

# UNIVERSIDAD DE SONORA DIVISIÓN DE INGENIERÍA



## POSGRADO EN INGENIERÍA INDUSTRIAL MAESTRÍA EN INGENIERÍA EN SISTEMAS Y TECNOLOGÍA

DESARROLLO DE UN SISTEMA BASADO EN VISIÓN ARTIFICIAL  
PARA LA EVALUACIÓN DE LA CALIDAD EN EL ENSAMBLE DE  
CONECTORES EN BOLSAS DE AIRE AUTOMOTRICES

# T E S I S

PRESENTADA POR

**EDUARDO RODARTE LEYVA**

Desarrollada para cumplir con uno de los  
requerimientos parciales para obtener  
el grado de Maestro en Ingeniería

DIRECTOR DE TESIS  
DR. VICTOR HUGO BENITEZ BALTAZAR

HERMOSILLO, SONORA, MÉXICO.

MARZO 2021

# Universidad de Sonora

Repositorio Institucional UNISON



“El saber de mis hijos  
hará mi grandeza”



Excepto si se señala otra cosa, la licencia del ítem se describe como openAccess



"El saber de mis hijos  
hará mi grandeza"

Hermosillo, Sonora a 11 de enero de 2021

## EDUARDO RODARTE LEYVA

Con fundamento en el artículo 66, fracción III, del Reglamento de Estudios de Posgrado vigente, otorgamos a usted nuestra aprobación de la fase escrita del examen de grado, como requisito parcial para la obtención del Grado de Maestro en Ingeniería: Ingeniería en Sistemas y Tecnología.

Por tal motivo este jurado extiende su autorización para que se proceda a la impresión final del documento de tesis: **DESARROLLO DE UN SISTEMA BASADO EN VISIÓN ARTIFICIAL PARA LA EVALUACIÓN DE LA CALIDAD EN EL ENSAMBLE DE CONECTORES EN BOLSAS DE AIRE AUTOMOTRICES** y posteriormente efectuar la fase oral del examen de grado.

ATENTAMENTE

Dr. Victor Hugo Benitez Baltazar  
Director de tesis y Presidente del jurado

Dr. Jesús Horacio Pacheco Ramírez  
Secretario del Jurado

Dra. María Elena Anaya Pérez  
Vocal del Jurado

Dr. Victor Manuel Herrera Jiménez  
Vocal del Jurado



Hermosillo, Sonora, México, a 21 de diciembre de 2020

**EDUARDO RODARTE LEYVA**

Con fundamento en el artículo 66, fracción III, del Reglamento de Estudios de Posgrado de la Universidad de Sonora, otorgo a usted mi aprobación de la fase escrita del examen profesional, como requisito parcial para la obtención del Grado de Maestro en Ingeniería: Ingeniería en Sistemas y Tecnología.

Por tal motivo, como sinodal externo y vocal del jurado, extiendo mi autorización para que se proceda a la impresión final del documento de tesis: **DESARROLLO DE UN SISTEMA BASADO EN VISIÓN ARTIFICIAL PARA LA EVALUACIÓN DE LA CALIDAD EN EL ENSAMBLE DE CONECTORES EN BOLSAS DE AIRE AUTOMOTRICES** y posteriormente efectuar la fase oral del examen de grado.

ATENTAMENTE

DR. LUIS CARLOS FÉLIX HERRÁN  
INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY  
Sinodal Externo y Vocal del Jurado

## RESUMEN

Se presenta una metodología para el desarrollo de un clasificador por medio de visión artificial utilizando redes neuronales convolucionales. Este clasificador complementado con la capa física compuesta por un sistema de adquisición y elementos localizadores fue utilizado para la clasificación de conectores de bolsas de aire en una línea de producción de autos. El propósito de esta implementación es el de detectar los defectos en la línea de producción y disminuir la cantidad de piezas defectuosas que salen de la misma.

La implementación se realizó en una empresa proveedora de puertas y paneles para autos tipo sedán y fue realizada durante el periodo de julio de 2019 a diciembre de 2019. Se analizaron vehículos de dos marcas, cada uno con tres conectores en el área de interés. Estos conectores podrían estar en buen o mal estado de conexión. En los seis tipos de conectores analizados los defectos pueden ser apreciados a simple vista por lo que se determino era viable analizarlos por medio de visión artificial.

El sistema clasificador se implementó utilizando una arquitectura de redes neuronales convolucionales la cual fue elegida entre las diferentes opciones de arquitecturas neuronales por su desempeño en el análisis de imágenes. Este modelo fue entrenado con imágenes etiquetadas y pre procesadas de conectores en buen y mal estado, de acuerdo con lo establecido en metodologías existentes para el entrenamiento de redes neuronales.

Los elementos localizadores fueron diseñados y fabricados utilizando herramientas CAD/CAM y siguiendo metodologías preestablecidas para el diseño de herramientas localizadoras y principio de diseño mecánico para manufactura. La repetibilidad y precisión de este sistema fueron evaluados de manera que se asegure el buen funcionamiento del sistema en general.

El algoritmo fue primeramente evaluado a nivel prototipo fuera de la línea de producción entrenando y validando con conjuntos de imágenes independientes hasta llegar a un nivel de precisión aceptable. Posteriormente se probó en línea durante 5 meses durante los cuales los datos fueron recopilados y analizados en un estudio.

Los resultados del estudio arrojaron que el sistema tiene una confiabilidad aceptable para su uso en la industria automotriz, logrando una reducción del tiempo de inspección y teniendo un impacto significativo positivo en el número de reportes que el proveedor recibe de su cliente en cuanto a piezas con defectos. Se determinó entonces que para futuros proyectos de monitoreo inteligente de la calidad se puede considerar el uso de sistemas de visión artificial entrenados por medio de redes neuronales para evaluar componentes y crear un registro de las piezas analizadas para una futura consulta y diagnóstico.

# ABSTRACT

The following document presents a methodology for the development of an image classifier utilizing computer vision utilizing a convolutional neural network. This classifier is aided by the physical layer of the system which is composed of hardware to reference the acquisition system to the actual part for inspection, which is a series of electric connectors for airbags in an assembly line. The purpose of this implementation is to implement in-line defect detection and by doing that lowering the number of defective parts that leave the production line.

The project was implemented on a production line of a door and panel supplier during the period of July 2019 and December 2019. Two models of cars were analyzed each having the three electrical connectors in the ROI. On the six analyzed connectors a defective connection could be diagnosed visually so it was determined that a computer vision-based solution might be viable.

The classifier was implemented utilizing a convolutional neural network architecture, which was chosen due to its performance towards solving image analysis problems. The model was trained using preprocessed tagged images of connectors. The images fed to the system represented connectors of both defective and good connections.

The positioning elements were designed and fabricated utilizing CAD/CAM tools for mechanical design as well as following established methodologies for the design of locating elements and positioning tools as well as DFMA techniques. The repeatability and precision of the system were evaluated as to ensure the adequate performance of the system in general.

The algorithm was first evaluated as a prototype off-site and validated with previously acquired datasets until an acceptable precision was achieved. After a satisfactory model was trained the system was tested online for 5 months during which more data was compiled and analyzed.

The results of this study indicate that the performance of such system has an acceptable performance for the automotive industry standards, achieving reductions in inspection time and having a significant reduction in defective parts being reported on the next link of the supply chain. It was determined then that for future IQM projects it would be viable to consider computer vision systems based on CNN classification methods.

# **AGRADECIMIENTOS**

A mi esposa por su apoyo y compañía durante todo este proceso.

A mis padres por sus palabras de aliento y haberme apoyado hasta esta etapa de mi vida.

A mi director de tesis Dr. Víctor H. Benítez por tener la paciencia y dedicación para cumplir con este proceso.

A las empresas Moretech y Delta Technology por abrir sus puertas para el desarrollo de este proyecto.

Al coordinador del posgrado, Dr. Alonso Pérez por acompañarnos durante el proceso.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) y al Programa de Fortalecimiento de la Calidad Educativa (PFCE) por su apoyo económico brindado en mi estudio de posgrado.

# ÍNDICE GENERAL

RESUMEN .....	i
ABSTRACT .....	iii
AGRADECIMIENTOS .....	v
ÍNDICE GENERAL .....	vi
ÍNDICE DE FIGURAS .....	ix
ÍNDICE DE TABLAS .....	xii
1. INTRODUCCIÓN .....	1
1.1. Presentación .....	1
1.2. Planteamiento del problema.....	3
1.3. Objetivo general .....	3
1.4. Objetivos específicos .....	4
1.5. Hipótesis .....	4
1.6. Alcances y delimitaciones .....	4
1.7. Justificación.....	4
2. MARCO DE REFERENCIA .....	6
2.1. MANEJO INTELIGENTE DE LA CALIDAD (IQM) .....	6
2.2. Visión por computadora .....	6
2.2.1. Visión artificial acelerada por GPU .....	7
2.2.2. Evolución de visión artificial .....	8
2.3. Deep learning.....	8
2.4. Redes Neuronales.....	9
2.5. Estudios Previos .....	10

3. METODOLOGIA.....	13
3.1. Inmersión .....	14
3.1.1. Análisis de situación actual.....	15
3.1.2. Identificación de errores .....	15
3.1.3. Identificación de patrones.....	16
3.2. Diseño de posicionador mecánico .....	16
3.2.1. Selección de superficies de referencia .....	18
3.2.2. Evaluación de posiciones para cámara e iluminación .....	19
3.3. Adquisición de datos iniciales .....	19
3.3.1. Calibración de iluminación.....	20
3.3.2. Calibración de enfoque.....	21
3.3.3. Adquisición de datos para entrenamiento.....	23
3.4. Pre-Procesamiento de datos.....	24
3.4.1. Segmentación de imagen y etiquetado.....	25
3.4.2. Diseño de filtros para procesamiento inicial de imágenes .....	26
3.4.3. Corrección de brillo y contraste .....	27
3.4.4. Alineación .....	28
3.4.5. Reconocimiento tradicional.....	30
3.5. Entrenamiento de modelo .....	33
3.5.1. Crear el conjunto de datos.....	33
3.5.2. Seleccionar el tipo de modelo.....	34
3.5.3. Crear modelo.....	35
3.5.4. Entrenar modelo .....	36
3.5.5. Evaluación de modelo .....	37

3.5.6.	Visualizar función de pérdida.....	38
4.	IMPLEMENTACIÓN.....	40
4.1.	Inmersión .....	40
4.1.1.	Análisis de situación actual.....	40
4.1.2.	Identificación de errores .....	43
4.1.3.	Identificación de patrones.....	45
4.2.	Diseño de posicionador mecánico .....	46
4.2.1.	Evaluación de posiciones para cámara e iluminación .....	48
4.2.2.	Selección de superficies de referencia .....	52
4.3.	Adquisición de datos iniciales .....	56
4.3.1.	Adquisición de datos para entrenamiento.....	57
4.4.	Pre-procesamiento de datos .....	59
4.4.1.	Localización y segmentación.....	59
4.5.	Entrenamiento de modelo .....	60
4.5.1.	Importar conjunto de datos .....	61
4.5.2.	Seleccionar tipo de modelo .....	62
4.5.3.	Crear modelo.....	64
4.5.4.	Entrenar modelo .....	66
4.6.	Evaluación de modelo.....	68
5.	CONCLUSIONES RECOMENDACIONES Y TRABAJO FUTURO .....	76
6.	REFERENCIAS .....	77

# ÍNDICE DE FIGURAS

Figura 3-1 Metodología propuesta .....	13
Figura 3-2 Ejemplo de error que puede ser detectado (Keyence, 2019) .....	16
Figura 3-3 Seis grados de libertad (Erik K. Hendriksen, 2010).....	18
Figura 3-4 Distancia de trabajo (WD) (Keyence, 2019).....	21
Figura 3-5 Efecto sobre la imagen izq. apertura cerrada, der. apertura abierta (Keyence, 2019).....	22
Figura 3-6 Condiciones del experimento de apertura (Keyence, 2019) .....	22
Figura 3-7 Calibración de enfoque (Keyence, 2019) .....	23
Figura 3-8 Buen enfoque contra mal enfoque(Keyence Corporation, 2016) .....	23
Figura 3-9 Metodología para segmentación (Qiao, Truman y Sukkarieh, 2019) ...	25
Figura 3-10 Pasos generales para diseñar una aplicación de visión (National instruments, 2004).....	25
Figura 3-11 Ejemplo de segmentación de instancias (Santos et al., 2020).....	26
Figura 3-12 Ejemplos de corrección de brillo (Keyence, 2019) .....	27
Figura 3-13 Filtro dinámico de iluminación (Keyence Corporation, 2016) .....	28
Figura 3-14 Imagen de referencia (Vaidya y Gandhe, 2019) .....	28
Figura 3-15 Imagen secundaria (Vaidya y Gandhe, 2019).....	29
Figura 3-16 Cuatro algoritmos de alineación de imágenes (Vaidya y Gandhe, 2019) .....	29
Figura 3-17 Corrección de alineación (Keyence Corporation, 2016).....	30
Figura 3-18 Pasos para desarrollar un segmentador tradicional (National instruments, 2004).....	31
Figura 3-19 Imagen de referencia vs imagen de inspección 1) área de búsqueda para el sistema de coordenadas 2) bordes del objeto 3) origen del sistema de coordenadas 4) área de medición o interés (National instruments, 2004) .....	32
Figura 3-20 Dos regiones de búsqueda definidas en una misma imagen(National instruments, 2004).....	33
Figura 3-21 Seudocódigo para creación de modelo.....	36

