer vision along with various algorithms to classify them. The classification involves identifying the pallet type and determining the extent of damage to individual boards, thereby assessing whether the pallet is suitable for continued use, requires repairs, or is deemed fit for disposal. The inspection is conducted on a unitary basis as pallets traverse a conveyor belt, where cameras capture images to initiate the evaluation process. This automated approach enhances efficiency and accuracy in the pallet management workflow, contributing to improved decision-making regarding their usability and maintenance.

Resumen

Esta investigación se centra en la automatización del proceso de inspección y clasificación de pallets. El sistema propuesto emplea una máquina equipada con cámaras para inspeccionar los pallets y utiliza visión por computadora junto con diversos algoritmos para clasificarlos. La clasificación implica identificar el tipo de pallet y determinar el grado de daño en las tablas individuales, evaluando así si el pallet es apto para un uso continuo, si requiere reparaciones o si se considera adecuado para desecharlo. La inspección se realiza de manera unitaria a medida que los pallets avanzan por una cinta transportadora, donde las cámaras capturan imágenes para iniciar el proceso de evaluación. Este enfoque automatizado mejora la eficiencia y precisión en el flujo de trabajo de gestión de pallets, contribuyendo a una toma de decisiones mejorada en cuanto a su utilidad y mantenimiento.

Agradecimientos

Querida familia,

En el umbral de culminar este viaje, no puedo más que empezar agradeciendo a quienes siempre han sido mi faro, mi sostén y mi inspiración: mi amada familia. A mis queridos padres y a mis entrañables hermanos, ustedes han sido mi red de seguridad, mi refugio en los días difíciles y mi celebración en los triunfos. Su apoyo incondicional ha sido el cimiento sobre el cual he construido cada paso de este camino, y no puedo expresar con palabras lo agradecido que estoy por tenerlos a mi lado.

A cada persona que ha dejado su huella en esta travesía, quiero dedicar un agradecimiento sincero y lleno de emoción. Cada conversación, cada idea compartida, ha sido como una luz que ilumina este recorrido. Es en esos intercambios donde encontré esos pequeños granitos de sabiduría que han alimentado la llama de este proyecto. Gracias a cada mente generosa que me brindó su tiempo y conocimiento, aportando ese ingrediente especial que faltaba para convertir este sueño en realidad.

En este viaje, aprendí que lo grande se construye en la suma de pequeños gestos, en la apertura a cada conversación y en la receptividad a cada idea que florece. Este logro no es solo mío, sino de todos aquellos que creyeron y contribuyeron con su valiosa perspectiva.

A todos ustedes que compartieron su tiempo, su experiencia y su corazón en esta travesía, mi más profundo agradecimiento. Este proyecto es el testimonio de la colaboración, del tejido de conexiones humanas que hacen posible lo extraordinario.

Con gratitud y emoción...

Leonardo Castillo.

Contents

1. Introducción	5
1.1 Contexto y Motivación	5
1.2 Inspección y Clasificación de Pallets en la Cadena de Suministro	6
1.2.1 Diferencias en los Pallets Utilizados por Coca-Cola	6
1.2.2 Codificación de Colores y Capacidades de Carga	7
1.3 Problema a resolver	8
1.4 Acercamiento a la solución	9
1.5 Hipótesis	10
1.6 Objetivos	11
1.6.1 Sistema de Inspección y Captura de Imágenes	11
1.6.2 Definición de Vistas y Entradas	11
1.6.3 Clasificación de Pallets	11
Filtración por Tamaño Andina	11
Filtración por Color Específico	12
Identificación de Marcas "CCU" y "CMF"	12
1.6.4 Detección de Fallas	12
1.6.5 Identificación de Pallets Andina	12
1.7 Estructura de la memoria	13
2. Estado del arte.	14
2.1 Agenda del Estado del arte	14
2.2 Soluciones existentes	15
2.2.1 Análisis del sistema de inspección y clasificación de SICK	15
2.2.2 Análisis del Sistema de Inspección de Pallets de Sidel	16
Ventajas	16
Desventajas	17

2.2.3	Análisis del Sistema Innocheck PKS DR	17
2.3	Marco teórico	18
2.3.1	Introducción a la Automatización Industrial	18
2.3.2	Soluciones Relevantes	19
2.4	Discusión	25
3.	Desarrollo de la solución	27
3.1	Arquitectura del Sistema	27
3.1.1	Arquitectura IoT	27
3.1.2	Descripción de Componentes	29
3.1.3	Diagrama de contexto	32
3.1.4	Descripción de módulos	36
	Módulo 1: Diseño del Sistema de Obtención de Datos	36
	Propósito	36
	Alcance	36
	Dependencias	37
	Supuestos	37
	Restricciones	37
	Estructura General	37
3.1.5	Vistas y Áreas de Interés para la Inspección de Pallets:	38
	Vista Superior	38
	Vista Lateral 1	38
	Vista Lateral 2	39
	Vista Inferior	39
3.1.6	Módulo 2: Preprocesamiento de la imagen	40
	Propósito	40
	Alcance	40
	Dependencias	41
	Supuestos	41
	Restricciones	41
	Estructura General	42
	Funcionamiento	42
3.1.7	Módulo 3: Clasificación y Segmentación	44

Propósito	44
Alcance	44
Dependencias	45
Supuestos	45
Restricciones	45
Estructura General	46
3.1.8 Módulo 3: Clasificación	46
3.1.9 Módulo 3: Segmentación	50
4. Resultados	55
4.1 Análisis de datos	55
4.2 Interpretación de resultados	58
5. Conclusiones	59
5.1 Resumen de hallazgos	59
5.2 Contribuciones	60
5.3 Limitaciones	61
5.4 Futuras Investigaciones	61
References	64

Chapter 1

Introducción

1.1 Contexto y Motivación

En la actualidad, la automatización se ha vuelto esencial para optimizar la eficiencia y la calidad en la industria. Aunque se han logrado avances tecnológicos significativos en diversos aspectos de la producción, la gestión de pallets en la cadena de suministro sigue siendo un componente crítico subestimado en términos de su potencial de automatización.

Empresas líderes como Coca-Cola enfrentan desafíos en la inspección y clasificación manual de pallets, a pesar de contar con procesos altamente automatizados en otras áreas de producción. Esta carencia ha dado lugar a problemas que afectan tanto la eficiencia de la producción como la precisión en la clasificación de productos.

Las deficiencias en la inspección y clasificación de pallets pueden generar impactos significativos en la producción y la calidad del producto final. Inconsistencias en la disposición de productos en los pallets pueden causar retrasos en la cadena de suministro, aumentar costos de transporte y afectar la satisfacción del cliente. La intervención humana en este proceso también conlleva el riesgo de errores, comprometiendo la eficacia general de la operación.

Esta investigación se centra en diseñar e implementar un sistema automatizado de inspección y clasificación de pallets. El objetivo es abordar los desafíos mencionados, proporcionando a empresas como Coca-Cola Andina una solución efectiva para mejorar la eficiencia de operaciones y garantizar una clasificación precisa de productos. La aplicación de tecnologías avanzadas, como visión por computadora e inteligencia artificial, busca eliminar la intervención humana y optimizar la gestión de pallets.

A lo largo de este trabajo, se explorarán metodologías, desarrollos técnicos e implementaciones prácticas para lograr este objetivo. Además, se analizarán los beneficios potenciales que esta solución puede aportar a la industria en términos de eficiencia, calidad y reducción de costos operativos.

En resumen, este proyecto representa un avance significativo en la modernización de los procesos de gestión de pallets en la industria, ofreciendo soluciones innovadoras para mejorar la producción y la calidad del producto final. La colaboración con empresas líderes como Coca-Cola subraya la relevancia y aplicabilidad de esta investigación en el contexto industrial actual.

1.2 Inspección y Clasificación de Pallets en la Cadena de Suministro

La inspección y clasificación de pallets son procesos fundamentales para la gestión eficiente de la cadena de suministro y la logística empresarial. Estas plataformas planas, también conocidas como pallets o tarimas, desempeñan un papel crucial en el transporte y almacenamiento de mercancías, y garantizar su calidad es esencial para evitar problemas en la cadena de suministro.

1.2.1 Diferencias en los Pallets Utilizados por Coca-Cola

Cada empresa tiene requisitos específicos respecto a los pallets que emplea. Coca-Cola, como líder en la industria de bebidas, utiliza una gama diversificada de pallets para adaptarse a sus distintos productos y necesidades logísticas. Esto incluye pallets de madera, plástico, entre otros, cada uno con características particulares en capacidad de carga, durabilidad y costos.

Las diferencias entre los pallets de Coca-Cola y otras empresas pueden incluir:

- **Materiales y Construcción:** Coca-Cola utiliza pallets de madera o plástico según las características y demandas logísticas de sus productos, variando en resistencia y durabilidad.
- **Dimensiones:** Los pallets de Coca-Cola tienen dimensiones específicas para acomodar sus productos y cumplir con estándares logísticos. Esto incluye el uso de

estanterías elevadas, adaptadas a ciertos tipos de pallets.

- **Almacenamiento en Estanterías Elevadas:** Coca-Cola busca mejorar la eficiencia en el almacenamiento vertical mediante sistemas que permiten apilar pallets de manera segura y accesible, requiriendo pallets con dimensiones específicas.

1.2.2 Codificación de Colores y Capacidades de Carga

Coca-Cola emplea pallets de colores específicos, como azul y rojo, para distinguirlos de los pallets estándar. Estos pallets coloreados se destinan a fines específicos, como promociones o exhibiciones, y no están diseñados para soportar las mismas capacidades de carga ni para su uso en estanterías elevadas.

Además, aunque algunos pallets pueden cumplir con dimensiones y colores estándar, aquellos marcados con etiquetas de otros fabricantes, como "CMF" o "CCU", no son aptos para el proceso logístico de Coca-Cola. Identificar y filtrar estos pallets garantiza un flujo logístico eficiente y seguro, manteniendo la integridad de los productos durante el transporte y cumpliendo con estándares de calidad y seguridad.

En conclusión, la adecuada selección, inspección y clasificación de pallets en la cadena de suministro de Coca-Cola son esenciales para asegurar una entrega eficiente y segura de productos a los consumidores finales. Este proceso ilustra cómo estos procedimientos pueden variar significativamente según las necesidades y especificaciones de la empresa y los productos transportados.



Figure 1.1: Almacenamiento en estanterías elevadas.

1.3 Problema a resolver

Uno de los desafíos más apremiantes en la gestión de pallets dentro de la industria es la variabilidad en los tipos y condiciones de estos componentes esenciales para la cadena de suministro. La diversidad de pallets utilizados en distintas etapas de la producción, junto con el desgaste gradual que experimentan, plantea un problema crítico para la eficiencia operativa y la rentabilidad de las empresas.

Un análisis minucioso del problema revela que un porcentaje significativo de los pallets en circulación no son adecuados para los procesos en los que se utilizan. Estos pallets defectuosos pueden tener tablas dañadas, tacos desplazados o presentar dimensiones que no cumplen con los estándares necesarios para una manipulación segura y eficiente. La consecuencia directa de esta situación es una disminución de la calidad en la gestión de materiales y, en última instancia, la pérdida de eficiencia en la cadena de producción.

El deterioro y la acumulación de pallets no funcionales en la industria también tienen un impacto ambiental significativo debido a la necesidad de producción constante de nuevos pallets para reemplazar los dañados o inadecuados. Esto resulta en un uso ineficiente de recursos y un aumento en los costos de producción, además de contribuir al

desperdicio de materiales.

Por lo tanto, resulta imperativo implementar un sistema capaz de evaluar de forma ágil y precisa si un pallet satisface los criterios fundamentales para su idoneidad. Estos criterios pueden abarcar dimensiones específicas, requisitos cromáticos particulares, la ausencia de marcas específicas en el pallet, así como la integridad de sus tablas y la correcta disposición de los tacos.

El desarrollo de un sistema de inspección y clasificación automatizado que evalúe estos parámetros permitirá identificar los pallets no funcionales o potencialmente peligrosos antes de que ingresen a la cadena de suministro, evitando así retrasos, costos adicionales y riesgos para la seguridad.

En el contexto de la creación de un modelo, se ha identificado un problema crítico que plantea desafíos significativos para la inspección y clasificación efectiva de estos componentes esenciales. El problema en cuestión radica en la carencia de un dataset completo que contenga pallets con fallas y que también tenga muestras de cada uno de los tipos de pallets que podrían llegar a la inspección. Esta falta de datos representativos de defectos y deterioros en pallets obstaculiza el desarrollo de sistemas de inspección y clasificación confiables.

La naturaleza diversa de las fallas en pallets, que pueden incluir grietas, deformaciones, roturas, desgaste y otros tipos de deterioro, dificulta la generalización y la creación de algoritmos precisos de detección de fallas. Sin un conjunto de datos exhaustivo que capture esta diversidad de fallas, los sistemas existentes son propensos a errores y carecen de la robustez necesaria para cumplir con los estándares de calidad y seguridad requeridos en la gestión de la cadena de suministro.

1.4 Acercamiento a la solución

La solución propuesta para la automatización del proceso de inspección y clasificación de pallets se fundamenta en la implementación de un sistema basado en máquinas. Este sistema emplea cámaras especializadas para capturar imágenes detalladas de los pallets en cuestión. A través de algoritmos avanzados de visión por computadora, estas imágenes son analizadas y procesadas para llevar a cabo una clasificación eficiente y precisa.

El proceso de clasificación se lleva a cabo mediante la evaluación de diversas

métricas clave, que incluyen el color, el tamaño y la información escrita en los tacos de los pallets. La utilización de algoritmos específicos permite discernir entre distintas variaciones en estas características, asegurando una clasificación detallada y adaptada a las necesidades específicas del contexto.

En una etapa final del proceso, la solución se enfoca en la evaluación del estado general del pallet, considerando aspectos como la integridad de las tablas y posibles daños. Esta fase de inspección adicional garantiza que los pallets sean clasificados no solamente en función de sus características físicas, sino también en relación con su condición operativa y su idoneidad para su uso futuro.

Como resultado de este proceso de inspección y clasificación, se genera una etiqueta correspondiente a cada pallet, indicando su categoría específica. Estas etiquetas permiten una gestión eficiente y una disposición adecuada de los pallets, asignándolos a los conjuntos correspondientes según sus características y estado.

En resumen, la combinación de cámaras especializadas, algoritmos de visión por computadora y criterios de clasificación multidimensionales conforma una solución integral para la automatización del proceso de inspección y clasificación de pallets, mejorando significativamente la eficiencia y precisión de este proceso crucial en entornos logísticos y de producción.

1.5 Hipótesis

Con el rápido avance de las tecnologías de visión por computadora, el desarrollo de algoritmos de aprendizaje profundo y el acceso a hardware cada vez más potente, es plausible afirmar que es posible alcanzar los tiempos de inspección y clasificación requeridos en el proceso de análisis y clasificación de pallets, tal que se logre separar con alta precisión pallets defectuosos o de otras compañías en el tiempo adecuado. La combinación de estas tecnologías emergentes ofrece una plataforma sólida para la creación de un sistema automatizado altamente eficiente. Se postula que mediante la optimización continua de algoritmos y la adaptación de modelos de inteligencia artificial a situaciones específicas de inspección, el sistema será capaz de cumplir con los estándares de velocidad establecidos por las demandas logísticas actuales. Esta hipótesis se basa en la premisa de que la convergencia de avances tecnológicos en el ámbito de la visión por computadora permitirá

superar las limitaciones temporales, haciendo viable la implementación de un sistema de inspección y clasificación que satisfaga las exigencias temporales del proceso logístico de manejo de pallets.

1.6 Objetivos

El objetivo principal de esta memoria de titulación es diseñar y desarrollar tanto un sistema de inspección como un sistema de clasificación para pallets mediante métodos de visión artificial. Estos sistemas se dividen en varias etapas clave que se explican a continuación.

1.6.1 Sistema de Inspección y Captura de Imágenes

Seleccionar y establecer un sistema de inspección adecuado que permita la captura de imágenes de pallets con el propósito de identificar Regiones de Interés (ROI) en estas imágenes.

1.6.2 Definición de Vistas y Entradas

Definir de manera precisa las distintas vistas y características que serán consideradas en el proceso de clasificación de los pallets, estableciendo las entradas necesarias para el sistema de clasificación.

1.6.3 Clasificación de Pallets

Desarrollar un clasificador de pallets que se basará en los siguientes subobjetivos:

Filtración por Tamaño Andina

Implementar un módulo de medición de tamaño que permita identificar y separar los pallets que no cumplen con las dimensiones estándar del tipo "Andina". Los pallets que no se ajusten a estas dimensiones serán excluidos del proceso de clasificación siendo etiquetados como "No Andina".

Filtración por Color Específico

Establecer un sistema de clasificación por color que permita separar los pallets que cumplen con las dimensiones estándar del tipo "Andina", pero que presentan colores diferentes. Los pallets que no correspondan al color especificado serán excluidos del conjunto de pallets seleccionados.

Identificación de Marcas "CCU" y "CMF"

Desarrollar un sistema de reconocimiento de texto que permita identificar pallets que presenten las marcas "CCU" y "CMF". Estas marcas son indicativas de un tipo específico de pallet dentro de la categoría "andina". Los pallets que contengan estas marcas serán descartados.

1.6.4 Detección de Fallas

Una vez que se ha filtrado el conjunto de pallets de acuerdo con los criterios anteriores, se procederá a realizar un análisis de detección de fallas. El objetivo principal de esta etapa es identificar posibles defectos o problemas en los pallets restantes, asegurando que sólo los pallets "Andina" que se encuentren en buenas condiciones sean seleccionados para su posterior uso.

La detección de fallas es de vital importancia, ya que garantiza que los pallets utilizados en la cadena logística cumplan con los estándares de calidad y seguridad necesarios. Los pallets que no superen este proceso serán descartados, evitando así posibles problemas en el transporte y almacenamiento de mercancías.

1.6.5 Identificación de Pallets Andina

Al concluir el proceso de filtración y detección de fallas, se obtendrá un conjunto de pallets que cumplen con los estándares de tamaño, color y marcas especificadas, y que están libres de defectos. Estos pallets conformarán la selección final de pallets "Andina".

1.7 Estructura de la memoria

1. Capítulo: Estado del Arte

En este capítulo, se realiza una exhaustiva revisión de proyectos previos orientados a la automatización de procesos industriales. Se analizan procesos industriales automatizados con el objetivo de comprender las técnicas utilizadas en este campo. Además, se examinan soluciones de inspección y clasificación de pallets implementadas para entender el panorama actual y las innovaciones tecnológicas aplicadas en la inspección y clasificación de pallets.

2. Capítulo: Desarrollo de la Solución

Este capítulo se centra en la propuesta de solución desarrollada para la automatización de la inspección y clasificación de pallets. Se describen detalladamente las técnicas empleadas en cada etapa del proceso, desde los componentes individuales de la máquina hasta el diseño global para organizar y clasificar eficientemente los distintos tipos de etiquetas asociadas a los pallets.

3. Capítulo: Resultados

Aquí se presentan los resultados obtenidos durante la implementación y pruebas del sistema. Se aborda específicamente el tiempo de ejecución de los diferentes módulos empleados en la clasificación de pallets, proporcionando datos cuantitativos que respaldan la eficacia y eficiencia de la solución propuesta.

4. Capítulo: Conclusiones

En este capítulo se resumen las conclusiones derivadas de los resultados obtenidos. Se analizan los logros alcanzados y se reflexiona sobre las implicaciones prácticas de la automatización en la inspección y clasificación de pallets. Además, se identifican áreas de mejora y se plantea el trabajo futuro necesario para llevar a cabo la automatización de manera integral.

Chapter 2

Estado del arte

2.1 Agenda del Estado del arte

1. Automatización en Inspección y Clasificación de Pallets

- Visión general de la automatización en el contexto de pallets.
- Avances tecnológicos y su aplicación en inspección y clasificación.
- Beneficios: mejora de calidad, aumento de velocidad de procesamiento, reducción de costos.

2. Introducción a la Automatización Industrial

- Importancia y aplicaciones de la automatización en la industria.
- Tecnologías avanzadas en automatización: sistemas inteligentes, maquinaria controlada por computadora, robots industriales.
- Objetivos: reducción de intervención humana, minimización de errores, aumento de eficiencia.

3. Soluciones Relevantes en Automatización

- Estudios y propuestas innovadoras en la automatización y control de calidad.
- Ejemplos específicos de aplicaciones en diferentes industrias: textiles, producción de botellas, inspección de tomates, etc.
- Modelos y técnicas aplicadas: Deep Learning, Machine Vision, etc.

4. Discusión

- Comparación con soluciones existentes.
- Innovaciones y diferencias clave de nuestra propuesta.
- Ventajas en adaptabilidad, eficiencia y fiabilidad.

2.2 Soluciones existentes

2.2.1 Análisis del sistema de inspección y clasificación de SICK

SICK(SICK Sensor Intelligence, 2024) una empresa prominente en el ámbito de sensores y automatización, ha contribuido significativamente a la evolución de la clasificación automatizada de pallets. Su enfoque utiliza redes neuronales, un componente del aprendizaje automático, para la identificación y clasificación de pallets. Este sistema se distingue por su uso de cámaras de alta resolución y sensores que capturan imágenes detalladas de los tacos de los pallets, las cuales son analizadas por una red neuronal diseñada para reconocer marcas específicas.

Ventajas y Desventajas A pesar de su innovación tecnológica, el sistema de SICK presenta tanto fortalezas como limitaciones:

Fortalezas:

- Alta precisión en la identificación de marcas en los tacos de pallets.
- Capacidad de adaptación a nuevas marcas o variaciones, aumentando la flexibilidad del sistema.
- Contribución a la eficiencia operativa gracias a su velocidad de respuesta.

Limitaciones:

- Dependencia de la calidad de las marcas en los tacos de los pallets: Si las marcas están deterioradas o no son claras, el sistema puede enfrentar dificultades en la clasificación.
- Necesidad de una cantidad significativa de datos para entrenar la red neuronal en nuevos tipos de pallets, lo cual puede limitar su efectividad en situaciones con datos limitados.