Figura 3-22 Pasos para entrenamiento del modelo.....	36
Figura 3-23 Visualización de topografía de función de pérdida de una red neuronal tipo Resnet (ankur6ue, 2019).....	38
Figura 3-24 Efecto sobre la topografía de incluir conexiones de salto en la red (Li et al., 2018) .....	39
Figura 4-1 Conector tipo SRS característico (Arpe, 2013) .....	42
Figura 4-2 Elementos principales del conector (leda, 2014) .....	42
Figura 4-3 Conector izquierdo, perteneciente a la marca A comparativa: conectado incorrectamente (izq.) vs correctamente (der.).....	43
Figura 4-4 Conector izquierdo, perteneciente a la marca A comparativa: conectado tipo semi-crimpado (izq.) vs correctamente (der.) .....	44
Figura 4-5 Diseño del sistema patentado para asegurar la conexión(leda, 2014)	44
Figura 4-6 Patrón de movimiento de botón con respecto a la carcasa.....	45
Figura 4-7 Vista general del panel de instrumentos (el área a inspeccionar se muestra en blanco).....	46
Figura 4-8 Diagrama de vista frontal de la estación .....	47
Figura 4-9 Elementos para prueba de primera iteración (izq) gimbal y (der) trípode .....	48
Figura 4-10 Iteración 1 del sistema de captura .....	48
Figura 4-11 Visualización de planos evaluados inicialmente .....	49
Figura 4-12 Versión 2 de posicionador, impreso en 3D .....	50
Figura 4-13 Orientación superior, izq. clip conectado, der. clip desconectado.....	51
Figura 4-14 Orientación superior izquierda .....	51
Figura 4-15 Orientación frontal.....	52
Figura 4-16 Versión dos anclada a un perfil tubular recto .....	53
Figura 4-17 Superficies de referencia en rojo, superficies de candado en amarillo .....	54
Figura 4-18 Versión 3 con superficie de referencia y mecanismo referenciado a la misma.....	55
Figura 4-19 Elemento mecánico final en acero .....	55

Figura 4-20 Elemento de referencia en posición .....	56
Figura 4-21 Orientación de prueba (foto de referencia) .....	56
Figura 4-22 Orientación de prueba (referencia de iluminación baja).....	57
Figura 4-23 Conector con región de búsqueda, patrón y orientación indicadas....	59
Figura 4-24 Estructura de base de datos .....	61
Figura 4-25 Visualización de la red en estilo Alexnet.....	64
Figura 4-26 Visualización de las 3 capas finales de un modelo de 30 nodos .....	66
Figura 4-27 Visualización de las 3 capas con pesos de conexión.....	67
Figura 4-28 Dispersión 3D de conectores antes de agrupar .....	71
Figura 4-29 Dispersión de conectores antes de agrupar en XY .....	71
Figura 4-30 Gráficos de control.....	72
Figura 4-31 Marca 1 conector medio.....	73
Figura 4-32 Marca 1 conector derecho .....	74
Figura 4-33 Marca 1 conector izquierdo.....	74
Figura 4-34 Marca 2 conector derecho cuando es mostrado marca 1 .....	75

## ÍNDICE DE TABLAS

Tabla 4-1 Conectores en buen estado y en falla .....	58
Tabla 4-2 Variación en geometría y color entre marcas .....	58
Tabla 4-3 Regiones de búsqueda y mascararas aplicadas .....	60
Tabla 4-4 Arquitectura de red final .....	63
Tabla 4-5 Resultados de precisión generales .....	69
Tabla 4-6 Precisión clasificando conectores en buen estado.....	69
Tabla 4-7 Precisión clasificando conectores en mal estado.....	70

# 1. INTRODUCCIÓN

En algunas ocasiones, a pesar de los esfuerzos de una empresa con el fin de evitar defectos en su producción, estos ocurren. Idealmente, en el caso de generar un defecto el mismo debiera ser identificado y no llegar al cliente final. La identificación oportuna de defectos es crítica para aquellas empresas en las que la seguridad de una persona pueda estar en riesgo si el producto se encuentra defectuoso.

El presente capítulo abarca la descripción de la problemática estudiada en este trabajo de tesis, así como el entorno donde se da la misma. Además, se presentan los objetivos y la hipótesis planteada.

## 1.1. Presentación

El proyecto se llevó a cabo en una empresa integradora. La compañía se dedica a la automatización e integración de sistemas para la industria. El cliente final de dicha integradora en este proyecto en particular es un proveedor Tier 1 de puertas y paneles para autos tipo sedán.

En el producto analizado, un panel de instrumentos, el cliente realiza un proceso de colocación de conectores para bolsas de aire se realiza de forma manual utilizando dos operadores. Dicho proceso está constituido por la colocación de tres conectores tipo macho en sus contrapartes tipo hembra del módulo de bolsa de aire; la fijación de los conectores se finaliza oprimiendo manualmente los clips de seguridad que cada uno tiene. En la línea de producción de paneles, al proceso de instalación le sigue una etapa de validación de los tres conectores de manera manual; los dos procesos ocupan tres estaciones de trabajo para realizarse. Dos de los conectores cumplen el propósito de asegurar que la bolsa se encuentra en buen estado por medio de un monitoreo constante. En caso de un accidente el tercer conector se utiliza para accionar la detonación del contenido de la bolsa.

Una falla en este sistema de seguridad puede tener repercusiones serias para la empresa y el usuario final; por ejemplo, en el caso de que un vehículo con conector aplicado de forma inadecuada se vea involucrado en una colisión, y éste no active la bolsa de aire correctamente. Anteriormente, en una de las estaciones que compone el proceso actual, se contaba con un sistema de validación por visión. Dicho sistema fue desinstalado en junio de 2018 por no cumplir con las expectativas de la empresa en cuanto a su confiabilidad y facilidad de uso.

A pesar de los métodos de validación con los que cuenta la línea actualmente, existen casos registrados de producto que llega a la siguiente etapa presentando defectos. Entre los defectos registrados se incluyen bolsas de aire con conectores faltantes, desconectados o incorrectamente conectados. El personal de calidad de la empresa determinó que las causas principales de estas fallas son conectores defectuosos y una mala ejecución del proceso por parte del operador. Como ya fue mencionado, la empresa ya había implementado un sistema de validación de posicionamiento de conectores por medio de visión artificial con anterioridad. Ese sistema no cumplió con las exigencias de la empresa. El personal de la empresa que estuvo involucrado en la evaluación del sistema mencionó que el sistema presentaba cuatro problemas serios por los cuales fue desinstalado, los cuales se enumeran a continuación:

- 1) No contaba con la confiabilidad requerida. La repetibilidad del sistema no era buena, podía ser mostrado un mismo conector y el grado de pertenencia de este a una clase variar considerablemente entre mediciones. No siempre detectaba la presencia de los conectores.
- 2) La robustez del sistema era deficiente. El sistema implementado era muy susceptible a cambios en la iluminación ambiental, por lo cual su desempeño variaba considerablemente durante el día. Además, las vibraciones por el funcionamiento normal de la línea tenían un impacto no deseado sobre la cámara.

- 3) La línea de vista entre la pieza y la cámara podía ser bloqueada por el operador. El sistema estaba montado en una posición fija a aproximadamente tres metros de distancia de la pieza. Este espacio podía ser ocupado por un operador durante la ejecución del proceso lo cual imposibilitaba la captura de imágenes.
- 4) Precisión o resolución insuficiente. A juicio del departamento de calidad la resolución del sistema implementado era insuficiente. Considerando que la falla ocurre en conectores de menos de  $5\text{cm}^2$  de área y la foto se toma a 3 metros de distancia esto es posible mas no necesariamente es el caso. Otras posibles explicaciones pueden ser una incorrecta selección de lente, iluminación o tiempo de exposición. Como resultado el sistema no alcanzaba a distinguir correctamente entre paneles con defectos y paneles sin defectos.

## **1.2. Planteamiento del problema**

El método actual de verificación no es suficiente para determinar los errores relacionados con la colocación correcta de los conectores de las bolsas de aire.

La empresa ha intentado disminuir, con diferentes grados de éxito, los ensambles con defectos por diferentes métodos, incluyendo: un sistema mecánico de validación, uno basado en visión artificial, y la inspección visual redundante por otro operador. La dirección de la empresa ha manifestado que ninguno de los métodos ha resuelto de manera satisfactoria la problemática planteada.

## **1.3. Objetivo general**

Desarrollar un sistema basado en visión artificial para validar el correcto posicionamiento de los conectores de un componente automotriz con el fin de disminuir los falsos positivos en un proceso de ensamble de paneles de instrumentos.

## **1.4. Objetivos específicos**

- Identificar las tecnologías y métodos existentes de inspección en el proceso para determinar las variables y seleccionar los posibles métodos a utilizar.
- Desarrollar un sistema capaz de aumentar la confiabilidad de la discriminación entre conectores colocados correctamente de aquellos que no cumplan las especificaciones del cliente.
- Implementar el sistema de reconocimiento de conectores en buen estado.
- Validar el sistema en condiciones de laboratorio y en línea de producción.

## **1.5. Hipótesis**

La implementación de un sistema de visión artificial usado por un operador en la línea de producción mejorará la detección de fallas respecto a la calidad del ensamble en los conectores de bolsa de aire.

## **1.6. Alcances y delimitaciones**

Para efectos del desarrollo del proyecto, únicamente se trabajará en el panel de instrumentos para un modelo de vehículo tipo sedán. La inspección se limitará a los tres conectores ubicados en la bolsa de aire del panel de instrumentos actualmente en producción. El sistema propuesto deberá incluir solo una estación de espacio, crear un registro de los subensambles analizados y los resultados de la validación. Se limitará a requerir que el operador posicione y remueva el sistema cuando sea necesario, excepto en el caso de inspecciones fallidas las cuales requerirán de acciones correctivas por parte del operador.

## **1.7. Justificación**

Actualmente existen casos reportados de paneles de instrumentos producidos en la planta del cliente final que salen de las instalaciones y son detectados como defectuosos en la siguiente etapa productiva, una vez que forman parte del

ensamble final. Identificar y resolver estos errores antes de que salgan de línea disminuye el número de retrabajos que el cliente final tiene que realizar, lo cual trae repercusiones económicas para la empresa proveedora. Además, identificar conectores que presentan fallas de conexión dentro de la línea de ensamble disminuiría la probabilidad de que un componente con falla llegue al usuario final del vehículo, lo cual ayudaría a evitar repercusiones para las empresas involucradas.

## **2. MARCO DE REFERENCIA**

En esta sección se presentan generalidades del manejo de calidad, diseño mecánico, visión por computadora, técnicas modernas de clasificación de imágenes y finalmente estudios previos.

### **2.1. Manejo inteligente de la calidad (iqm)**

Dada la madurez y el incremento de la competencia en el sector automotriz, las empresas del ramo deben mejorar la calidad de sus productos. Además de parámetros como el desempeño y precio, la calidad es un factor crítico. El manejo de la calidad en el sector automotriz involucra todo el proceso desde el diseño, surtido, manufactura y servicio postventa (Hanaysha, Hilman y Abdul-ghani, 2014).

Con los avances constantes en las tecnologías de la información, el IQM ha ganado tracción. El IQM se enfoca en aplicar técnicas de minería de datos para extraer conocimiento identificando relaciones de causa-efecto previamente no identificadas (Weckenmann, Akkasoglu y Werner, 2015).

Para que el IQM pueda ser implementado debidamente se deben contar con los sistemas de adquisición de datos confiables. Una de las maneras en que se puede lograr es automatizando la adquisición de los datos, en conjunto con sistemas de adquisición de alta precisión como las cámaras utilizadas en los sistemas de visión artificial (Xu, Dang y Munro, 2018).