- Posibles limitaciones en la predicción de clases con poca información, afectando el rendimiento del sistema.

Etiquetas Asignadas SICK clasifica los pallets en varias categorías, reflejando la diversidad en entornos logísticos. Las categorías incluyen: NoType, EPAL, UIC, CHEP, LPR, MUNDO, IPP, y OTROS.

En conclusión, mientras que el sistema de SICK muestra una notable capacidad adaptativa y precisión, su dependencia de marcas de calidad en los tacos de pallets y la necesidad de extensos datos para el entrenamiento de nuevas categorías son aspectos que deben ser considerados al evaluar su aplicabilidad en diferentes contextos logísticos.

2.2.2 Análisis del Sistema de Inspección de Pallets de Sidel

El sistema de inspección de pallets desarrollado por Sidel (*Sistema de inspección de palés*, 2024) proporciona una evaluación automática integral de la integridad de las tablas de madera en ambos lados del pallet. Este sistema se caracteriza por su capacidad para examinar detalladamente cada tabla de madera durante el avance del pallet, lo que permite una detección eficiente de tablas rotas. Utiliza rodillos de pasador palpador metálico inactivo montados sobre elementos elásticos, asegurando un escaneo suave y preciso de cada superficie de madera.

La eficiencia de este sistema es notable, con una capacidad de inspección de hasta 180 pallets por hora. Esta velocidad no afecta la precisión, gracias a la tecnología de fotocélulas que reaccionan rápidamente al movimiento del rodillo y su elemento elástico al encontrar irregularidades en las tablas.

Una ventaja distintiva del sistema es su flexibilidad. Se adapta fácilmente a diferentes tamaños de pallets mediante la posición ajustable de los rodillos, tanto vertical como horizontalmente. Esta personalización facilita su uso en entornos de producción con diversas dimensiones de carga.

Ventajas

- Alta precisión en la detección de tablas defectuosas, gracias a su sistema físico de inspección.
- Capacidad de procesar un volumen significativo de pallets (hasta 180 por hora), lo

que es beneficioso en entornos de producción a gran escala.

- Flexibilidad para ajustarse a diferentes tamaños de pallets, lo que aumenta su versatilidad en distintos entornos de producción.

Desventajas

- La necesidad de reajuste manual para diferentes tipos de pallets. Aunque el sistema es ajustable, cualquier cambio en el tipo de pallet requiere un reajuste, lo que puede ser ineficiente en entornos con una variedad frecuente de tipos de pallets.
- La falta de uso de tecnologías como cámaras o sensores avanzados, lo que limita sus capacidades en comparación con sistemas que integran estas tecnologías.
- Posibles limitaciones en la adaptabilidad a condiciones de producción variables o a pallets con características no estándar.

En conclusión, el sistema de inspección de pallets de Sidel ofrece beneficios significativos en términos de precisión y capacidad de procesamiento. Sin embargo, sus limitaciones en flexibilidad y adaptabilidad tecnológica pueden ser factores restrictivos en ciertos entornos de producción.

2.2.3 Análisis del Sistema Innocheck PKS DR

El sistema Innocheck PKS DR (*Innocheck PKS DR Pallet Checker*, 2024) está diseñado para inspeccionar la estabilidad e integridad de pallets vacíos de madera, plástico o metal, asegurando así la integridad de los productos durante el transporte. Este sistema comprueba meticulosamente la geometría de los pallets y utiliza cilindros de prueba para evaluar la capacidad de carga de las tablas individuales del pallet. Además, ofrece la opción de un rodillo que empuja los clavos hacia adentro y, opcionalmente, una estación de cepillado para preparar la superficie del pallet para la paletización.

Una característica notable del diseño es la integración de la estación de inspección en el sistema de manejo de pallets, que evalúa la estabilidad, integridad y geometría de los pallets. Los clientes tienen la opción de seleccionar entre pistones neumáticos o rodillos neumáticos para las pruebas de presión, adaptando así el sistema a sus necesidades

específicas. La fuerza aplicada es ajustable, y los pallets que no cumplen con los estándares son automáticamente rechazados.

El sistema está equipado con sensores para recopilar datos del proceso de prueba. Estos datos se envían a la estación de inspección para su análisis y luego se transmiten al equipo de manejo posterior. La detección temprana de pallets defectuosos o dañados permite su expulsión automática de la línea de producción, minimizando interrupciones en el flujo de material y daños a los productos.

Si bien el sistema Innocheck PKS DR destaca por su velocidad y precisión, capaz de inspeccionar hasta 120 pallets o 200 medios pallets por hora, y por su capacidad de reparar clavos en la misma estación, presenta ciertas limitaciones. No cuenta con un mecanismo para filtrar por tipos de pallet, enfocándose únicamente en la integridad física del mismo. Además, carece de la capacidad de medir las dimensiones de los pallets o identificar su color, lo que sería relevante para determinar la etiquetación adecuada. En resumen, el sistema se centra en evaluar si el pallet se encuentra en buenas condiciones físicas, sin ofrecer una clasificación más detallada basada en tipo, tamaño o color.

2.3 Marco teórico

2.3.1 Introducción a la Automatización Industrial

La automatización industrial ha emergido como un componente esencial en la mejora de la eficiencia, la calidad y la productividad en diversos sectores manufactureros. En un mundo cada vez más competitivo, las empresas buscan constantemente formas de optimizar sus procesos de producción y minimizar los costos, y la automatización industrial se ha convertido en una solución clave para lograr estos objetivos.

La automatización industrial implica la aplicación de tecnologías avanzadas y sistemas inteligentes para controlar y supervisar los procesos de fabricación de manera autónoma. Estos sistemas pueden abarcar desde maquinaria controlada por computadoras hasta robots industriales y sistemas de control de procesos en tiempo real. Su principal objetivo es reducir la intervención humana, disminuir los errores y aumentar la eficiencia de la producción.

Esta sección del marco teórico se centrará en proporcionar una visión general de la automatización industrial, destacando su importancia en el contexto de la inspección

y clasificación de pallets. Además, se explorarán los avances tecnológicos más relevantes que han permitido la automatización de los procesos industriales y cómo estas tecnologías pueden aplicarse específicamente al ámbito de la inspección y clasificación de pallets.

La automatización industrial no sólo ofrece la promesa de mejorar la calidad y la consistencia en la inspección de pallets, sino que también puede aumentar la velocidad de procesamiento y reducir los costos operativos. Al comprender los fundamentos de la automatización industrial y su relación con la inspección y clasificación de pallets, se sienta una base sólida para abordar las cuestiones específicas que se tratarán en este trabajo de investigación.

A lo largo de esta sección, se examinarán conceptos clave como los sistemas de control automático, la robótica industrial, la visión por computadora y la integración de sistemas, todos los cuales desempeñan un papel esencial en la automatización de los procesos de inspección y clasificación de pallets. Además, se discutirán las ventajas y desafíos asociados con la implementación de sistemas de automatización en el entorno industrial, proporcionando una visión completa de esta área fundamental de estudio.

2.3.2 Soluciones Relevantes

1. **Machine vision intelligence for product defect inspection based on deep learning and Hough transform(Wang, Fu, & Gao, 2019):** propusieron un modelo de visión por computadora para la inspección de defectos en productos basado en aprendizaje profundo y la transformada de Hough. El método diseñado detecta productos defectuosos a través de tres pasos principales: preprocesamiento de imágenes, extracción de la región de interés (ROI) e identificación de imágenes. Como primer paso, se aplicó un filtro Gaussiano a la imagen adquirida para limitar el ruido aleatorio y obtener una representación mejorada de la imagen cruda. La operación continua del dispositivo de imágenes inevitablemente conduce a un aumento excesivo de su temperatura. Como resultado, las imágenes capturadas se verán afectadas por ruido Gaussiano. Por lo tanto, se utilizó un filtro Gaussiano como etapa de preprocesamiento para mejorar las estructuras de la imagen y reducir el ruido.

En segundo lugar, se empleó la transformada de Hough probabilística para extraer la ROI de las imágenes filtradas. Las imágenes capturadas no garantizan que toda

la información contenida esté relacionada con la tarea. Por ejemplo, el contenido del fondo puede ocupar una parte considerable de la imagen, lo que resulta en cálculos innecesarios en la siguiente etapa de identificación. Por lo tanto, se utilizó la técnica de la transformada de Hough para aislar las características y extraer la ROI de las imágenes filtradas.

Finalmente, los autores utilizaron una red neuronal convolucional para construir el módulo de identificación de imágenes. Construyeron el módulo de identificación de imágenes basado en el bloque residual invertido, que es una buena alternativa para reducir el tamaño del modelo y el tiempo de cálculo. La identificación de imágenes se realizó utilizando el método propuesto con una gran cantidad de conjuntos de datos, que consistían en imágenes de botellas defectuosas y sin defectos. El análisis de los resultados obtenidos reveló que la preparación de los datos es un paso crucial y decisivo para el éxito de cualquier modelo.

La aplicación del método de extracción de ROI basado en la transformada de Hough probabilística con la ayuda de una fuente de luz rectangular permitió obtener la región correcta de la botella en la imagen original. En consecuencia, el tiempo requerido para la identificación de imágenes se redujo significativamente. El método de inspección considerado gasta en promedio 47.60 ms en cada identificación de imagen y logra una precisión del 99.60

2. **A computer vision system for defect discrimination and grading in tomatoes using machine learning and image processing(Ireri, Belal, Okinda, Makange, & Ji, 2019):** propusieron un sistema de visión por computadora para clasificar tomates basado en imágenes RGB. Inicialmente, se aplicaron algoritmos de segmentación para eliminar el fondo de las imágenes capturadas. En este estudio, se utilizó una técnica simple de sustracción de imágenes para eliminar el fondo debido a que el sistema de adquisición de imágenes era estacionario. Por lo tanto, los píxeles de fondo tenían valores más bajos que los píxeles del primer plano. Por lo tanto, el fondo se eliminó por completo mediante una técnica de umbralización de histograma. A continuación, se detectaron las cicatrices del cáliz y el pedúnculo y se segmentaron los defectos. El sistema detecta cicatrices del cáliz y el pedúnculo tanto en tomates defectuosos como en tomates sanos mediante umbralización de histograma basada en el valor medio de g-r de estas regiones de interés.

En tercer lugar, se extrajeron las características de color, textura y forma de todas las imágenes. En este estudio, se utilizó el espacio de color LAB debido a su capacidad de variación limitada debido a la sensibilidad de los sensores [13], las características texturales se calcularon a partir de matrices de co-ocurrencia de niveles de gris (GLCM) [14] y se calculó el valor asimétrico de la forma del tomate como medida de la regularidad de la forma [15].

Finalmente, se aplicaron clasificadores basados en algoritmos de máquinas de soporte vectorial (SVM), redes neuronales artificiales (ANN) y bosques aleatorios para la clasificación de diferentes categorías de tomates. Los resultados obtenidos indican que el algoritmo RBF-SVM superó a todos los demás modelos con la mayor precisión del 97.09% para las categorías de tomates sanos y defectuosos. Sin embargo, la precisión de la clasificación disminuyó a medida que aumentó el número de categorías de clasificación.