### **2.2. Visión por computadora**

La visión por computadora es un subcampo de inteligencia artificial e informática que permite a las computadoras desarrollar una percepción visual de las entidades del mundo real (Szeliski, 2011).

En la industria la visión por computadora se aplica para el procesamiento de imágenes principalmente para la realización de inspecciones o asistencia de robots. Generalmente se realiza, en el ambiente industrial, bajo condiciones controladas de iluminación y ruido. Entre las áreas principales de aplicación son la detección de defectos, alineación y guía, medición, y verificación de ensamble (Malamas et al., 2003).

El campo de la visión por computadora se puede dividir en múltiples subáreas, cada una de las cuales se centra en información específica de los datos de la imagen: clasificación, localización, detección, segmentación semántica y segmentación de instancias (Janke, Castelli y Popovič, 2019).

Los sistemas de inspección equipados con cámaras para soluciones basadas en visión artificial se utilizan principalmente por su flexibilidad y precisión en procesos de manufactura automatizada. Aun cuando existe una amplia gama de aplicaciones y usos para dichos sistemas, la optimización, la robustez y la implementación todavía presentan un reto (Semeniuta et al., 2018).

### **2.2.1. Visión artificial acelerada por GPU**

Las tarjetas de video (Graphic Processing Unit, GPU por sus siglas en inglés) han encontrado un nicho en su aplicación a algoritmos de visión artificial dada su flexibilidad y alto desempeño. Para reducir el tiempo de procesamiento, los algoritmos pueden ser implementados en DSPs, FPGAs o GPUs. Las aplicaciones de procesamiento en GPUs han evolucionado de proveer resultados rápidamente a ser parte del desarrollo propio de los algoritmos de visión. Dadas sus prestaciones, en los últimos años se están construyendo algoritmos de visión que residen completamente dentro de las GPUs (HajiRassouliha et al., 2018).

El procesamiento en tiempo real posibilita a los desarrolladores a probar sus algoritmos y obtener retroalimentación en menor tiempo. Además, posibilita el procesamiento de grupos de datos grandes o de algoritmos de alta complejidad

como imágenes en un tiempo reducido, lo cual posibilita el desarrollo de sistemas de inspección del cien por ciento de partes en la industria (HajiRassouliha et al., 2018).

### **2.2.2. Evolución de visión artificial**

Los primeros investigadores dedicados al tema de visión artificial se enfocaron en desarrollar algoritmos para tareas de percepción visual. Esto incluía el reconocimiento de objetos dentro de una imagen para determinar si estaban presentes, la detección de objetos con el fin de localizar instancias de objetos de una clase y finalmente la compresión de escenarios para segmentar imágenes en áreas relevantes (Feng et al., 2019).

## **2.3. Deep learning**

Antes del dominio de las redes neuronales en la investigación de la visión por computadora, los algoritmos de clasificación utilizaban la salida de extractores de características, también llamados filtros, diseñados manualmente, para distinguir las clases (Lecun et al., 1998).

En un principio los algoritmos de visión podían reconocer objetos comunes, pero tenían dificultades con objetos naturales que contienen un infinito número de variaciones como árboles o animales. Para solventar esto, grupos de investigadores que confiaban en la capacidad de los sistemas de visión por computadora para lograr clasificaciones más complejas crearon “ImageNet”. Imagenet es un compendio de alrededor de 15 millones de imágenes divididas en 22,000 clases de objetos el cual fue creado con el fin de posibilitar el desarrollo del Deep learning para visión artificial.

La construcción de un extractor de características implicó décadas de arduo trabajo y experiencia para transformar los datos en bruto en una representación adecuada

o vector de características a partir del cual las máquinas de aprendizaje pueden clasificar los patrones en la entrada (Wason, 2018).

El aprendizaje profundo (Deep Learning) se ha convertido en los últimos años en la ciencia preferida para aprender estructuras complejas ocultas en grandes conjuntos de datos. Aplica algoritmos de retro propagación para determinar cómo debe alterar sus parámetros para calcular correctamente la salida en cada capa para crear sistemas inteligentes. La tecnología ha tenido éxito y gran impacto en dominios variados como el procesamiento de imagen, video, voz y audio (LeCun, Bengio y Hinton, 2015).

El concepto de aprendizaje profundo (Deep learning) proviene del estudio de redes neuronales artificiales (ANN). En resumen, la red de aprendizaje profundo es una red neuronal de múltiples capas. El número de capas de una red neuronal artificial generalmente consta de solo tres capas: una capa de entrada, una capa oculta y una capa de salida, mientras que la red de aprendizaje profundo es diferente de la red neuronal artificial. La red de aprendizaje profundo consta de múltiples capas ocultas, incluso decenas a cientos de capas. La estructura jerárquica de la red de aprendizaje profundo puede sintetizar características de bajo nivel capa por capa para obtener características avanzadas más abstractas, que pueden representar información como atributos, categorías y características de imágenes. La red de aprendizaje profundo puede ajustar el peso de las neuronas artificiales de la red mediante la función objetivo o la función de pérdida de los datos de la muestra, aprendiendo así el conocimiento de los datos de la muestra (Chen y Shi, 2019).

## **2.4. Redes Neuronales**

En los últimos años, ha habido muchos desarrollos en las arquitecturas de Redes Neuronales Convolucionales (CNN). La gran mayoría de estos avances se han realizado en las capas inferiores de la red neuronal, o todas hasta antes de las capas completamente conectadas. Poca investigación se ha enfocado a las capas

completamente conectadas. Los perceptrones multicapa (MLP) totalmente conectados son la opción de diseño más utilizada en las arquitecturas de red, con pocos cambios o modificaciones a esto (Janke, Castelli y Popovič, 2019).

Tanto las capas convolucionales como las completamente conectadas de una red neuronal aprenden sus “pesos” durante la fase de entrenamiento, y el error se propaga desde la salida a través de las capas completamente conectadas de regreso a las capas convolucionales. Debido a la naturaleza del proceso de aprendizaje, los perceptrones multicapa son la opción natural para las redes neuronales convolucionales (Janke, Castelli y Popovič, 2019).

Las redes neuronales convolucionales (CNN) están diseñadas para analizar datos con algún tipo de estructura u orden en el espacio. Un ejemplo son las imágenes, debido a que los datos que la conforman, los píxeles, tienen un orden en el espacio en particular. Las redes neuronales convolucionales se componen de una serie de filtros, que iteran a través de los datos, y producen una activación en cada posición de convolución. Las activaciones producen un mapa de características, que representa en qué porcentaje activaron los diferentes filtros los datos en esa región. Una particularidad de las redes neuronales convolucionales es que independientemente de dónde se encuentre una característica de una imagen, la red la detectará. Esto se debe a que el filtro se va deslizando por cada parte de la imagen y cada porción de la imagen tiene el mismo peso.

## **2.5. Estudios Previos**

Un sistema de inspección de calidad inteligente, en contraste con los métodos tradicionales, buscan utilizar herramientas computacionales como la visión por computadora para monitorear en tiempo real la calidad y tomar acciones en base a los resultados obtenidos. Existen casos documentados para una amplia gama de aplicaciones. Algunas utilizan sistemas de visión por computadora para analizar y

detectar si cada uno de los insumos que entran a la línea de proceso son aceptables o no (Xu, Dang y Munro, 2018).

Existen casos de estudio donde se logra realizar la clasificación de defectos y pseudo defectos con redes neuronales convolucionales en componentes electrónicos. La diferencia entre un defecto y un pseudo defecto es que mientras un defecto verdadero puede ser un problema de conexión o daño de pista, un pseudo defecto puede ser una mota de polvo o un poco de óxido. En este documento analizado se propuso un nuevo enfoque utilizando la arquitectura CNN de entradas múltiples para usar dos imágenes con iluminación diferente para evaluar el rendimiento de clasificación utilizando imágenes defectuosas de la placa de circuito electrónico. Usualmente otros enfoques necesitan las imágenes de referencia en dos condiciones de iluminación, mientras que el enfoque propuesto no requiere ambas.

La evaluación en los experimentos determinó que una CNN conectada alrededor de la capa de entrada proporciona la mayor precisión en la clasificación de defectos. El enfoque por medio de CNN se comparó contra una SVM y la CNN de múltiple entrada dio la mejor precisión de clasificación (Iwahori et al., 2018).

Otro caso es el de la empresa Kongsberg Automotive AS, un proveedor de Tier 1 del ramo automotriz ubicado en Noruega. KAS se dedica a la fabricación de productos para transferencia de fluidos distribuidos en dos marcas de producto, Raufoss ABC y Krtridge. KA utiliza un número considerable de sistemas de visión para tres categorías principalmente: Inspección de componentes individuales para presencia de defectos, inspección de proceso para verificar que no se introdujeron defectos en el ensamble e identificación de orientación de pieza para que se pueda estimar la posición de agarre. El principal problema al que se enfrentó KA es la variación de color e iluminación en sus procesos. Para solucionar esto, se le incorporó al sistema de visión un algoritmo de optimización para realizar ajustes automáticamente al sistema para tomar en cuenta variaciones sutiles (Semeniuta et al., 2018).

Un último caso de estudio es el realizado por la facultad de ingeniería mecánica en Malasia, en este, se desarrolló una herramienta para verificar la redondez de una pieza utilizando métodos sin contacto basados en una cámara y algoritmos de visión artificial. Como parte de la metodología desarrollaron un sistema para validar la calidad del sistema de visión en sí, obteniendo que los resultados del sistema de inspección sin contacto son confiables y suficientemente consistentes como para ser usados en un proceso de inspección en línea. La variación entre mediciones se mantuvo por debajo de los 0.11 mm por lo cual se consideró que es aceptable tomando en cuenta que la flecha tenía un diámetro nominal de 46 mm. En la imagen la diferencia representaba solo dos pixeles entre fotografías tomadas a la máxima velocidad de 800 pies por segundo (Ayub, Mohamed y Esa, 2014).

### 3. METODOLOGIA

Se propone una metodología la cual, considerando que el objetivo es detectar si los tres conectores del componente inspeccionado se encuentran en buen estado, deberá contemplar el diseño y fabricación de un elemento portador del sensor de visión y el diseño y entrenamiento de un algoritmo capaz de determinar el estado de los conectores. La metodología general se presenta en la Figura 3-1.

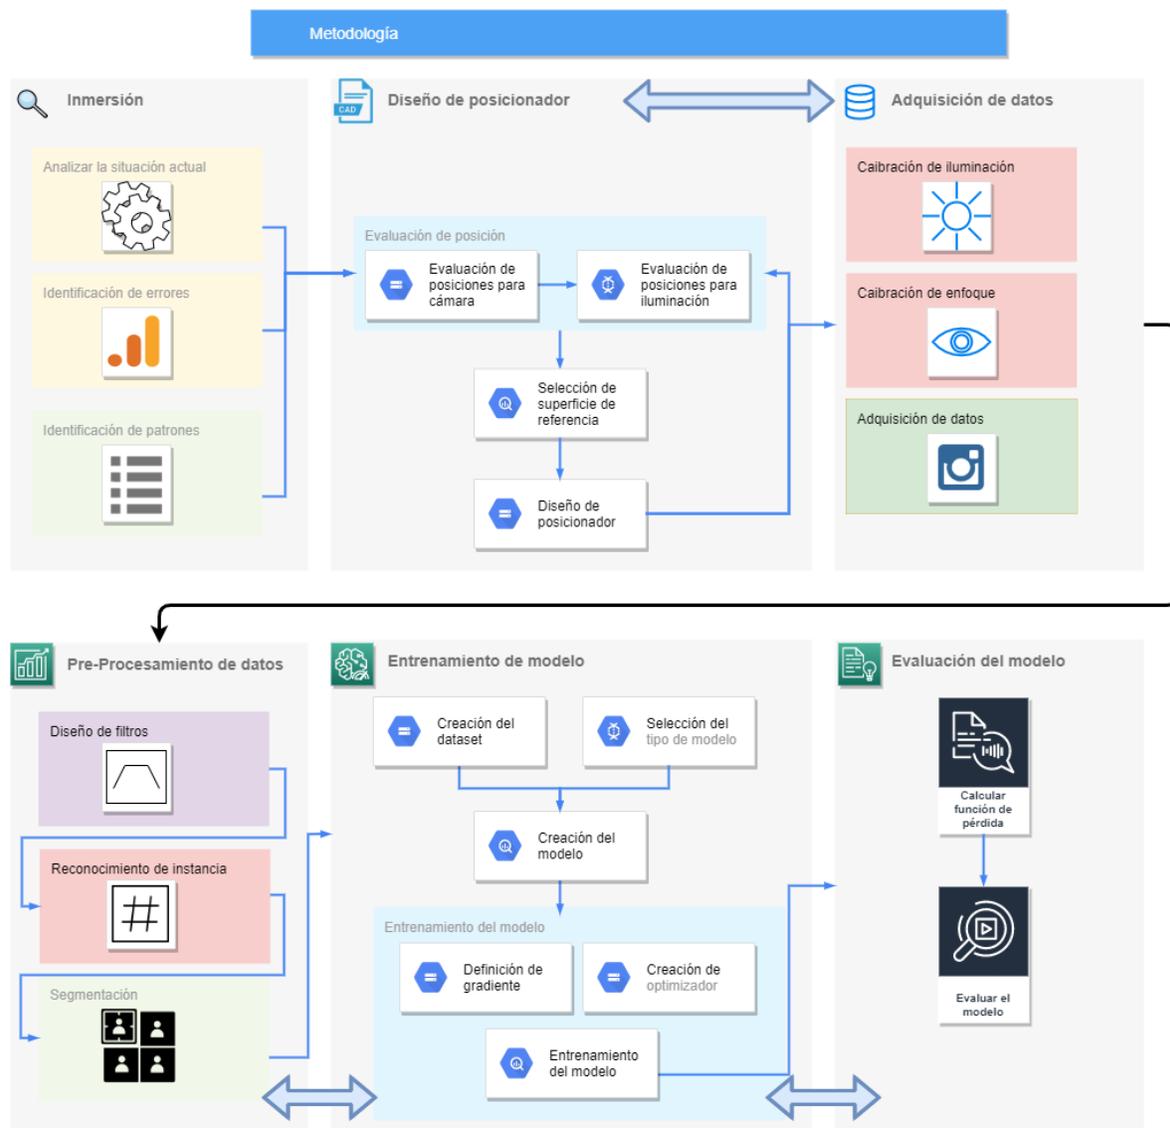


Figura 3-1 Metodología propuesta

La propuesta contempla el desarrollo de un sistema de visión artificial, el cual puede ser posicionado por el operador manualmente sobre la pieza a inspeccionar. Una vez que el dispositivo detecte que se encuentra en la posición correcta, el sistema deberá entonces accionar la cámara y el sistema de iluminación para realizar la captura de imagen. Dicha imagen será procesada en tiempo real y el algoritmo deberá, al analizar la foto, determinar si los tres conectores presentan fallas. La metodología está dividida en tres secciones principales, la primera engloba los primeros dos pasos y se basa principalmente en el análisis de la problemática y determinar la posición de la cámara e iluminación. Este paso se basa principalmente en documentación realizada por compañías dedicadas a sistemas de visión comerciales y literatura para el diseño de mecanismos posicionadores de diferentes autores. Los siguientes dos pasos que engloban la adquisición de datos y calibración de la imagen se basan en métodos propuestos por compañías dedicadas al desarrollo de sistemas de visión, tanto del punto de vista de hardware como de software. La tercera sección de la metodología que engloba los pasos 5 y 6 se basa en la documentación existente para el desarrollo de redes neuronales y clasificadores de imágenes.

### **3.1. Inmersión**

Se deberá seguir una secuencia de pasos con el fin de lograr los objetivos propuestos. El primero de los pasos descritos en la metodología es la inmersión, la cual comienza con entender el proceso a fondo. La inmersión comienza con realizar visitas a la empresa. Durante las visitas se recopila evidencia diversa sobre el proceso, la cual puede consistir en entrevistas al personal que opera la máquina, el personal que supervisa a los operadores y los ingenieros a cargo del proceso. Además de las entrevistas, se recopila evidencia fotográfica del proceso en operación, los defectos encontrados. Como complemento se pueden crear registros, en caso de que estos no existan, sobre la operación del proceso, analizando las piezas con defectos que son generadas, los tiempos de ciclo, el tipo

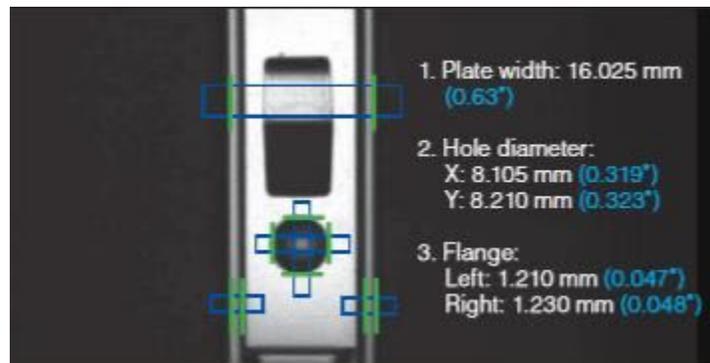
de piezas analizadas y las fallas que se presentan, entre otros datos pertinentes. Por último, se debe contar con acceso a un panel donde la pieza se monta y muestras de los conectores en buen y mal estado.

### **3.1.1. Análisis de situación actual**

Como fue mencionado anteriormente el primer paso de la inmersión es el análisis de la situación actual. Para realizar el análisis se deben mapear las operaciones del proceso, las diferentes entradas y los tipos de salidas que se pueden obtener. Realizar un análisis adecuado de la situación actual permitirá evaluar de mejor manera las mejoras del modelo con respecto a lo ya existente, así como permitir que el desarrollo se ejecute contemplando la realidad del entorno en primer lugar.

### **3.1.2. Identificación de errores**

Una vez realizado el análisis de la situación actual, incluyendo el levantamiento de encuestas, llenado de registros y recopilación de evidencia fotográfica, se pueden analizar los datos obtenidos con el fin de identificar los errores que se presentan en la línea. Se prevé que estos errores puedan ser detectados como desviaciones de medidas nominales por un sistema de visión por lo cual se deberá tener en cuenta que las características del objeto deben ser visibles. Un ejemplo de características que pueden ser medidas son las mediciones de borde que se muestran señaladas dentro de rectángulos en la figura 3-2, en las cuales el sistema detecta las transiciones de claro a oscuro y estima mediciones del área y puede compararlas contra una medida nominal.



**Figura 3-2** Ejemplo de error que puede ser detectado (Keyence, 2019)

El identificar en qué superficie se presentan estos errores ayudará en etapas posteriores al desarrollo tanto del posicionador mecánico como del algoritmo. Sabiendo además el tipo de errores que se presentan se podrá seleccionar el algoritmo más apropiado.

### 3.1.3. Identificación de patrones

Durante el análisis de los registros y errores podrían encontrarse patrones de importancia. Un ejemplo de patrón podría ser que los conectores con error se presenten más en una de las 3 posiciones con mayor recurrencia que en las otras dos, o que se produzcan más errores en el modelo 1 de vehículo que en el modelo 2. También se puede verificar el grado de influencia que tiene el operador sobre la ocurrencia de los errores o si existe una relación entre lotes de conectores del proveedor con la presencia de errores. Dependiendo de lo encontrado en el análisis, se puede realizar un estudio de agrupamiento o clasificación para determinar si existe relación entre los errores y algún factor en particular.

## 3.2. Diseño de posicionador mecánico

Un elemento importante para simplificar el diseño de un sistema de visión es el considerar la posición y orientación de la cámara relativa al punto o pieza a inspeccionar, es decir, definir un marco de referencia. En el caso de estudio

propuesto la cámara debe analizar un área ubicada dentro de un panel de instrumentos de un vehículo tipo sedán.

Para que la cámara realice su trabajo correctamente, los operadores deben posicionar la cámara con precisión y coherencia en relación con la parte a inspeccionar, parte tras parte. Para lograr esto, los localizadores deben asegurarse de que la pieza de trabajo esté correctamente referenciada y que el proceso sea repetible.

Referenciar una pieza es un proceso que consiste en el posicionamiento de la pieza de trabajo en relación con el posicionador mecánico, y el posicionador mecánico en relación con la cámara. La referencia de la pieza de trabajo al posicionador se realiza con localizadores.

Si el posicionador se coloca incorrectamente en una pieza, no se logrará la ubicación adecuada de la cámara con respecto a la pieza de inspección y la pieza se clasificará incorrectamente. Por lo tanto, en el diseño de un posicionador, se debe considerar y mantener simultáneamente la referencia de la pieza de trabajo y la cámara.

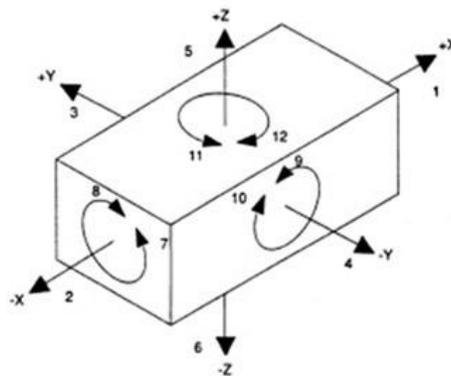
La "repetibilidad" es la capacidad del trabajador de producir piezas de manera consistente dentro de los límites de tolerancia, y está directamente relacionado con la capacidad de referencia de la herramienta. En este caso se refiere estrictamente a que tan repetible es la posición de la cámara con respecto a la pieza. La ubicación de la pieza de trabajo con respecto a la herramienta y de la herramienta a la cámara debe ser consistente. El sujetador de trabajo debe estar diseñado para acomodar las superficies de ubicación de la pieza de trabajo.

El punto de ubicación ideal en una pieza de trabajo es una superficie maquinada. Las superficies maquinadas permiten la ubicación desde un punto de referencia constante. Las superficies fundidas, forjadas, cortadas o inyectadas pueden variar mucho de una parte a otra y afectarán la precisión de la ubicación.

### 3.2.1. Selección de superficies de referencia

Una pieza de trabajo libre en el espacio puede moverse en un número infinito de direcciones. Para simplificar, este movimiento se puede dividir en doce movimientos direccionales, o "grados de libertad". Los doce grados de libertad deben restringirse para garantizar una referencia adecuada de una pieza de trabajo.

Como se muestra en la Figura 3-3, los seis grados de libertad se relacionan con los ejes centrales de la pieza de trabajo. Se pueden apreciar los tres grados axiales de libertad y los tres grados radiales de libertad. Los grados de libertad axial permiten el movimiento de traslación en ambas direcciones a lo largo de los tres ejes principales, que se muestran como X, Y y Z. Los grados radiales de libertad permiten el movimiento de rotación, tanto en sentido horario como antihorario, alrededor de los mismos tres ejes.



**Figura 3-3** Seis grados de libertad (Erik K. Hendriksen, 2010)

Los elementos que restringen el movimiento de una pieza de trabajo son los localizadores. Los localizadores deben ser lo suficientemente fuertes como para mantener la posición de la pieza de trabajo y resistir las fuerzas cortantes.

Los localizadores proporcionan un tope para la pieza de trabajo. Colocada contra el tope, la pieza de trabajo no puede moverse. Las abrazaderas, por otro lado, dependen solo de la fricción entre ellas y la superficie sujeta para sostener la pieza

de trabajo. Una fuerza suficiente podría mover la pieza de trabajo. Las abrazaderas solo están destinadas a sostener la pieza contra los localizadores.

### **3.2.2. Evaluación de posiciones para cámara e iluminación**

Se considera que el sistema de posicionamiento diseñado y fabricado en la etapa anterior tendrá contemplado un rango de ajuste para el posicionamiento tanto de la cámara, así como de la fuente de iluminación. El fin de esa decisión es el de realizar el muestreo en varias posiciones y evaluar que tan buenas son las posiciones con respecto a las demás.

Los factores por evaluar durante la etapa para seleccionar la posición adecuada son los siguientes:

1. Porcentaje de variación en la imagen entre un conector bueno y uno malo para cada conector analizado.
2. Calidad de la iluminación y el tipo de sombras y reflejos proyectados sobre las superficies de inspección.

### **3.3. Adquisición de datos iniciales**

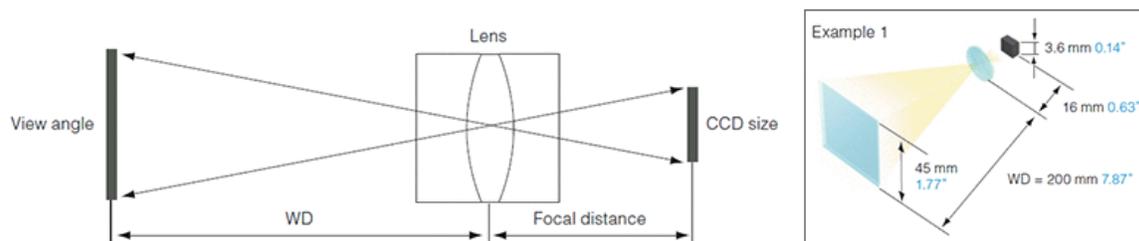
Una vez que se cuente con un sistema de posicionamiento referenciado a la pieza, el cual sea confiable y además se haya colocado la cámara y el sistema de iluminación en una posición adecuada, se procederá al muestreo de datos iniciales. Los datos muestreados servirán para entrenar y evaluar el modelo de manera rápida y repetible fuera de línea, así como realizar mejoras al algoritmo sin tener que interferir en el proceso de nueva cuenta. La calidad de los datos adquiridos es esencial para el correcto desarrollo del resto de las etapas por lo cual el proceso debe realizarse de una manera adecuada.