El sistema propuesto en este artículo puede utilizarse como una herramienta de clasificación de tomates en línea para garantizar el cumplimiento de los estándares de calidad.

3. **Fundamentals of common computer vision techniques for textile quality control(Jiang & Wong, 2018):** introdujeron los fundamentos de las técnicas comunes de visión por computadora para el control de calidad textil. Inicialmente, los autores enumeraron las dificultades encontradas al implementar un método basado en técnicas de visión por computadora para la detección de defectos en tejidos en tiempo real. Por ejemplo, la existencia de muchos tipos de tejidos y la caracterización de defectos en los tejidos que generalmente no está claramente definida requieren el uso de muchos tipos de algoritmos. Además, los algoritmos deben ser eficientes e implementarse en tiempo real.

A continuación, los autores definieron la arquitectura básica de un sistema de inspección automatizada de tejidos que consta de un conjunto de cámaras, capturadores de imágenes, una computadora y un sistema de iluminación. Se utilizan dos tipos de cámaras para detectar defectos en los tejidos: cámaras de línea y cámaras de área. Las cámaras de línea pueden capturar imágenes con textura más nítida que las cámaras de área, pero el costo de una cámara de línea es muy

alto; por lo tanto, se utilizan comúnmente una serie de cámaras de área para la detección económica de defectos en los tejidos. El capturador de imágenes es un dispositivo electrónico que captura imágenes digitales individuales de una secuencia de video digital. La computadora principal realiza dos funciones: detección de defectos y clasificación. La detección de defectos se realiza mediante los algoritmos de detección de defectos correspondientes, y la clasificación se lleva a cabo automáticamente utilizando una regla basada en el tamaño del defecto para puntuar los defectos. Además, la iluminación también es muy importante para la recopilación de imágenes, ya que determina la calidad de las imágenes capturadas.

Los autores luego dividieron las técnicas basadas en visión por computadora para la detección de defectos en tejidos en tres tipos de algoritmos: enfoques estadísticos, enfoques espectrales y enfoques basados en modelos. Los enfoques estadísticos y espectrales utilizan algoritmos de bajo nivel que operan directamente sobre los datos, mientras que los enfoques basados en modelos se centran en la estructura de los datos. Sugirieron dos modelos: el modelo autoregresivo, que es una representación que utiliza la dependencia lineal entre los diferentes píxeles de una textura para describir las características de la textura, y el modelo de campo aleatorio de Markov, que se aplica con éxito en la segmentación y clasificación de texturas.

Varios problemas deben considerarse para la implementación de tecnologías de detección de defectos en tejidos: la mayoría de los algoritmos aplicados funcionan mal cuando se aplican a imágenes de tejidos del mundo real y son computacionalmente demasiado costosos para su implementación en tiempo real. Además, el costo de implementar un sistema de inspección visual automatizada es muy alto. Por lo tanto, la investigación futura debe centrarse en un sistema de inspección de tejidos más económico y rápido para una aplicación industrial real.

4. **A Dynamic Bottle Inspection Structure.**(Kumar Sahoo, Sharma, & Choudhury, 2019): sugirieron una estructura de inspección dinámica de botellas. Primero, se capturaba la imagen de la botella a inspeccionar mediante una cámara inteligente de alta resolución. Luego, se emplearon técnicas de procesamiento de imágenes para reducir el ruido y mejorar la calidad de las imágenes capturadas. La región de interés (partes defectuosas de la botella) se seleccionaba de la imagen original mediante recorte y luego se convertía en una imagen en escala de grises. La imagen de la

botella se segmentaba del fondo de la imagen aplicando métodos de segmentación. A continuación, se construyó un conjunto de datos a partir de las características adaptativas estimadas utilizando conceptos matemáticos como el vector de características bidimensionales promedio en escala de grises, la transformada wavelet y el análisis de componentes principales (PCA).

Se utilizó una red neuronal artificial (ANN) entrenada mediante el algoritmo de retropropagación (BP), el algoritmo de evaluación diferencial (DEA) y una máquina de soporte vectorial (SVM) para clasificar las imágenes teniendo en cuenta las características extraídas como variables de entrada y los tipos de botellas defectuosas como variables de salida. Durante la inspección, existe el riesgo de iluminación insuficiente y un cambio en la posición de un objeto debido a diversos factores, lo que significa que se debe implementar un arreglo sensorial. Los autores de este artículo realizaron una comparación entre los diferentes algoritmos de clasificación utilizando tres métodos de extracción de características (vector de características bidimensionales promedio en escala de grises, características basadas en PCA y características basadas en wavelet) con y sin implementación de sensores en el sistema de inspección de visión por computadora. Los resultados obtenidos revelaron que el tiempo de cálculo de la ANN utilizando el DEA es comparativamente menor que el de la ANN utilizando BP.

La comparación del tiempo de cálculo promedio indicó que el tiempo de cálculo es más importante para la clasificación de botellas sin sensor que para la clasificación con sensor. El sistema propuesto es capaz de clasificar imperfecciones en botellas con una tasa de éxito de clasificación del 91.25% al 97.5%. Finalmente, se concluyó que el sistema de inspección de visión por computadora basado en inteligencia artificial es el más adecuado para la inspección del nivel de calidad de imperfecciones en botellas.

5. **Research on Vehicle Parts Defect Detection Based on Deep Learning(Liquin, Jiansheng, & Dingjin, 2020):** Diseñaron un modelo mejorado basado en VGG16 e introdujeron el módulo Inception v3 para la detección de defectos en piezas de vehículos de las seis categorías más comunes: pernos del eje delantero izquierdo, pernos del eje delantero medio, ejes de transmisión, cerraduras de estacionamiento y mecanismos de cambio, herramientas de dirección especiales, pernos de posi-

cionamiento del faro derecho y amortiguadores. VGGNet es un modelo de red neuronal convolucional profunda desarrollado por investigadores del Visual Geometry Group y Google DeepMind de la Universidad de Oxford.

El modelo de red VGGNet explora principalmente la relación entre la profundidad de la red neuronal convolucional y su rendimiento mediante la construcción de una red neuronal convolucional con una profundidad de 16 a 19 capas, apilando repetidamente capas de convolución de núcleos pequeños de 3×3 y capas de agrupación máxima de 2×2 . El método Inception v3 descompone los núcleos de convolución para integrar una convolución bidimensional más grande en dos convoluciones unidimensionales más pequeñas. Por ejemplo, la red de convoluciones de 7×7 se divide en tres convoluciones de 3×3 , lo que produce más parámetros que dividir la red de convoluciones de 7×7 en convoluciones de 1×7 y 7×1 para reducir el tiempo computacional.

Las muestras experimentales se dividen en un conjunto de entrenamiento y un conjunto de pruebas, y cada una de las siete categorías de detección de defectos en vehículos se divide en muestras positivas y negativas. El experimento en este artículo se dividió en tres partes que utilizan el método tradicional HOG + SVM, el modelo de red VGG16 sin mejoras y el modelo de red VGG16 mejorado para detectar defectos en piezas de vehículos. Los resultados obtenidos son los siguientes: en primer lugar, la tasa de precisión del modelo de estructura de red VGG16 es del 94.36%; en segundo lugar, la tasa de precisión del modelo de estructura de red VGG16 mejorado al introducir el módulo Inception v3 es del 95.29%; y, finalmente, la precisión del método de clasificación tradicional HOG + SVM es sólo del 93.88%. El modelo de estructura de red VGG16 mejorado con el módulo Inception v3 ofrece mejores resultados que otros métodos.

6. Intelligent Machine Vision Model for Defective Product Inspection Based on Machine Learning(Benbarrad, Salhaoui, Kenitar, & Arioua, 2021):

Trata de un modelo de inspección basado en visión por computadora para el control de calidad de productos, que combina dos tipos de aprendizaje automático: un modelo de clasificación para la inspección de productos y un modelo de regresión para la predicción de procesos. El sistema propuesto permite la detección temprana

de errores en los procesos de fabricación y ayuda a garantizar una alta calidad del artículo antes de que se mueva a la siguiente etapa de fabricación. Además, el sistema ayuda en la recopilación de estadísticas históricas y de producción tanto para productos defectuosos como sin defectos, que se utilizan para mejorar los procesos de fabricación. Como resultado, contribuye a reducir el desperdicio de material, los costos de reparación y retrabajo, así como el tiempo y los gastos adicionales de mano de obra de fabricación.

Sin embargo, el sistema diseñado tiene algunas limitaciones relacionadas con la implementación de redes neuronales convolucionales (CNN). Estos modelos consumen una gran cantidad de recursos computacionales y requieren grandes cantidades de datos de entrenamiento para optimizar su rendimiento.

2.4 Discusión

En esta sección, examinaremos en detalle las contribuciones distintivas de nuestra solución en la automatización del proceso de inspección y clasificación de pallets, destacando las diferencias clave con las soluciones proporcionadas por SICK, Sidel e Innocheck PKS DR.

Nuestra propuesta se basa en una estrategia innovadora que utiliza cámaras estratégicamente ubicadas a lo largo de la cinta transportadora. Esto permite la captura de Regiones de Interés (ROI) de los pallets en movimiento sin interrupciones en el flujo del proceso. Las imágenes resultantes se procesan de manera instantánea mediante un servidor en el borde (edge) o in situ, centrado en analizar las ROI identificadas. Este enfoque posibilita la ejecución de pruebas y evaluaciones diversas, conduciendo a una clasificación precisa de los pallets.

En términos de rendimiento, es crucial destacar que la máquina puede operar de manera continua durante 24 horas, clasificando hasta 5,760 pallets al día, gracias a la velocidad máxima de 1 pallet cada 15 segundos. Esta sincronización con el magazine de pallets garantiza una eficiencia constante en la inspección y clasificación, incluso en entornos logísticos de operación constante.

Innovación en la Detección y Clasificación: Nuestra solución se distingue por integrar un sistema avanzado de cámaras capaz de filtrar los pallets según diversas características, como color, tamaño y marcas específicas en los tacos de los pallets.

Esta innovación proporciona una clasificación detallada, superando las limitaciones de los sistemas convencionales que a menudo se limitan a parámetros fijos.

Alta Capacidad de Adaptación: Una fortaleza clave de nuestra solución es su capacidad para adaptarse a diferentes tipos de pallets sin necesidad de recalibración específica para cada variante. Esta flexibilidad es esencial para operaciones que manejan una amplia gama de pallets, asegurando una eficiencia constante frente a variaciones en cargas de trabajo o tipos de pallets.

Mejora en Eficiencia y Fiabilidad: La aplicación de tecnología de cámaras no sólo incrementa la precisión en la clasificación de pallets, sino que también contribuye a una mayor eficiencia operativa. La automatización avanzada reduce la intervención manual, disminuyendo los errores humanos y aumentando la velocidad del proceso de inspección.

Esta combinación de innovación, adaptabilidad y eficiencia sitúa a nuestra solución en una posición ventajosa para satisfacer las demandas actuales y futuras en la industria de manejo de pallets, superando las opciones existentes en términos de rendimiento y versatilidad.

Chapter 3

Desarrollo de la solución

3.1 Arquitectura del Sistema

3.1.1 Arquitectura IoT




Figure 3.1: Internet of Things(IoT) architecture of the proposed model.