### **3.3.1. Calibración de iluminación**

La iluminación ambiental puede fluctuar dado que en las condiciones reales de operación la pieza se encuentra en movimiento, la luz del sol puede entrar por los tragaluces y el operador puede proyectar sombras sobre la pieza mientras se mueve por la estación. Con el fin de absorber las variaciones se debe calibrar la posición, intensidad y tipo de iluminación a utilizar de manera que la influencia de estos factores sea minimizada y, en consecuencia, se disminuya la variación que existe en las fotografías por la iluminación ambiental.

### 3.3.2. Calibración de enfoque

Un componente esencial para cualquier sistema de visión es el lente. El lente determina en gran medida la calidad de la imagen que se obtendrá, así como las aberraciones visuales a las que se tendrá que enfrentar el algoritmo. Uno de los parámetros más importantes a la hora de instalar un lente y calibrarlo es el enfoque. Una imagen capturada con un mal enfoque no conduce a un buen procesamiento y análisis. Una cámara con un solo lente cuenta con un foco, la distancia entre el foco y el centro óptico del lente se llama distancia focal. Existe una distancia optima entre el lente y el objeto a analizar dependiendo principalmente del tamaño del área que se desea analizar. Para calcular la distancia optima se requiere conocer el tamaño del sensor CCD, la distancia focal del lente y las dimensiones del área de trabajo deseada. Estos términos se muestran en la Figura 3-4.



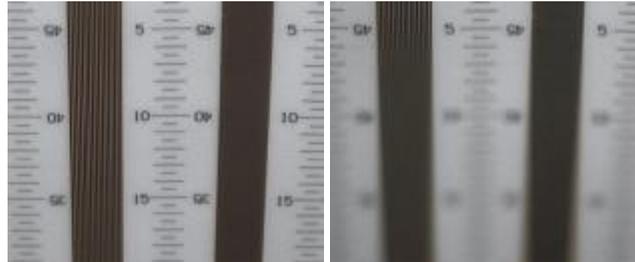
**Figura 3-4** Distancia de trabajo (WD) (Keyence, 2019)

La distancia de trabajo necesaria se puede calcular utilizando la siguiente expresión la cual nos indica que la proporción entre la distancia de trabajo y el ángulo de visión es igual a la proporción de la distancia focal y el tamaño del CCD:

$$WD : VA = FD : \text{Tamaño del CCD}$$

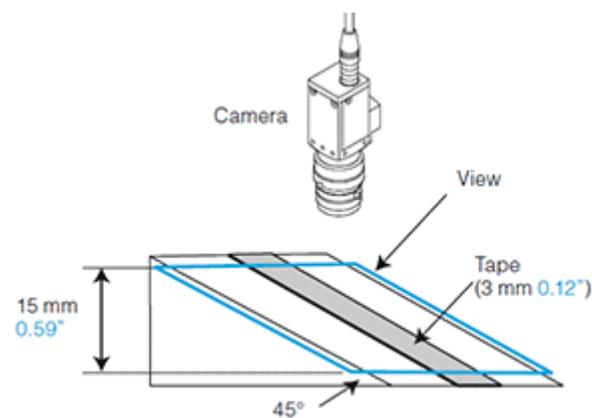
Una vez determinada la distancia de trabajo necesaria otro elemento importante para tener un buen enfoque es la apertura del lente. Por lo general cuando se desea enfocar una imagen con objetos que se encuentran a diferentes distancias del lente se debe considerar la profundidad de campo de este. Por lo general entre menor es la distancia focal la profundidad de campo es mayor, entre menor sea la apertura

del lente también la profundidad de campo será mayor y entre mayor sea la distancia entre el lente y el objeto la profundidad de campo será mayor. Considerando que para un lente dado solo la apertura puede ser modificada, se muestra, como ejemplo, el efecto que variar la apertura tiene sobre la imagen en la Figura 3-5.



**Figura 3-5** Efecto sobre la imagen izq. apertura cerrada, der. apertura abierta (Keyence, 2019)

Se puede apreciar que cuando la apertura se encuentra más cerrada se puede percibir mejor la imagen. En el experimento la cámara se encuentra posicionada como se detalla en la Figura 3-6 donde se puede apreciar que la cinta se encuentra sobre un plano inclinado y la parte inferior de la imagen por lo tanto se encuentra a mayor distancia de la cámara.



**Figura 3-6** Condiciones del experimento de apertura (Keyence, 2019)

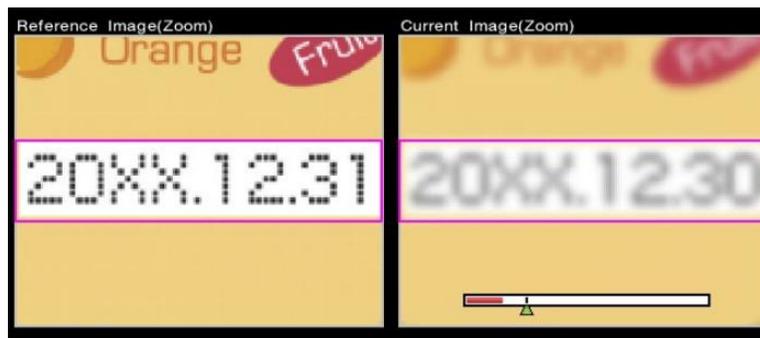
Conforme el objeto se acerca o aleja del foco se presentan distorsiones y pérdida de definición por estar fuera de foco. Un factor adicional que complica la situación es el hecho de que las piezas a analizar en algunos casos pueden no ubicarse en el mismo plano y esto dificulta la tarea de enfoque. Una imagen capturada utilizando un enfoque mal calibrado dificulta la tarea de detectar de manera consistente los

defectos presentes, independientemente del rendimiento o capacidades del procesador utilizado. En la Figura 3-7 se muestra la imagen de un vaso de papel con la misma iluminación, capturada desde la misma posición, pero variando el enfoque.



**Figura 3-7** Calibración de enfoque (Keyence, 2019)

Un ejemplo más notorio de un mal enfoque contra un buen enfoque puede apreciarse en la Figura 3-8 donde un mal enfoque dificulta la lectura de la etiqueta.



**Figura 3-8** Buen enfoque contra mal enfoque(Keyence Corporation, 2016)

### 3.3.3. Adquisición de datos para entrenamiento

Una adquisición de datos para entrenamiento consiste en la toma de muestras de fotografías en condiciones de operación; la cual debe realizarse una vez que los pasos anteriores como el diseño de la estructura mecánica (y su fabricación), la calibración de iluminación y la calibración de enfoque hayan sido terminadas. Se recomienda tomar la mayor cantidad de muestras posibles para contar con más información para realizar el entrenamiento y la evaluación del modelo.

Como complemento, se contempla la creación de una base de datos de las imágenes con datos que pudieran resultar relevantes en un futuro como el operador en turno, el turno en el que fue fabricada y el número identificador del panel.

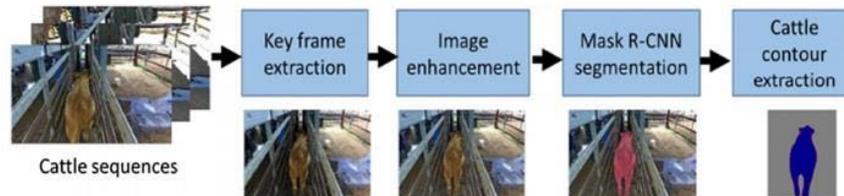
### **3.4. Pre-Procesamiento de datos**

Las imágenes adquiridas no pueden ser alimentadas directamente al modelo para entrenamiento. Estas deben pasar por una serie de procesos o filtros los cuales las preparan para que el modelo pueda utilizarlas. El preprocesamiento incluye filtros de corrección de orientación, segmentación, localización y etiquetado.

Para cumplir con el preprocesamiento primeramente todas las fotos deben pasar por una etapa de filtrado la cual tiene como objetivo homogenizar la iluminación, corregir la rotación de la imagen, corregir el error de posicionamiento y segmentar cada imagen en 3 distintas imágenes y aplicarles una etiqueta en el nombre dependiendo del estatus del conector.

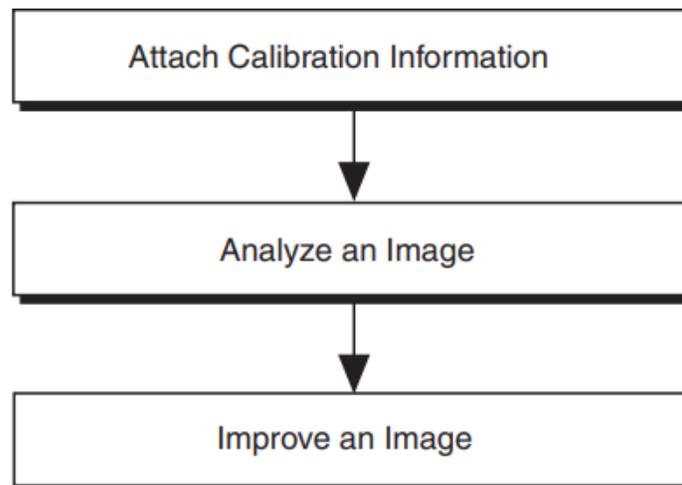
Existen para esta parte de la metodología tres elementos principales, primeramente un preprocesamiento tradicional basado en filtros estáticos, el cual está basado en la metodología y recomendaciones propuestas por la compañía Keyence, especializados en sistemas de visión artificial (Keyence, 2019). El segundo componente de la metodología está basado en filtros basados en machine learning para la segmentación de imágenes, según lo propuesto por (Qiao, Truman y Sukkarieh, 2019). En su artículo propone un sistema para extraer una imagen de un video, aplicarle un preprocesamiento y utilizar una R-CNN para segmentar la imagen, extrayendo así una nueva imagen. El primer paso es extraer de la serie de imágenes un key frame la cual es una imagen de referencia. La imagen de referencia posteriormente pasa por una etapa de preprocesamiento donde primeramente se trabaja sobre los niveles de iluminación y ruido para estandarizarlos. Una vez normalizada la imagen se aplica la R-CNN para realizar la generación de la máscara, en el caso analizado una máscara que indica la ubicación

de la imagen objetivo (una vaca). Posteriormente, para efectos del caso de estudio presentado, se extrae el contorno de la vaca y la información de color que contiene para ser utilizado en otra operación. La representación gráfica de la metodología de segmentación puede verse en la Figura 3-9.



**Figura 3-9** Metodología para segmentación (Qiao, Truman y Sukkarieh, 2019)

Por último, el tercer elemento en el que se basa la metodología es la secuencia de pasos mostrados en la Figura 3-10. del cual los pasos pertinentes al preprocesamiento serían los pasos 6, 7 y 8.

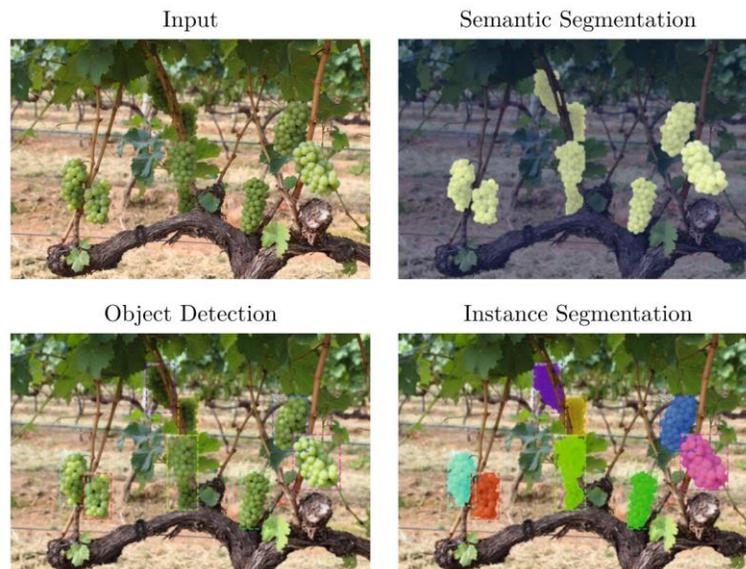


**Figura 3-10** Pasos generales para diseñar una aplicación de visión (National instruments, 2004)

### 3.4.1. Segmentación de imagen y etiquetado

Un elemento importante para el problema en cuestión, ya que se encuentran 3 conectores en una misma imagen, es la segmentación de instancias dentro de una imagen. Los algoritmos de segmentación de instancias son utilizados en otras aplicaciones de visión artificial para analizar la presencia de instancias de un objeto en una imagen y posteriormente reutilizar la información para otros procesos.