Fuente: elaboración propia

1. Sensores: Estos dispositivos son responsables de recopilar datos, en este caso, imágenes de la cinta transportadora. Los sensores pueden ser cámaras u otros dispositivos

de captura de imágenes que capturan información sobre los pallets a medida que se mueven a lo largo de la cinta. Estas imágenes son datos crudos que se utilizan como entrada para el sistema.

2. IoT Gateway: El IoT Gateway es un componente central en la arquitectura. Su función principal es recibir los datos capturados por los sensores, incluyendo las imágenes de los pallets. Luego, realiza varias tareas importantes:

- (a) Procesamiento Local: El IoT Gateway puede realizar un preprocesamiento inicial de las imágenes, como la reducción de ruido o la compresión, junto con realizar la clasificación correspondiente de la imagen inspeccionada. El fin de que este procesamiento sea local es poder ofrecer los mejores tiempos de respuesta para una rápida clasificación.
- (b) Comunicación con la Nube: El IoT Gateway se encarga de enviar los datos procesados, incluidas las imágenes, a la nube para su análisis y almacenamiento.
- (c) Instrucciones al PLC: Además de enviar datos a la nube, el IoT Gateway también puede recibir instrucciones del sistema central y enviarlas al PLC (Controlador Lógico Programable). Estas instrucciones pueden estar relacionadas con la manipulación y clasificación de los pallets en la cinta transportadora.

3. PLC (Controlador Lógico Programable): El PLC es un componente esencial en la automatización industrial. Recibe instrucciones del IoT Gateway y controla físicamente la cinta transportadora y otros actuadores para llevar a cabo las acciones requeridas, como desviar pallets hacia diferentes destinos en función de la información recibida.

4. Nube: La nube es donde se realiza el almacenamiento. Los datos, incluidas las imágenes y las etiquetas, se almacenan en la nube y se utilizan para tareas como la creación de modelos de clasificación de pallets, la detección de defectos, el seguimiento de la eficiencia del proceso y la generación de informes.

3.1.2 Descripción de Componentes

1. Pallets a ser Clasificados: Estos son los objetos físicos que se mueven a lo largo de la cinta transportadora y que deben ser clasificados según su estado o características. Los pallets son los elementos que atraviesan todo el proceso de inspección y clasificación.
2. Sistema de Inspección: Este componente es responsable de la recopilación de datos sobre los pallets. Incluye cámaras y sensores que capturan imágenes e información relevante sobre los pallets en movimiento. Las cámaras toman imágenes de alta resolución que se utilizan como datos de entrada para el sistema de clasificación.

El sistema de inspección viene compuesto por 3 cámaras 2D que tienen la principal ventaja de tener obturador total. Esto se traduce en la capacidad para obtener imágenes nítidas y detalladas de un pallet en movimiento, sin que la imagen se vea distorsionada o corrida. Esto es esencial para garantizar una inspección precisa y una clasificación efectiva de los pallets, incluso en situaciones de alta velocidad.

- **Tarjetas Raspberry Pi (3):** Las tarjetas Raspberry Pi son empleadas para capturar imágenes de los pallets. Estas imágenes se envían al servidor para su procesamiento y análisis en el sistema de inspección y clasificación.
- **Memoria MicroSD 64GB (3):** La memoria MicroSD de 64GB se utiliza para almacenar datos y el sistema operativo en las tarjetas Raspberry Pi, asegurando un espacio adecuado para el procesamiento de imágenes y el correcto funcionamiento del sistema.
- **Fuente de alimentación cámaras (3):** La fuente de alimentación suministra energía a las cámaras, garantizando un funcionamiento continuo y estable durante la captura de imágenes. Es esencial para mantener la integridad del sistema de inspección de pallets.
- **Carcasa y ventilador Raspberry (3) :** La carcasa y el ventilador para Raspberry Pi se emplean para proporcionar un entorno de funcionamiento óptimo. Ayudan a mantener una temperatura adecuada para el rendimiento eficiente de las Raspberry Pi, asegurando la estabilidad del sistema de captura y procesamiento de imágenes.

3. Sistema de Clasificación: El sistema de clasificación es un componente crítico que procesa los datos capturados por las cámaras y sensores. Incluye modelos de aprendizaje automático o algoritmos específicos que analizan las imágenes y determinan el estado o la categoría de cada pallet. Este sistema toma decisiones basadas en los datos de entrada y puede etiquetar los pallets como 'defectuosos' o 'aceptables' según los criterios establecidos.

El sistema de clasificación viene compuesto por el servidor:

- **Tarjeta de Video (1):** Encargada de procesar y mostrar datos visuales, es crucial para el rendimiento gráfico en el procesamiento de imágenes (Pruebas hechas bajo una RTX3090).
- **Procesadores (1):** Elemento central de procesamiento que ejecuta tareas computacionales, garantizando la eficiencia del servidor en la manipulación de datos complejos.
- **Placas Madre (1):** La plataforma principal que integra y conecta todos los componentes, asegurando la comunicación fluida entre ellos.
- **RAM (2):** Memoria de acceso aleatorio para el almacenamiento temporal de datos, esencial para la velocidad y capacidad de respuesta del servidor.
- **Disco Duro 2TB (1):** Almacena grandes cantidades de datos, incluyendo imágenes y resultados procesados, proporcionando capacidad de almacenamiento significativa.
- **Fuente de Poder PC (1):** Suministra energía eléctrica al servidor, garantizando un funcionamiento continuo y estable.
- **Unidades de Estado Sólido (1):** Proporcionan almacenamiento rápido y eficiente, mejorando la velocidad de lectura y escritura de datos críticos.
- **Cooler CPU (1):** Sistema de refrigeración para los procesadores, evitando el sobrecalentamiento y asegurando un rendimiento óptimo del servidor.
- **Soporte estación de trabajo (1):** Se utiliza como una medida ergonómica esencial para optimizar el entorno de trabajo del usuario. Proporciona una plataforma estable y organizada para los componentes del computador, garantizando un acceso fácil y cómodo para el usuario.

4. Cinta Transportadora Controlada por PLC: La cinta transportadora es la infraestructura física que transporta los pallets a través del proceso. Está controlada por un PLC (Controlador Lógico Programable), que recibe instrucciones del sistema de clasificación para dirigir los pallets hacia la salida apropiada en función de su estado. El PLC garantiza que los pallets se muevan de manera eficiente y segura a través del proceso de clasificación.




Figure 3.2: Componentes.

Estos componentes trabajan en conjunto para automatizar y mejorar el proceso de clasificación de pallets, permitiendo una inspección rápida y precisa de los pallets en

movimiento y la toma de decisiones en tiempo real sobre su destino o estado.

3.1.3 Diagrama de contexto




Figure 3.3: Diagrama de algoritmo de vision artificial propuesto.




Figure 3.4: Diagrama de la clasificación de los pallets

Fuente: Elaboración propia

En el diseño del sistema de inspección y clasificación de pallets, se han implementado cuatro salidas para optimizar la eficiencia del proceso. La primera salida se ha configurado linealmente, destinada a los pallets "No Andina" y aquellos en condiciones no aptas. Esta disposición lineal garantiza un flujo continuo, priorizando la rápida identificación y separación de las diversas categorías de pallets.

Las salidas 2, 3 y 4, exclusivas para pallets Andina, incorporan un sistema de conteo de fallas para determinar su destino final. Aquellos pallets que requieren reparación son dirigidos a la salida 2, mientras que los que se encuentran en buenas condiciones se canalizan hacia las salidas 3 y 4. La distinción entre estas últimas radica en la altura del pallet, siendo la salida 4 designada para pallets reforzados y la salida 3 para pallets de altura estándar. Este enfoque estratégico asegura una clasificación eficiente y precisa, optimizando el rendimiento del sistema de inspección.




Figure 3.5: Sistema de inspección.

Se han incorporado sensores de proximidad en puntos estratégicos del sistema para detectar con precisión la llegada de cada pallet a puntos específicos. Estos sensores, al utilizar tecnología de proximidad, permiten una detección eficiente sin contacto físico directo. Su capacidad para alertar cuando un pallet alcanza un punto predeterminado es esencial para la sincronización y el control de flujo en el proceso de inspección y clasificación. La implementación de estos sensores optimiza la automatización del sistema, mejorando la eficiencia y asegurando una respuesta rápida y precisa en cada etapa del proceso.

Se han integrado cuatro barras amarillas estratégicamente posicionadas a la misma altura que los pallets, y a distancias conocidas, con el propósito de facilitar la calibración de la cámara en el sistema. Estas barras amarillas desempeñan un papel esencial al proporcionar puntos de referencia visualmente distintos para asegurar una calibración precisa de la cámara. Al encontrarse a alturas conocidas y distancias predefinidas,

estas barras se convierten en elementos clave para garantizar la exactitud y consistencia en la captura de imágenes durante el proceso de inspección. Su incorporación contribuye significativamente a la calidad y confiabilidad del sistema, mejorando la capacidad de la cámara para realizar evaluaciones precisas y consistentes de los pallets.

Las cámaras implementadas en el sistema desempeñan una función crucial al realizar la obtención de dos imágenes distintas para una evaluación integral de cada pallet. En primer lugar, capturan una vista directa del taco del pallet, permitiendo así una verificación detallada de su texto y características específicas. Esta perspectiva directa es esencial para garantizar una inspección minuciosa de los detalles del pallet.

Adicionalmente, las cámaras capturan una vista completa lateral del pallet, ofreciendo una visión panorámica que complementa la información obtenida desde la vista del taco. Esta dualidad en la obtención de imágenes proporciona al sistema una visión holística y detallada de cada pallet, mejorando la capacidad de inspección y clasificación al considerar tanto aspectos específicos del taco como la condición general del pallet.




Figure 3.6: Sistema de inspección - Imagen Lateral 1.




Figure 3.7: Sistema de inspección - Imagen Lateral 2.

3.1.4 Descripción de módulos

Módulo 1: Diseño del Sistema de Obtención de Datos

Propósito

El propósito del diseño del sistema de obtención de datos es establecer una estructura y metodología para recopilar de manera eficiente y precisa la información necesaria para el proceso de inspección de pallets. Este sistema garantiza la adquisición adecuada de imágenes de los pallets, y medición de tablas y la verificación de la posición de los pallets.

Alcance

El diseño del sistema de obtención de datos abarca los siguientes aspectos:

- Selección y configuración de cámaras adecuadas para la captura de imágenes de los pallets desde diferentes ángulos.
- Desarrollo de algoritmos y técnicas para el procesamiento de las imágenes y los datos de los sensores.
- Integración de los componentes del sistema de obtención de datos con otros módulos del sistema general de clasificación y evaluación de los pallets.

Dependencias

- Disponibilidad de cámaras capaces de obtener una imagen del pallet en movimiento sin distorsión. Para esto se eligen cámaras que posean la cualidad de tener obturador total.
- Interfaz de comunicación para transmitir los datos recopilados a otros módulos del sistema.

Supuestos

- Se asume que las cámaras se encuentran en condiciones operativas y son capaces de proporcionar datos precisos y confiables.
- Los pallets están ubicados en una posición adecuada para la inspección y se pueden capturar imágenes desde diferentes ángulos.
- Existe una infraestructura de comunicación establecida para la transmisión de los datos recopilados a otros componentes del sistema.

Restricciones

- Las cámaras tienen limitaciones técnicas en términos de rango, resolución y velocidad de captura.
- La calidad de las imágenes puede verse afectada por factores ambientales, como la iluminación y la visibilidad.
- La posición y orientación de los pallets pueden influir en la precisión de los datos recopilados por los sensores.

Estructura General

El módulo de *Obtención de Data* consta de los siguientes componentes y procesos:

1. Configuración de los sensores láser y activación para la adquisición de datos.
2. Captura de imágenes de los pallets desde diferentes ángulos utilizando cámaras.

3. Verificación de la posición de los pallets y confirmación de su ubicación adecuada para la inspección.
4. Transmisión de los datos recopilados a otros módulos del sistema para su posterior análisis y clasificación.

3.1.5 Vistas y Áreas de Interés para la Inspección de Pallets:

Para un modelo de inspección y clasificación de pallets, es importante definir las vistas y las áreas de interés (ROI) que serán capturadas por las cámaras para garantizar una inspección efectiva. Para este trabajo, se definen las siguientes vistas con sus respectivos ejemplos.

Vista Superior

- **Descripción:** Captura una vista aérea completa del pallet.
- **Área de Interés (ROI):** El pallet completo en el centro de la imagen.
- **Utilidad:** Verificación del estado de las tablas del pallet, junto con saber las dimensiones de este, para saber a qué tipo pertenece.



Figure 3.8: Vista superior.



Figure 3.9: Vista Superior 2.

Vista Lateral 1

- **Descripción:** Vista desde uno de los lados largos del pallet.
- **Área de Interés (ROI):** Enfoque en la alineación y estabilidad de los productos desde el lateral.

- **Utilidad:** Detección de problemas en tacos sobresalientes o desalineados. También permitirá la obtención de la altura del pallet inspeccionado. Junto con características esenciales para determinar el tipo de pallet




Figure 3.10: Vista Lateral 1.

Vista Lateral 2

- **Descripción:** Vista desde el otro lado largo del pallet.
- **Área de Interés (ROI):** Similar a la vista lateral 1, enfoque en la alineación y estabilidad desde el otro ángulo.
- **Utilidad:** Complementa la vista lateral 1 para una inspección de 3 tacos delanteros como los 3 finales.




Figure 3.11: Vista Lateral 2.

Vista Inferior

- **Descripción:** Vista desde debajo del pallet.
- **Área de Interés (ROI):** El área bajo el pallet, enfocándose en las bases de apoyo y la integridad estructural.

- **Utilidad:** Verificación de daños en la parte inferior y la condición de las tablas que se encuentran por debajo.



Figure 3.12: Vista inferior.

3.1.6 Módulo 2: Preprocesamiento de la imagen

Propósito

En el módulo de preprocesamiento de imágenes, se llevan a cabo una serie de pasos para preparar las imágenes de los pallets y optimizarlas para su posterior inspección y clasificación. A continuación, se describen los principales pasos realizados:

Alcance

El diseño del preprocesamiento abarca los siguientes aspectos:

- Selección de un modelo adecuado para la clasificación de imágenes de pallets.
- Preprocesamiento de las imágenes capturadas por las cámaras para su posterior análisis y clasificación.
- Implementación de algoritmos de extracción de características relevantes para la clasificación del tipo de pallet.
- Evaluación y validación del rendimiento del proceso

- Integración del proceso con otros módulos del sistema para el procesamiento y toma de decisiones basadas en la clasificación del tipo de pallet.

Dependencias

- Disponibilidad de un conjunto de datos etiquetados que contengan imágenes representativas de los diferentes tipos de pallets a clasificar.
- Selección y configuración de cámaras adecuadas para capturar imágenes de alta calidad y resolución de los pallets.
- Elección de modelos adecuados utilizando los datos etiquetados.
- Disponibilidad de recursos computacionales suficientes para el entrenamiento y evaluación del modelo de clasificación.

Supuestos

- Se asume que las imágenes capturadas por las cámaras representan fielmente las características visuales de los pallets y son suficientemente claras para permitir su clasificación precisa.
- El modelo de clasificación aprenderá patrones visuales distintivos para diferenciar los diferentes tipos de pallets y podrá generalizar correctamente a nuevas imágenes.
- No hay limitaciones técnicas o restricciones específicas que impidan la clasificación precisa del tipo de pallet utilizando imágenes capturadas por las cámaras.

Restricciones

- La precisión de la clasificación del tipo de pallet estará sujeta a la calidad de las imágenes capturadas, la variedad de los tipos de pallets y la capacidad del modelo de aprendizaje automático para generalizar a nuevas imágenes.
- El rendimiento del clasificador puede verse afectado por condiciones de iluminación y otros factores ambientales que pueden influir en la calidad de las imágenes.

Estructura General

El diseño del Módulo 2 sigue los siguientes pasos:

1. Adquisición de imágenes de pallets utilizando cámaras adecuadas.
2. Preprocesamiento de las imágenes para mejorar la calidad y eliminar posibles ruidos o distorsiones.
3. Extracción de características relevantes de las imágenes para la clasificación del tipo de pallet.
4. Evaluación y validación del modelo utilizando conjuntos de datos.
5. Integración del clasificador en el sistema para su uso en la clasificación automatizada del tipo de pallet.

Funcionamiento

El módulo encargado del preprocesamiento inicia su función al recibir imágenes que contienen pallets, pero no vistos con una perspectiva óptima e incluyendo áreas que no nos sirven. Para asegurar una captura precisa y relevante, se implementan técnicas avanzadas de obtención de características destacadas. Utilizando métodos de filtrado de color, enmascaramiento y detección de bordes, se logra identificar de manera precisa el área relevante de cada pallet en la imagen.

Posteriormente, se aplica un proceso de warping, que consiste en la transformación geométrica de la imagen. Esta transformación se realiza de manera que se genere una vista del pallet con sus tablas de manera óptima. El objetivo es lograr una representación visual donde sólo se destaque el pallet y se visualicen claramente las tablas, eliminando cualquier elemento no relevante para la inspección. A continuación, se describen los principales pasos realizados:

1. **Filtrado en el espacio de color YCrCb:** El primer paso consiste en aplicar un filtro en el espacio de color YCrCb a la imagen original del pallet. Este filtrado permite resaltar la cara más relevante del pallet, lo que es esencial para una inspección precisa.

2. **Generación de la máscara del pallet:** Utilizando técnicas de procesamiento de imágenes, se genera una máscara que identifica la región del pallet en la imagen. Esto se logra mediante un proceso de convex hull (envoltura convexa), que delimita la forma general del pallet en la imagen.
3. **Detección de bordes:** Una vez obtenida la máscara del pallet, se aplica el operador de Canny para detectar los bordes del pallet de manera precisa. Esta detección de bordes es fundamental para obtener una representación clara de la estructura del pallet.
4. **Identificación de las 4 esquinas:** Para lograr una perspectiva más uniforme y adecuada del pallet, se lleva a cabo la identificación de las cuatro esquinas del pallet en la imagen. Esto permitirá realizar un proceso de "warping" para enderezar y ajustar la perspectiva del pallet, dejándolo listo para pruebas posteriores en el módulo 3.
5. **Warping de la imagen:** Para evitar cualquier mal posicionamiento del pallet, se realiza un warping a la misma, para obtener dicho pallet con una buena perspectiva.




Figure 3.13: Proceso de preprocesamiento.



Figure 3.14: Entrada y salida del módulo de preprocesamiento.

3.1.7 Módulo 3: Clasificación y Segmentación

Propósito

En este módulo, nos centraremos en dos aspectos fundamentales: la segmentación de los objetos en el pallet, que incluyen las tablas y los tacos, y la realización de pruebas para determinar si el pallet pertenece a la clase deseada. Estos procesos son críticos para garantizar la precisión en la clasificación de pallets en nuestro proyecto de inspección.

Alcance

El diseño del Módulo 3 abarca los siguientes aspectos:

- Procesamiento de las imágenes capturadas por las cámaras para su posterior análisis y detección de fallas.
- Implementación de algoritmos de procesamiento de imágenes para localizar las áreas de interés y resaltar las posibles fallas en el pallet.

- Desarrollo de métodos de detección y segmentación de las fallas presentes en el pallet.
- Integración del clasificador con otros módulos del sistema para el procesamiento y toma de decisiones basadas en la cantidad de test aprobados para la clasificación adecuada.

Dependencias

- Disponibilidad de un conjunto de datos etiquetados que contengan imágenes representativas de los diferentes tipos de fallas en los pallets.
- Selección y configuración de cámaras adecuadas para capturar imágenes de alta calidad y resolución de las fallas presentes en los pallets.
- Elección y desarrollo de algoritmos de procesamiento de imágenes para la detección y segmentación de las fallas.
- Disponibilidad de recursos computacionales suficientes para el procesamiento y análisis de las imágenes capturadas.

Supuestos

- Se asume que las imágenes capturadas por las cámaras representan fielmente las características visuales de las fallas presentes en los pallets y son suficientemente claras para permitir su detección y segmentación.
- El conteo de las fallas identificadas se realizará correctamente y reflejará la cantidad real de fallas presentes en el pallet.

Restricciones

- La detección de fallas estará limitada a las áreas visibles y accesibles en las imágenes capturadas. No se considerarán las áreas ocultas o fuera del alcance de las cámaras.
- El clasificador no podrá detectar fallas que no sean visibles en las imágenes capturadas o que requieran de técnicas de inspección adicionales, como pruebas de resistencia o análisis estructural más avanzado.

Estructura General

El diseño del Módulo 3 sigue los siguientes pasos:

1. Detección de contornos: Identificación de los bordes de los objetos en la imagen.
2. Umbralización: Definir umbrales para separar las tablas de los tacos y el fondo.
3. Extracción de regiones de interés (ROI): Recortar y aislar cada tabla y taco para su posterior análisis.
4. Filtrado y limpieza de ruido: Eliminación de elementos no deseados en las ROI.

Clasificación de Pallets:

1. Características de las tablas y tacos: Extracción de características relevantes, como dimensiones, color, textura, y otros atributos que nos permitan caracterizar los objetos y el pallet en su conjunto.
2. Comparación con criterios de clasificación: Establecer reglas o umbrales que determinen si el pallet se ajusta a los estándares de la clase deseada.
3. Clasificación: dados los distintos tests, saber si el pallet cumple o no cumple con los requisitos de un pallet Andina para hacer conteo de sus respectivas fallas.

3.1.8 Módulo 3: Clasificación

El proceso de clasificación de pallets Andina se llevó a cabo mediante la implementación de un robusto módulo de clasificación que incorpora tres técnicas clave: color, tamaño y texto en taco. Estas técnicas se han diseñado con el objetivo de discernir de manera eficiente y precisa aquellos pallets que cumplen con los estándares de la marca Andina.

Clasificación binaria: Color

- Para llevar a cabo la identificación y clasificación de los pallets de la región Andina, se implementó una técnica de filtrado basada en colores.
- Los pallets de interés se caracterizan por poseer tonalidades específicas, siendo el rojo y el azul los colores distintivos asociados a esta región.