Un ejemplo de segmentación de instancias comparado con la entrada y algoritmos que en algunas ocasiones se pueden confundir con segmentación de instancias puede verse en la Figura 3-11.



**Figura 3-11** Ejemplo de segmentación de instancias (Santos et al., 2020)

Como puede apreciarse en la imagen superior izquierda marcada como input existen varios racimos de uvas verdes. En la imagen superior derecha se realiza una segmentación semántica, donde se detecta todo lo que es un racimo de uvas. En la imagen inferior izquierda se realiza una detección de objetos de acuerdo con algún patrón deseado. Por último, en la cuarta imagen se realiza lo que es una segmentación de instancias en la que se detecta no solo que existen ocho objetos en la imagen si no que estos son racimos de uvas independientes.

### 3.4.2. Diseño de filtros para procesamiento inicial de imágenes

El preprocesamiento es esencial para obtener imágenes de una calidad suficientemente alta para los propósitos que se desean. Las imágenes adquiridas por una cámara, aun cuando se tome en consideración el enfoque y la iluminación, no necesariamente son adecuadas para realizar un procesamiento inmediatamente. Para solventar este problema las imágenes usualmente son procesadas usando

filtros de imágenes de acuerdo con el uso final que se le dará a dichas imágenes. Esto puede incluir filtros que mejoren la claridad de las imágenes, discriminen entre elementos requeridos por la aplicación o eliminen el ruido.

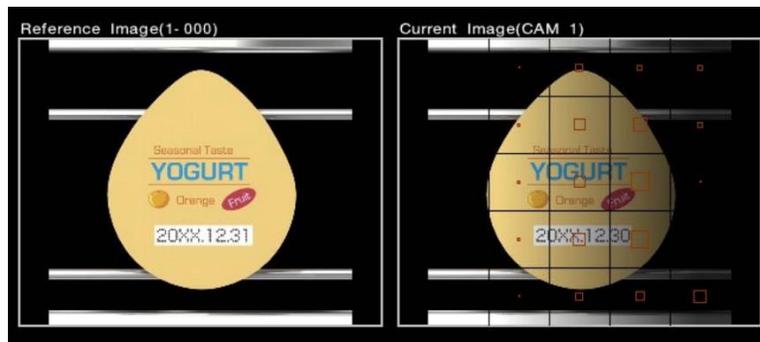
### 3.4.3. Corrección de brillo y contraste

Calibrar las imágenes con respecto al brillo es el proceso que consiste en ajustar las imágenes digitales para que los resultados sean más adecuados para la visualización o el posterior análisis de la imagen. En el caso de la Figura 3-12 se puede apreciar los efectos de una corrección de brillo y contraste, la aplicación de un filtro de corrección puede ser estático o dinámico dependiendo de la aplicación. Si se tiene una operación donde las condiciones de iluminación y operación controladas es deseable implementar un filtro estático el cual produzca resultados mas predecibles y con menos tiempo de procesamiento.



*Figura 3-12 Ejemplos de corrección de brillo (Keyence, 2019)*

Los filtros dinámicos deben tener una imagen de referencia que se desee utilizar para la corrección de la imagen. En el caso de la Figura 3-13 se muestra a la izquierda una imagen de referencia con los niveles de iluminación deseados y a la derecha un análisis del filtro dinámico previo a realizar la corrección de la iluminación. Los recuadros naranjas indican la diferencia entre el brillo esperado y encontrado en la imagen de acuerdo con la referencia y utilizan esto para realizar la corrección (Keyence Corporation, 2016).



**Figura 3-13** Filtro dinámico de iluminación (Keyence Corporation, 2016)

### 3.4.4. Alineación

En los problemas de inspección de componentes algo recurrente es el cambio de la orientación y posición relativa de los objetos a analizar. Para realizar la operación de corrección de alineación se deben conocer elementos clave de la imagen que ayudan a tener un punto de referencia con el cual corregir la posición entre ambas imágenes. Si se considera que se tiene de referencia la imagen de las vías de ferrocarril que se muestra en la Figura 3-14 sobre las cuales se quiere realizar una inspección y además se cuenta con la imagen mostrada en la Figura 3-15 como una segunda imagen de las mismas vías tomada con una orientación diferente se pueden apreciar los resultados de esta operación en acción.



**Figura 3-14** Imagen de referencia (Vaidya y Gandhe, 2019)



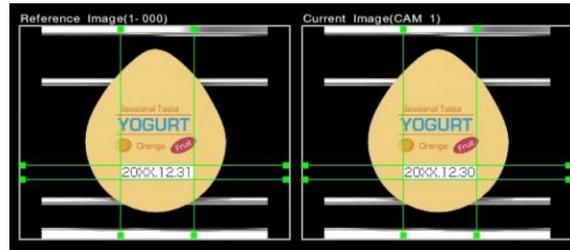
**Figura 3-15** Imagen secundaria (Vaidya y Gandhe, 2019)

Como se puede apreciar en ambas imágenes el punto al que la cámara fue enfocada es diferente, sin embargo, estas fotos fueron tomadas unos segundos de diferencia entre sí, por lo que las condiciones de iluminación y ambientales como la ubicación de los objetos no presenta variación significativa. En este caso se utiliza un algoritmo para la alineación híbrido que además deforma la imagen en base a patrones que reconoce entre las imágenes. Existen diferentes variantes de algoritmo, como las observadas en la Figura 3-16, pero lo que logran al final es una alineación entre las imágenes, en el caso del artículo analizado se proponen para realizar la operación de mosaico, pero para el caso de estudio propuesto en esta tesis esa parte de la operación no es relevante (Vaidya y Gandhe, 2019).



**Figura 3-16** Cuatro algoritmos de alineación de imágenes (Vaidya y Gandhe, 2019)

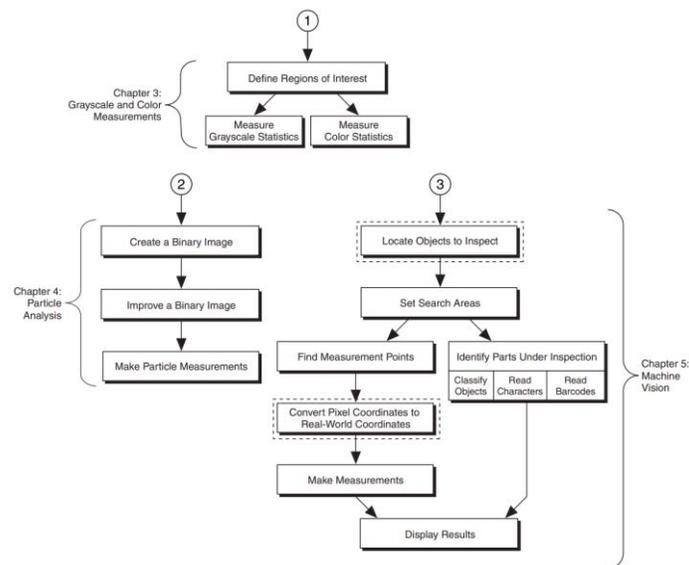
En el caso de la visión por computadora más tradicional se utilizan elementos geométricos más simples como en el caso que se muestra en la Figura 3-17 donde se utiliza el recuadro blanco con la etiqueta de fecha de caducidad para referenciar el resto de la imagen con respecto al patrón inicial.



*Figura 3-17 Corrección de alineación (Keyence Corporation, 2016)*

### 3.4.5. Reconocimiento tradicional

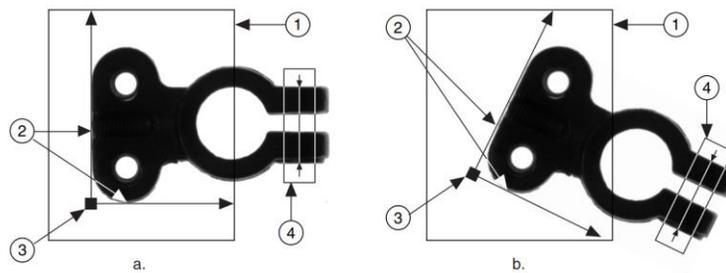
El reconocimiento de patrones consiste en la técnica de localización de un set definido de características en una imagen, las cuales se les llama patrón. Este patrón, en la etapa de creación de imágenes para entrenamiento y evaluación, consiste en detectar áreas de interés y exportarlas para realizar un mejor análisis. Se propone que se realice de dos maneras en el desarrollo descrito. En primera instancia debe ser con visión tradicional utilizando la metodología descrita por National Instruments (National Instruments, 2004) que se basa en pasos para ubicar un patrón en una imagen de manera supervisada. Estos pasos se detallan en la Figura 3-18.



**Figura 3-18** Pasos para desarrollar un segmentador tradicional (National instruments, 2004)

En la Figura 3-18 se puede apreciar que existen tres pasos principales para construir un segmentador tradicional. El de mayor interés para la metodología a implementar es el paso 3 el cual comienza con la localización de un objeto a inspeccionar. Para realizar la localización se deben definir las áreas de búsqueda, encontrar los objetos, realizar mediciones o inferencias y mostrar los resultados. Independientemente del lenguaje que se utilice para implementarlo estos pasos se encontraran presentes de una u otra forma en el algoritmo de clasificador tradicional. Cabe aclarar que lo que se desea en primera instancia es crear imágenes separadas del objeto para poder entrenar al clasificador de tipo red neuronal entrenado por medio de machine learning.

Es muy importante que la calidad de datos sea buena ya que la precisión del clasificador entrenado dependerá en gran manera de que los datos iniciales sean de buena calidad. Por lo mismo se recomienda analizar el conjunto de datos inicial de manera manual para corroborar que los resultados del clasificador tradicional son correctos.



**Figura 3-19** Imagen de referencia vs imagen de inspección 1) área de búsqueda para el sistema de coordenadas 2) bordes del objeto 3) origen del sistema de coordenadas 4) área de medición o interés (National instruments, 2004)

Un ejemplo de resultado de clasificador configurado se puede ver en la Figura 3-19 donde a la izquierda se puede apreciar una imagen de patrón que fue configurado manualmente por el programador. En el lado derecho se observa una imagen capturada y cómo fue analizada por el algoritmo. Primeramente, busca en la región 1 los bordes del objeto, una vez encontrados los utiliza para dibujar el sistema de coordenadas, que en el caso de la figura se encuentra rotado con respecto al original y posteriormente lo utiliza para realizar una evaluación del área de interés en el paso 4. En el caso del desarrollo de este documento se cambiaría el paso 4, la medición de distancia, por el paso de exportar una imagen nueva que corresponda a la sección de interés de la imagen, los conectores. De esta manera se crearían imágenes estandarizadas de 300x300 pixeles para el entrenamiento del modelo. Las imágenes resultantes deben ser almacenadas de acuerdo con una nomenclatura y estructura de carpetas compatible con el algoritmo de entrenamiento de la red neuronal a utilizar.

Si existe más de un objeto a buscar por imagen, se pueden definir diferentes regiones de búsqueda de acuerdo a lo que se esté buscando, por ejemplo, en la Figura 3-20 se definieron dos patrones, un patrón para un fusible de 20 amperes y otro para uno de 25 amperes. En este caso solo se adquiere una imagen y dentro de la misma se buscan los patrones en dos diferentes regiones definidas por los rectángulos rojo y amarillo. Ambas regiones son suficientemente grandes como para compensar variación entre los productos y por el movimiento de la cámara, pero no

tan grandes como para desperdiciar una cantidad excesiva de tiempo de procesamiento.



**Figura 3-20** Dos regiones de búsqueda definidas en una misma imagen (National instruments, 2004)

### 3.5. Entrenamiento de modelo

El entrenamiento del modelo por medio de machine learning consiste en la secuencia de pasos que conlleva a la generación de un modelo que pueda realizar predicciones o inferencias en base a imágenes que le son alimentadas. Comienza con la creación de un conjunto de imágenes para entrenamiento y otro separado para evaluación y prosigue con la ejecución de un algoritmo de entrenamiento y evaluación que arroja un modelo el cual posteriormente puede ser evaluado con nuevas imágenes.