- Aquellos pallets que exhiben estos colores fueron seleccionados para no pasar a la siguiente fase del proceso de clasificación, mientras que aquellos con tonalidades cafés, continúan con el flujo.

Clasificación binaria: Tamaño

- Otra técnica empleada en el proceso de clasificación se basa en el tamaño de los pallets.
- Se establecieron criterios dimensionales específicos que permiten diferenciar los pallets Andina de otros.
- Aquellos que cumplen con las dimensiones predefinidas como representativas de la región Andina fueron identificados como pertenecientes a esta categoría, mientras que los que no cumplen con estos parámetros fueron excluidos de la selección.




Figure 3.15: Diagrama de clasificación por tamaño.

Calibración de la Cámara

1. Uso de ArUco Marker:

- ArUco Marker como herramienta de calibración: Se emplea ArUco Marker como una herramienta eficaz para la calibración de la cámara. Al ser un objeto de tamaño conocido, facilita la estimación de la relación entre los píxeles y la distancia en la imagen.
- Objetivo: El propósito de utilizar ArUco Marker es establecer la relación precisa entre los píxeles en la imagen y las distancias reales, permitiendo una calibración precisa de la cámara.

2. Relación Píxel-Distancia:

- Obtención y cálculo de la relación píxel-distancia: Se detalla el proceso de obtención y cálculo de la relación píxel-distancia utilizando ArUco Marker. Este paso es crucial para traducir las dimensiones de la imagen a unidades físicas.
- Importancia de la relación para las mediciones: Se destaca la importancia de la relación píxel-distancia en las mediciones de objetos en la imagen, ya que proporciona la base para convertir las dimensiones de píxeles a unidades físicas significativas.

Obtención de Contornos y Medición de Objetos:

Haciendo uso de la función de obtención de contornos de OpenCV, se hace la medición de los pallet en cuestión, para determinar si cumplen con las dimensiones características de un pallet Andina. En caso de no cumplir con las dimensiones, el sistema retornará la etiqueta "No andina", y finalizará el proceso de clasificación del pallet.




Figure 3.16: Ejemplo Módulo Tamaño .

Clasificación binaria: Texto

- El tercer criterio utilizado para el filtro de pallets Andina se fundamenta en la presencia de texto específico en el área del taco.

- Se identificaron dos términos clave, CCU y CMF, como indicadores representativos de pallets Andina.
- Aquellos pallets que presentan alguno de estos términos en el área del taco fueron considerados como pertenecientes a pallets no Andina, mientras que aquellos que no contienen esta información continuaron con el proceso de clasificación.




Figure 3.17: Diagrama de clasificación por texto.

1. Entrada de Imagen:

- Una imagen es proporcionada como entrada al módulo.

2. Rotación de 180°:

- La imagen se somete a una rotación de 180 grados para inspeccionar la imagen tanto en su orientación normal como invertida.

3. Filtros Aplicados:

- La imagen, tanto en su forma original como invertida, se pasa a través de una serie de filtros para mejorar la calidad y destacar características del texto, incluyendo:
 - Filtro Gaussiano
 - Filtro Blur
 - Filtro de Contraste

- Filtro de Enfoque
- Filtro de Segmentación

4. Proceso de OCR con Easy OCR:

- Se utiliza un motor de OCR (Optical Character Recognition), en este caso, Easy OCR, para extraer texto de las imágenes procesadas con los filtros.

5. Verificación de Palabras Clave:

- El texto extraído se compara con una lista predefinida de palabras clave, que incluyen: 'ccu', 'cu', 'cc', 'cm', 'cf', 'cmf', 'mf', 'c', 'u', 'm', 'f'.

6. Conteo de Coincidencias:

- Se cuenta cuántas veces se encuentra cada palabra clave en las detecciones realizadas por el OCR.

7. Decisión de No Andina:

- Si se identifican más de dos ocurrencias de palabras clave en la lista predefinida, se toma la decisión de marcar la imagen como "no andina". Esto implica que la imagen no cumple con los criterios específicos establecidos para ser considerada como una imagen andina.

3.1.9 Módulo 3: Segmentación

El módulo de segmentación de objetos es una parte fundamental de nuestro proyecto de inspección y clasificación de pallets. Su objetivo principal es identificar y aislar las tablas de los pallets en las imágenes con el propósito de evaluar su integridad y detectar posibles daños o roturas. Para lograr esta tarea de manera eficiente, hemos desarrollado un proceso de segmentación que se integra perfectamente en nuestra arquitectura general.

En nuestro proyecto, hemos empleado un modelo de segmentación de objetos conocido como "Segment Anything Model" (Kirillov et al., 2023). Este modelo ha demostrado ser altamente efectivo en la tarea de segmentar objetos en imágenes complejas. Aunque su capacidad es versátil y podría utilizarse para segmentar varios tipos de objetos, gracias al preprocesamiento que implementamos, el segmentador se enfoca exclusivamente en la región de interés, es decir, la cara del pallet.

Fast SAM es una variante del modelo SAM que está optimizada para un rendimiento más rápido, lo que lo hace adecuado para aplicaciones en tiempo real. A pesar de la aceleración en el procesamiento, aún mantiene una calidad satisfactoria en la segmentación de las tablas de los pallets en las imágenes, lo que lo convierte en una elección efectiva para su proyecto.

Esta elección estratégica de utilizar Fast SAM(Zhao et al., 2023) se debe a la necesidad de mantener una velocidad de respuesta óptima en la inspección y clasificación de pallets, lo que garantiza una evaluación eficiente de la integridad de los pallets y la detección de posibles daños o roturas en tiempo real.




Figure 3.18: Pallet en buenas condiciones.




Figure 3.19: Pallet defectuoso.

Dado que FastSam lo que segmenta es toda la imagen, si nosotros no realizamos ningún filtro los resultados son los siguientes:




Figure 3.20: Resultado final pallet en buenas condiciones.




Figure 3.21: Resultado final para pallet defectuoso.

Como se puede ver, lo que se tiene es que para el caso del pallet con falla, se encuentran muchas más máscaras.

También es posible realizar un filtrado de las máscaras obtenidas. A continuación se filtró por el tamaño promedio que tiene una tabla, por lo que se descartan todas las que no cumplen con este criterio.




Figure 3.22: Tablas Pallet en buenas condiciones.




Figure 3.23: Tablas Pallet defectuoso.

A partir de este punto, las máscaras están preparadas y se puede proceder al último módulo, donde se analizarán para detectar posibles fallas. Además, es crucial evaluar el tiempo de ejecución de este proceso.




Figure 3.24: Comparacion entre Fast SAM y SAM.

Gracias a la utilización de Fast SAM, se puede confirmar que efectivamente nos encontramos con un algoritmo que puede ser utilizado en tiempo real (estas pruebas fueron realizadas utilizando una GPU RTX 3090).

Chapter 4

Resultados

4.1 Análisis de datos

En la evaluación del rendimiento del sistema de automatización para la inspección y clasificación de pallets, los resultados obtenidos revelan un impacto significativo en la eficiencia operativa.

Para el módulo de obtención de ROI junto con la etapa de preprocesamiento se obtuvieron los siguientes resultados:

Descripción	Valor
Máximo	50.11 μ s
Mínimo	40.52 μ s
Media	47.63 μ s
Desviación Estándar	3.35 μ s

Table 4.1: Resumen de Estadísticas Módulo ROI y Módulo Preprocesamiento

Para el módulo de color se obtuvieron los siguientes resultados:

Descripción	Valor
Máximo	0.351 s
Mínimo	0.298 s
Media	0.317 s
Desviación Estándar	0.0134 s

Table 4.2: Resumen de Estadísticas Módulo Filtrado de Color

Para el módulo de medición de tamaño se obtuvieron los siguientes resultados:

Descripción	Valor
Máximo	0.195 s
Mínimo	0.147 s
Media	0.163 s
Desviación Estándar	0.013 s

Table 4.3: Resumen de Estadísticas Módulo Filtrado de tamaño

Para el módulo de procesado de texto se obtuvieron los siguientes resultados:

Descripción	Valor
Máximo	0.508 s
Mínimo	0.234 s
Media	0.282 s
Desviación Estándar	0.077 s

Table 4.4: Resumen de Estadísticas de Tiempos

Durante los experimentos, se observó que el módulo SAM, inicialmente preocupante debido a su tiempo de respuesta de aproximadamente 2000 ms/photo, experimentó una mejora notable gracias a la implementación de FastSAM. Esta optimización redujo drásticamente el tiempo de clasificación a tan solo 40 ms/photo, eliminando así las preocupaciones iniciales sobre la velocidad de procesamiento asociada con este componente.




Figure 4.1: Imágenes por segundo.

Asimismo, el módulo de reconocimiento óptico de caracteres (OCR) de EasyOCR, durante la evaluación, se observó que, dado que las condiciones de los pallets con textos escritos no siempre son ideales, fue necesario realizar ajustes adicionales en el módulo. Estos ajustes implicaron un proceso más detallado de filtrado para mejorar la eficiencia del modelo y garantizar su robustez frente a diversas condiciones. Esta adaptación estratégica permitió superar los desafíos iniciales y consolidar la eficacia del módulo OCR, reforzando así la capacidad general del sistema para lidiar con condiciones variables de manera efectiva.

Esta eficiencia se traduce en un sistema que, en su conjunto, opera con tiempos de respuesta excepcionalmente rápidos, ofreciendo una mejora sustancial en comparación con enfoques convencionales. La preocupación inicial sobre la velocidad, especialmente en el caso de SAM, ha sido abordada de manera efectiva, destacando la robustez y confiabilidad del sistema automatizado.

En resumen, los resultados cuantitativos y cualitativos respaldan la eficacia y rapidez del sistema implementado, allanando el camino para una automatización eficiente y confiable del proceso de inspección y clasificación de pallets.

4.2 Interpretación de resultados

En el desarrollo de nuestro proyecto de inspección y clasificación de pallets, implementamos un enfoque modularizado. Este enfoque nos proporcionó la flexibilidad necesaria para abordar cada etapa del proceso de manera independiente, facilitando la gestión eficiente de tareas específicas y otorgando a nuestro modelo la capacidad de ser escalable y adaptable a futuras necesidades del proyecto. La división del proceso en módulos permitió una mejora continua de cada componente, resultando en un sistema integral y versátil que responde efectivamente a los desafíos de inspección y clasificación de pallets.

Además, la modularización optimizó la implementación práctica del proyecto y estableció las bases para una arquitectura que puede evolucionar y expandirse fácilmente. Esta capacidad de adaptación se traduce en una mayor eficiencia operativa y en la posibilidad de incorporar mejoras iterativas de manera fluida. En resumen, nuestro proceso modularizado no sólo cumplió con los objetivos actuales del proyecto, sino que también sentó las bases para futuras innovaciones y refinamientos, posicionando nuestro sistema como una solución robusta y evolutiva en el ámbito de la inspección y clasificación de pallets.

Hemos alcanzado un hito significativo al implementar la capacidad de filtrar eficientemente todos los pallets que no pertenecen al tipo "Andina", evitando que lleguen a las últimas instancias del flujo de procesamiento donde se lleva a cabo la verificación de posibles fallas. Este logro es crucial, ya que permite reducir considerablemente la carga de trabajo en las etapas finales del proceso, focalizando los recursos únicamente en aquellos pallets relevantes para la clasificación final.

Importante destacar, hemos superado la barrera del tiempo en el proceso de visión por computador. Los tiempos obtenidos indican que ya no representa un problema, considerando que la velocidad de salida de pallets de los magazines (contenedores de pallets), que entregan los pallets unitariamente, es como máximo de 4 pallets por minuto. Esto significa que el proceso puede realizarse holgadamente incluso si se requiere clasificar pallets cada 15 segundos, asegurando una operatividad fluida y eficiente en el contexto de nuestro sistema de clasificación.

Chapter 5

Conclusiones

5.1 Resumen de hallazgos

El desarrollo de la presente investigación ha culminado en la concepción y ejecución exitosa de un sistema de inspección automatizada dedicado a la evaluación y clasificación de pallets en tiempo real. Entre los hallazgos más significativos se destaca el diseño innovador del sistema, el cual posibilita la identificación de las regiones de interés en los pallets incluso durante su movimiento. Este avance tecnológico permite llevar a cabo inspecciones de manera eficiente y en tiempo real, optimizando así los procesos de logística y almacenamiento.

Adicionalmente, se logró la implementación de módulos especializados en el preprocesamiento de imágenes, lo que posibilita el filtrado efectivo de clases no relevantes en el proceso de inspección. Este enfoque permitió mejorar la precisión y eficacia del sistema al reducir las interferencias visuales no deseadas. Asimismo, se diseñaron y aplicaron técnicas específicas para la obtención de máscaras correspondientes a cada tabla en los pallets inspeccionados. Esta segmentación facilita el procesamiento individualizado de cada componente, cumpliendo así con el objetivo central de la investigación.

En síntesis, los hallazgos obtenidos destacan el logro de un sistema integral que aborda los desafíos asociados con la inspección automatizada de pallets en movimiento, proporcionando resultados precisos y en tiempo real. La combinación de la identificación de regiones de interés, el preprocesamiento eficiente y la segmentación de tablas ha contribuido significativamente a la mejora de la calidad y eficacia en la clasificación de pallets, consolidando así un avance sustancial en el campo de la automatización industrial.

5.2 Contribuciones

La presente investigación ha generado valiosas contribuciones que impactan directamente en la eficiencia y adaptabilidad de los procesos de inspección y clasificación de pallets. A pesar de no haber alcanzado la completa identificación de tablas con fallas, los logros obtenidos representan avances sustanciales en dos áreas clave: la agilización del proceso de creación de datasets etiquetados para abrir las puertas a técnicas como las redes neuronales, y también la implementación de un sistema modularizado.

En primer lugar, el diseño del sistema de inspección en tiempo real ha demostrado ser altamente beneficioso en la reducción significativa del tiempo necesario para la obtención de imágenes de un pallet. La capacidad de identificar regiones de interés de manera dinámica, incluso en movimiento, ha simplificado considerablemente la tarea de recopilar datos relevantes para el entrenamiento de modelos de aprendizaje automático. Esta eficiencia se traduce en un aumento significativo de la productividad y una aceleración del desarrollo de sistemas de clasificación.

En segundo lugar, la implementación de un sistema modularizado ha abierto la puerta a la mejora continua y la adaptabilidad del modelo de clasificación. La capacidad de modificar y actualizar módulos específicos sin afectar la integridad del sistema general brinda la flexibilidad necesaria para responder a los cambios en los requisitos y demandas del proceso de inspección. Este enfoque modular no sólo facilita futuras mejoras en la identificación de tablas con fallas, sino que también destaca la importancia de la robustez del sistema en lugar de la velocidad como factor determinante.

En conclusión, las contribuciones de esta investigación no sólo se centran en los resultados específicos logrados hasta el momento, sino que también abren perspectivas prometedoras para el desarrollo continuo y la adaptabilidad en el ámbito de la inspección automatizada de pallets. La combinación de eficiencia en la creación de datasets y la modularidad del sistema sienta las bases para alcanzar mayores tasas de precisión y robustez en futuras implementaciones.

5.3 Limitaciones

Una de las limitaciones destacadas durante el desarrollo de esta investigación fue la carencia de un dataset robusto que permitiera poner a prueba de manera exhaustiva cada uno de los módulos creados. Aunque se realizaron esfuerzos para capturar imágenes representativas de pallets, la naturaleza multclasificación del problema complicó la obtención de datos que abarcaran de manera equitativa las diversas categorías de pallets y sus diferentes estados, como rotos, en buen estado o reparables. Esta limitación impactó la capacidad del sistema para generalizar eficazmente a situaciones diversas, lo que representa una oportunidad de mejora en futuras investigaciones.

Otra limitación identificada se relaciona con la falta de un enfoque profundo en la identificación única de los tacos en los pallets. Aunque el sistema aborda en gran medida la inspección y clasificación de las tablas, se reconoce que el análisis específico de los tacos y su conteo de fallas no ha sido abordado de manera exhaustiva. Explorar a fondo esta dimensión sería esencial para obtener una evaluación completa del estado de los pallets y representa una vía futura de investigación.

5.4 Futuras Investigaciones

Para superar las limitaciones señaladas, se propone la realización de futuras investigaciones centradas en la obtención de un dataset más completo y diverso. Este esfuerzo permitiría una validación más rigurosa del sistema y su capacidad para adaptarse a diversas condiciones y categorías de pallets. Además, se sugiere abordar específicamente la identificación de tacos, lo que abriría nuevas posibilidades para el análisis detallado y el conteo de fallas en esta parte crucial de la estructura del pallet.

Asimismo, se vislumbra la oportunidad de aprovechar al máximo el potencial de la inteligencia artificial mediante el etiquetado eficiente de datasets. Esta iniciativa no sólo mejoraría la calidad de los datos de entrada, sino que también posibilitaría el uso de técnicas avanzadas de aprendizaje automático, allanando el camino para sistemas más autónomos y eficientes. La investigación en esta dirección podría representar un paso fundamental hacia la automatización completa de la clasificación, liberando recursos humanos para tareas más estratégicas.

A partir de aquí se reconoce que el módulo de detección de fallas sigue siendo un desafío en nuestro proyecto. Sin embargo, gracias a la implementación actual, se ha logrado una notable disminución en el tiempo y esfuerzo necesarios para la creación de un conjunto de datos etiquetado. Este avance abre la puerta a nuevas oportunidades, especialmente en el ámbito de las técnicas de entrenamiento de máquinas.

En este contexto, proponemos explorar diversas técnicas de entrenamiento, tanto supervisado como no supervisado, para mejorar la capacidad de nuestro sistema en la detección de posibles fallas. Una opción prometedora que planteamos es la adopción de active learning, una técnica que permite mejorar la eficiencia del modelo al seleccionar de manera inteligente las instancias más informativas para la expansión del conjunto de datos. Esto no sólo optimizará la precisión del modelo, sino que también reducirá aún más el esfuerzo manual requerido en la recopilación y etiquetado de datos. En última instancia, estas mejoras contribuirán a perfeccionar nuestro sistema de inspección y clasificación de pallets, fortaleciendo su capacidad para abordar desafíos futuros de manera más efectiva.




Figure 5.1: Propuesta Active Learning.

En aras de fortalecer la robustez de nuestro sistema de inspección y clasificación de

pallets, proponemos la implementación de un módulo de confianza que evalúe la certeza de las predicciones realizadas por el modelo. Este componente adicional permitirá cuantificar el nivel de seguridad asociado con cada clasificación, expresado mediante un porcentaje de confianza. En situaciones donde el modelo exhiba un grado de certeza considerablemente bajo, proponemos establecer un mecanismo de intervención humana. En este escenario, se activaría la participación de un experto que, de manera manual, revisaría y etiquetaría la imagen en cuestión. Esta intervención no sólo actuará como un salvaguarda ante posibles errores, sino que también servirá como un valioso aporte para el proceso de aprendizaje del modelo, contribuyendo a mejorar su precisión a largo plazo. La sinergia entre la evaluación de confianza y la intervención experta se traducirá en un sistema más fiable y adaptable, capaz de enfrentar desafíos con mayor eficacia y confianza en su rendimiento.

En conclusión, la superación de estas limitaciones y la exploración de las futuras direcciones propuestas contribuirán a fortalecer y perfeccionar el sistema desarrollado, avanzando hacia soluciones más integrales y adaptables en el ámbito de la inspección automatizada de pallets.

References

- Benbarrad, T., Salhaoui, M., Kenitar, S. B., & Arioua, M. (2021). Intelligent machine vision model for defective product inspection based on machine learning. *Journal of Sensor and Actuator Networks*, 10(1). Retrieved from <https://www.mdpi.com/2224-2708/10/1/7> doi: 10.3390/jsan10010007
- Innocheck pks dr pallet checker. (2024). <https://www.khs.com/en/products/machines-equipment/detail/innocheck-pks-dr-pallet-checker>. (Accessed: 2024-01-03)
- Ireri, D., Belal, E., Okinda, C., Makange, N., & Ji, C. (2019). A computer vision system for defect discrimination and grading in tomatoes using machine learning and image processing. *Artificial Intelligence in Agriculture*, 2, 28-37. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2589721719300194> doi: <https://doi.org/10.1016/j.aiia.2019.06.001>
- Jiang, J., & Wong, W. (2018). 1 - fundamentals of common computer vision techniques for textile quality control. In W. Wong (Ed.), *Applications of computer vision in fashion and textiles* (p. 3-15). Woodhead Publishing. Retrieved from <https://www.sciencedirect.com/science/article/pii/B9780081012178000014> doi: <https://doi.org/10.1016/B978-0-08-101217-8.00001-4>
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., ... Girshick, R. (2023). *Segment anything*.
- Kumar Sahoo, S., Sharma, M., & Choudhury, B. (2019, 01). A dynamic bottle inspection structure. In (p. 873-884). doi: 10.1007/978-981-10-8055-5_77
- Liqun, W., Jiansheng, W., & Dingjin, W. (2020, jan). Research on vehicle parts defect detection based on deep learning. *Journal of Physics: Conference Series*, 1437(1), 012004. Retrieved from <https://dx.doi.org/10.1088/1742-6596/1437/1/012004> doi: 10.1088/1742-6596/1437/1/012004

- SICK Sensor Intelligence. (2024). *Pallet classification system: Quality control systems*. https://cdn.sick.com/media/docs/2/22/022/operating_instructions_pallet_classification_system_quality_control_systems_en_im0105022.pdf. (Accessed: 2024-01-03)
- Sistema de inspección de palés*. (2024). <https://www.sidel.com/es/paletizado-y-despaletizado/manipulacion-de-pales/sistema-de-inspeccion-de-pales-pd-452>. (Accessed: 2024-01-03)
- Wang, J., Fu, P., & Gao, R. X. (2019). Machine vision intelligence for product defect inspection based on deep learning and hough transform. *Journal of Manufacturing Systems*, 51, 52-60. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0278612519300111> doi: <https://doi.org/10.1016/j.jmsy.2019.03.002>
- Zhao, X., Ding, W., An, Y., Du, Y., Yu, T., Li, M., ... Wang, J. (2023). *Fast segment anything*.