#### 3.5.1. Crear el conjunto de datos

Es indispensable contar con un conjunto de datos e imágenes de buena calidad para poder entrenar el modelo de la red neuronal seleccionado. Usualmente no se cuenta con un banco de imágenes previamente curado y organizado cuando se trata de una situación de campo. Es necesario crearlo en base a las imágenes obtenidas,

estas imágenes como se menciona en la sección de reconocimiento pueden ya estar preprocesadas y segmentadas sin embargo hay que darles la estructura necesaria. Para la creación del conjunto de datos se deben tomar en cuenta las siguientes consideraciones:

- a) Es deseable que las imágenes sean de las mismas dimensiones, si no lo son hay que considerar una etapa de escalamiento de las imágenes para que lo sean.
- b) Hay que asegurar que las imágenes que se vayan a alimentar al modelo se encuentren correctamente etiquetadas. En primera instancia el etiquetado debe realizarse de manera manual o por medio de un algoritmo de preprocesamiento. Si se sigue la ruta de un algoritmo de igual manera se recomienda supervisar los resultados del mismo para asegurar la calidad.
- c) Se debe separar el conjunto de datos con al menos un grupo de entrenamiento y un grupo de evaluación que deben ser mutuamente excluyentes.
- d) Las imágenes dentro de las carpetas de entrenamiento o evaluación deben ser etiquetadas de acuerdo a la clase que pertenecen, por ejemplo en la Figura 3-20 se hace mención de dos tipos de fusibles, 20 amperes y 25 amperes, por lo que las imágenes deben ser etiquetadas al menos como pertenecientes a una de esas dos clases o pertenecientes a ninguna.
- e) Cada imagen debe contar con un ID único en su nombre, que no se repita, para evitar conflictos.

### **3.5.2. Seleccionar el tipo de modelo**

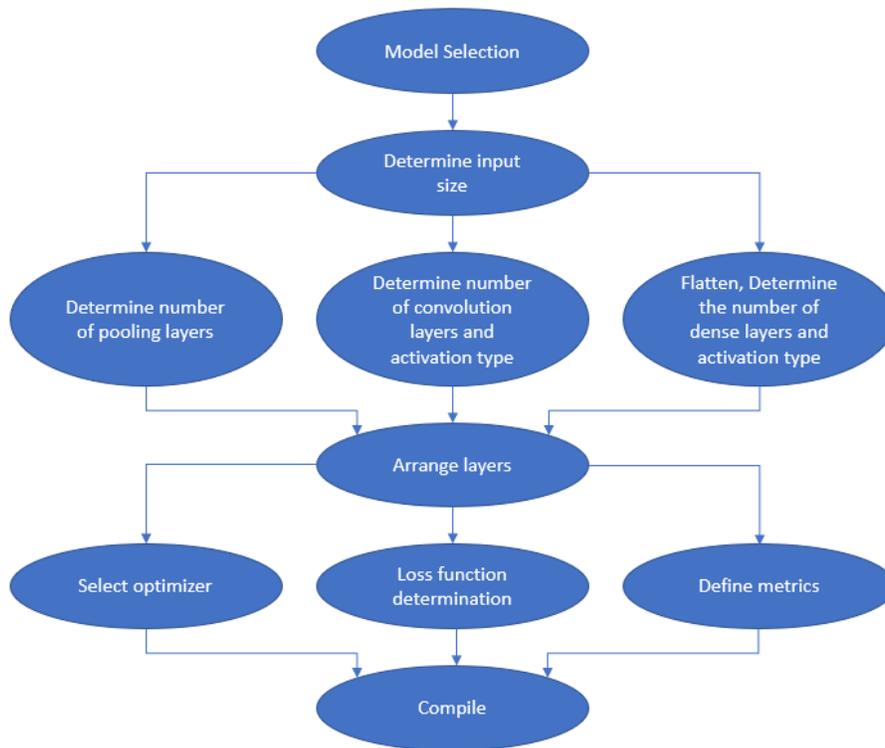
Existe una multitud de arquitecturas de redes neuronales artificiales desarrolladas en los últimos años. Cada una presenta ventajas en casos de uso particulares, por lo tanto, es importante conocer una amplia gama de arquitecturas con el fin de seleccionar la más adecuada para el problema en cuestión. Partiendo de la descripción del problema se conoce lo siguiente:

- Los datos principales son imágenes
- Dentro de la imagen se tratará de ubicar hasta tres conectores diferentes entre sí.
- Se tendrá a disposición aproximadamente 40,000 imágenes
- La ubicación y orientación del conector variará entre foto y foto
- Se desea utilizar la imagen para clasificar entre un conector en buen estado y uno en mal estado.

### **3.5.3. Crear modelo**

Una vez definido el tipo de red neuronal a utilizar y creado e importado el conjunto de datos al entorno de desarrollo debe implementarse la creación del modelo.

Con esto se finaliza la primera fase del entrenamiento y puede comenzar el entrenamiento del algoritmo. Para la creación del modelo existen diferentes librerías capaces de procesar imágenes y crear modelos de redes neuronales para clasificación. La secuencia de creación es similar en la mayoría y se describe a continuación en la Figura 3-21.



**Figura 3-21** Seudocódigo para creación de modelo

### 3.5.4. Entrenar modelo

El paso siguiente es el entrenamiento del modelo. El entrenamiento se logra siguiendo una serie de pasos que independientemente del lenguaje que se utilicen se podrían sintetizar como los mostrados en la

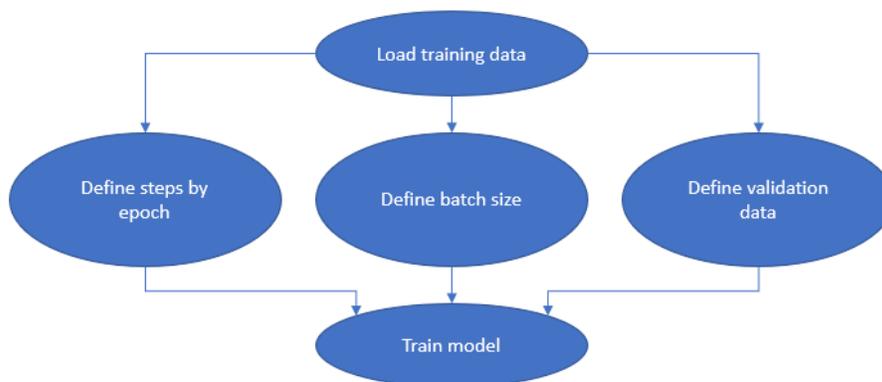
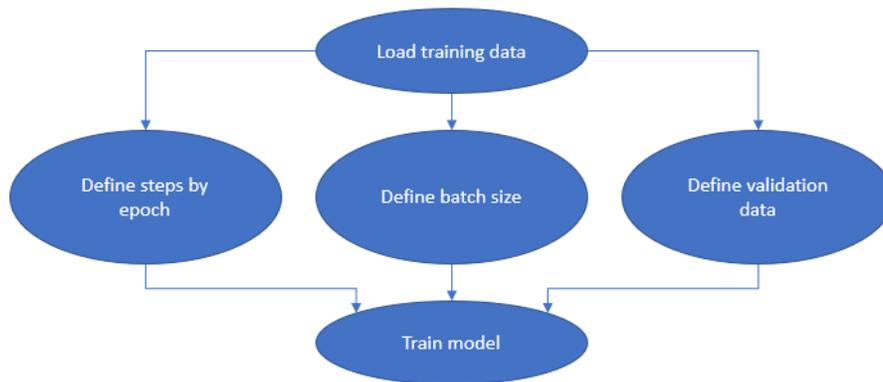


Figura 3-22.



**Figura 3-22** Pasos para entrenamiento del modelo

Cabe recalcar que todos los parámetros de la función de entrenamiento tienen un impacto significativo en el modelo resultante y que el pseudocódigo previamente ilustrado es solo un tipo de configuración. En realidad, el entrenamiento tendrá que repetirse con diferentes parámetros hasta encontrar un modelo satisfactorio.

### 3.5.5. Evaluación de modelo

Es importante recordar que la meta es entrenar al sistema para detectar qué elementos presentan un conector en buen estado y ser capaz de compensar por la variación de posición y orientación de la cámara al igual que variación en la posición, orientación y variaciones entre los conectores como el color.

El sistema deberá contemplar un sistema de posicionamiento suficientemente robusto ante la variación de la instalación del punto de anclaje con respecto a los conectores. De igual manera el algoritmo de visión debe ser capaz de compensar las variaciones que el sistema de posicionamiento no compense, manteniendo un nivel de confianza en las mediciones satisfactorio.

Hay que verificar el desempeño del algoritmo. Para realizar la verificación se utiliza el set de evaluación. El set de evaluación es un conjunto de imágenes que no fue utilizado para entrenar el modelo, de manera que el modelo no conoce estas

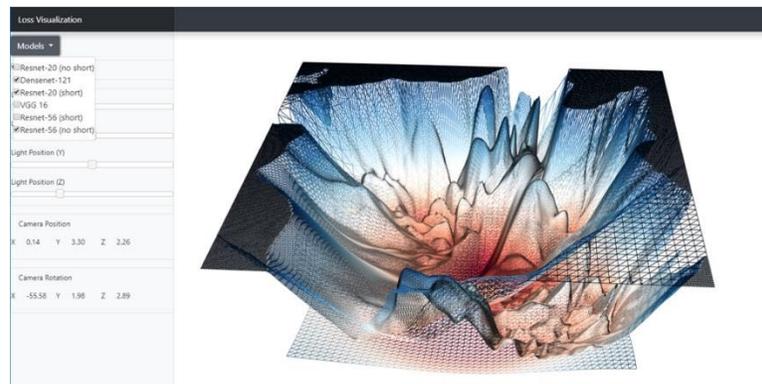
imágenes. Como parte del resultado que se genera cuando se corre el código de entrenamiento se obtiene lo siguiente para cada ciclo de entrenamiento:

```
Epoch 1/15  
15/15 [=====] - 9s 611ms/step - loss:  
0.8728 - accuracy: 0.5016 - val_loss: 0.6901 - val_accuracy:  
0.5156
```

Donde `val_accuracy` representa la precisión del algoritmo a la hora de clasificar las imágenes para las que no fue entrenado y `accuracy` representa la precisión con las imágenes que fue entrenado. Llegar a 1.0 significaría tener el 100% de precisión en la clasificación.

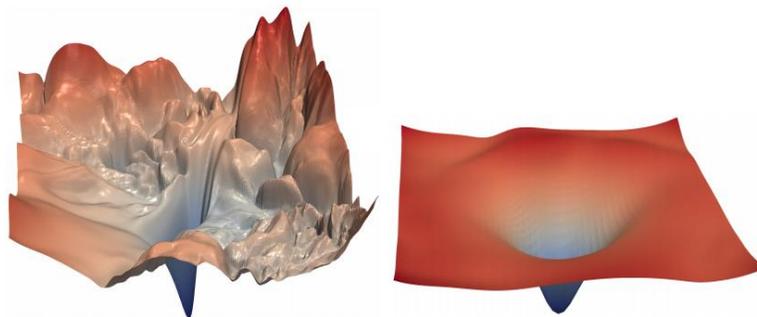
### 3.5.6. Visualizar función de pérdida

Entrenar redes neuronales involucra encontrar parámetros que minimicen lo que se llama función de pérdida. A veces visualizar la función de pérdida hace más fácil su interpretación, especialmente entre más compleja la aplicación o la red neuronal. La visualización ayuda a interpretar los resultados de la función de pérdida. Dependiendo de la profundidad de la red neuronal la complejidad de la topografía de la función de pérdida se vuelve más compleja. Se puede visualizar la función de pérdida como un mapa topográfico donde lo que se desea es llegar al punto más bajo. La topografía de estos modelos puede resultar tan compleja que utilizar un gradiente simple no lleve al valor óptimo. Por ejemplo, en la Figura 3-23 se visualiza la topografía de una red tipo Resnet que es una red neuronal bastante común. Se puede apreciar que si el optimizador del modelo se ubica en un punto en particular puede ir a valles localizados que no son el valle más profundo o el punto óptimo. Una vez que el optimizador llega a uno de esos valles puede permanecer en un mínimo local lo cual no es deseable.



**Figura 3-23** Visualización de topografía de función de pérdida de una red neuronal tipo Resnet (ankur6ue, 2019)

En el caso de que la topografía sea muy compleja se propone el uso de conectores de salto entre las diferentes capas de la red neuronal para simplificarla y disminuir la probabilidad de que un modelo permanezca en un mínimo local, el efecto de agregar estos conectores a la red neuronal desde el modelo se puede visualizar en la Figura 3-24.



**Figura 3-24** Efecto sobre la topografía de incluir conexiones de salto en la red (Li et al., 2018)

Los resultados de la topografía de la red neuronal deben ser analizados con el fin de no hacerla más compleja de lo necesario ya que esa complejidad resulta en una dificultad para obtener valores realmente óptimos.

## 4. IMPLEMENTACIÓN

La implementación de la metodología planteada se presenta en este capítulo. La estructura de la sección sigue la de la sección de metodología. Por protección de datos se han cambiado los nombres reales de las marcas de vehículos estudiados quedando como M1 y M2 para las dos marcas.

### 4.1. Inmersión

#### 4.1.1. Análisis de situación actual

Inicialmente las condiciones de la estación asignada a la inspección visual eran las siguientes:

- a) El espacio ocupado por la estación es el equivalente al de dos estaciones estándar, teniendo un total de 4.8 metros asignados en total.
- b) Tanto el operador de la estación anterior como el de la estación siguiente se turnaban la responsabilidad de inspeccionar los paneles que pasaban por la estación. Al inspeccionar la pieza suelen colocar una marca de color negro con un plumón sobre los tres conectores. La marca puede también ser blanca en algunos casos.
- c) La inspección visual a veces va acompañada de una inspección táctil donde el operador coloca su pulgar sobre el conector con el fin de determinar si se encuentra bien conectado.
- d) En caso de no encontrarse conectado correctamente el operador para la línea y toma su tiempo para conectarlo de manera correcta, de no ser posible, debe llamar al supervisor de la línea para que tome acciones correctivas.
- e) Actualmente se cuenta con un registro según el cual en promedio por cada turno de 8 horas, 32 unidades defectuosas son registradas en la estación.

- f) Existe una estación de inspección final antes de remover el panel de la línea, en la cual se registra al menos 1 panel con defecto el cual debe ser retrabajado. Esto indica que la inspección visual por parte de los operadores no es perfecta.
- g) Previamente se intentó implementar un sistema de inspección por visión artificial montado en una posición estática a 1.8 metros de distancia del panel medido desde su posición más cercana.
- h) Se determinó que el sistema falló por una combinación de factores entre los cuales se incluyen:
  - a. La posición del panel con respecto a la cámara varia, es decir el panel se encuentra siempre en movimiento
  - b. La orientación del panel con respecto a la cámara también varia, debido a que la sujeción del panel permite la rotación del mismo para facilitar otras operaciones.
  - c. Las marcas colocadas por el operador sobre el conector afectan la efectividad del sistema para clasificar correctamente
  - d. La iluminación ambiental varia con el tiempo (día vs noche, invierno vs verano) lo cual dificulta la clasificación
  - e. Los operadores y otro personal pueden colocarse entre la cámara y el panel imposibilitando que se capture una imagen adecuada del mismo.

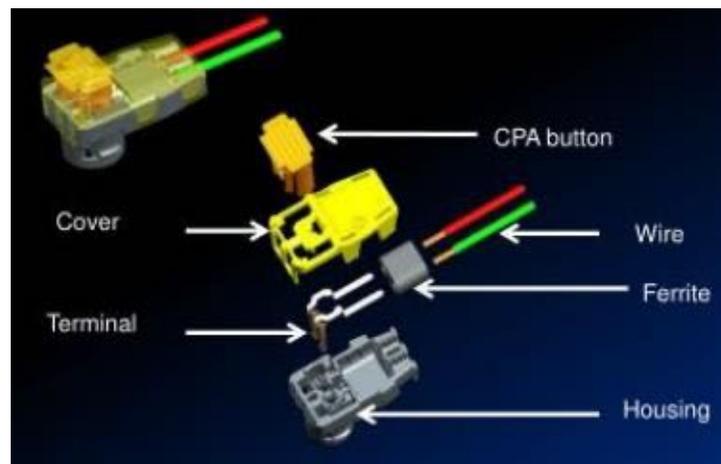
Los conectores pertenecen a la familia de conectores SRS (Safety Restraint Systems) que son conectores utilizados para conectar cableado a dispositivos pirotécnicos como bolsas de aire. Un ejemplo de ellos se puede apreciar en la Figura 4-1. Los conectores se han desarrollado para cumplir con requerimientos de limitantes de espacio, ambientes adversos y supresión de ruido electromagnético de manera que cumplan con su función principal. Su función principal es asegurar una conexión eléctrica estable durante el ciclo de vida del vehículo a la vez que asisten al trabajador en la instalación contemplando cuestiones ergonómicas.



**Figura 4-1** Conector tipo SRS característico (Arpe, 2013)

Los conectores se encuentran compuestos por 6 elementos mecánicos identificables. En la Figura 4-2 se identifican los 6 elementos los cuales son:

- a) Botón CPA
- b) Cubierta
- c) Cable
- d) Ferrita
- e) Terminal
- f) Carcasa



**Figura 4-2** Elementos principales del conector (Ieda, 2014)

Tres fueron identificados como relevantes para un sistema de clasificador por visión artificial los cuales son la carcasa, el botón y la cubierta. Tras realizar el análisis inicial se identificó que existen:

- 2 tipos de botones: identificados por una geometría distinta entre ellos y dos colores, naranja y rojo.
- 3 tipos de carcasa: identificados por 3 colores diferentes, negro, azul y amarillo correspondientes a la posición izquierda, central y derecha de los conectores en la pieza.
- 2 tipos de cubierta: ambas de color amarillo pero con una geometría con ligeras variaciones.

#### 4.1.2. Identificación de errores

Al analizarse el panel y específicamente los conectores en cuestión, se identificaron los siguientes tipos de errores en los mismos.

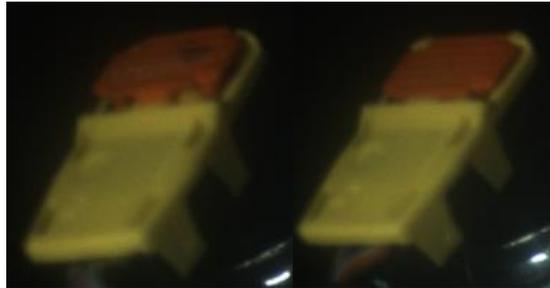
**Conector no asegurado correctamente:** Este tipo de falla el cliente explica que se debe a que el conector no es presionado por el operador de manera correcta. Los conectores ofrecen una alta resistencia antes de ser “crimpados” lo cual puede llegar a engañar al operador y hacerle creer que ya los presionó. Dependiendo de qué porcentaje de las paredes laterales del conector se vean expuestas varía el tipo de falla y el comportamiento que tendrá. Como se puede ver en la Figura 4-3 el conector perteneciente a la marca A se encuentra completamente expuesto en la imagen de la izquierda, y se encuentra correctamente conectado en la imagen de la derecha.



*Figura 4-3 Conector izquierdo, perteneciente a la marca A comparativa: conectado incorrectamente (izq.) vs correctamente (der.)*

**Conector semi-crimpado:** Se define como semi-crimpado si el conector se encuentra crimpado parcialmente, es decir existe conexión eléctrica más no se encuentra

asegurado mecánicamente de la manera adecuada. Esto se ve representado por paredes expuestas en menor grado que en el caso anterior pero apreciables como puede apreciarse en la Figura 4-4.



**Figura 4-4** Conector izquierdo, perteneciente a la marca A comparativa: conectado tipo semi-crimpado (izq.) vs correctamente (der.)

De acuerdo con el fabricante este error no debería ser posible ya que se supone que por diseño el botón cpa no solo puede ser empujado si el conector se encuentra posicionado completamente y en la posición final del receptáculo. El diseño se encuentra patentado por el fabricante, un render del mismo se aprecia en la Figura 4-5.



**Figura 4-5** Diseño del sistema patentado para asegurar la conexión (leda, 2014)

**Conector faltante:** Ocurre cuando el conector no se encuentra en posición, puede que pertenezca a un arnés defectuoso o incorrecto, se aprecia por la ausencia del conector en la posición adecuada. Es el error más fácil de detectar y no suele ser un problema para los operadores el diagnosticarlo.

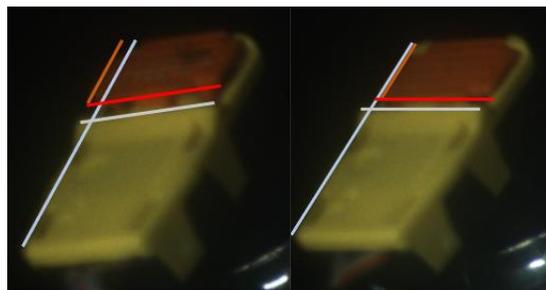
De los tipos de errores analizados existen dos tipos, los cuales se identificarán de ahora en adelante como error tipo A y error tipo B. El error tipo A implica una ausencia de conexión eléctrica entre la bolsa de aire y el vehículo, es decir el conector no se encuentra conectado. Eventualmente en el área de pruebas suele ser detectado si llega a eludir a los inspectores tanto del cliente como del cliente final.

El error tipo B se identifica por un conector que aparenta estar conectado correctamente pero no cuenta con la fijación mecánica adecuada. Por esto mismo el conector puede desprenderse con el uso y con eventualmente se inhabilita la conexión entre la bolsa de aire y vehículo. Es un problema mayor que el error tipo A pues es más fácil que eluda la detección en las inspecciones visuales y al contar con conexión eléctrica no es detectado por el cliente final. El usuario final del vehículo es quien entonces corre el riesgo de que, con el uso, el conector se desconecte y deshabilita el uso de la bolsa de aire del pasajero.

#### 4.1.3. Identificación de patrones

Tras un análisis inicial se identificaron varios puntos que pueden ser relevantes para el análisis y clasificación.

Tomando como referencia una línea dibujada a lo largo del borde de la cubierta, cuando un botón no se encuentra correctamente crimpado la distancia del borde izquierdo variará con respecto al patrón deseado como se puede apreciar en la Figura 4-6.



**Figura 4-6** Patrón de movimiento de botón con respecto a la carcasa

Al igual que la variación antes descrita, se puede apreciar que el borde inferior del botón incrementa su distancia relativa al borde equivalente en la carcasa, indicado por la línea roja en Figura 4-6.

Se identificó en las imágenes que los conectores pueden rotar hasta 15 grados de la línea vertical de conexión. El grado de variación deberá ser compensado por el algoritmo.

## 4.2. Diseño de posicionador mecánico

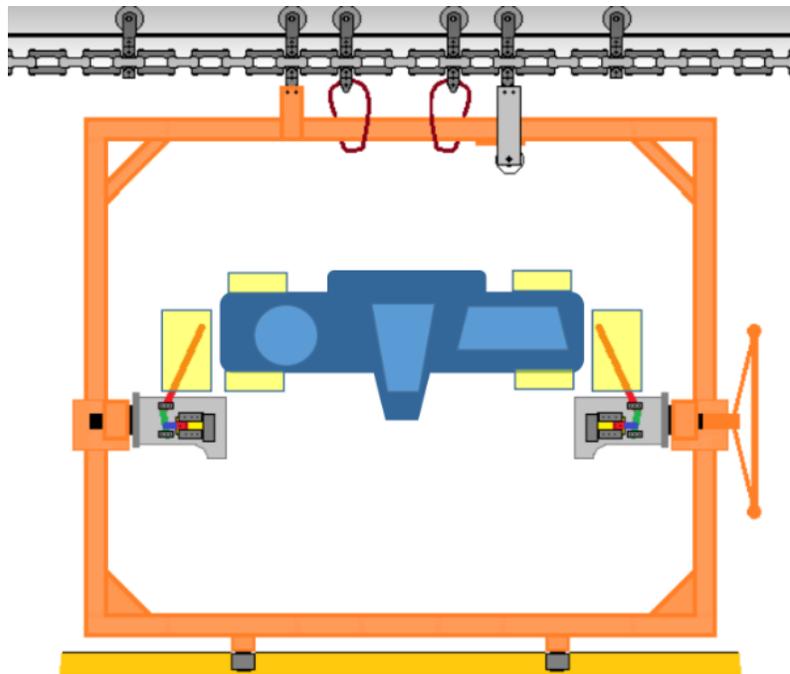
Un elemento importante para simplificar el diseño de un sistema de visión es el considerar la posición y orientación de la cámara relativa al punto o pieza a inspeccionar. En el caso de estudio propuesto la cámara debe analizar un área ubicada dentro de un panel de instrumentos de un vehículo tipo sedán. Esta área se señala en la Figura 4-7.



**Figura 4-7** Vista general del panel de instrumentos (el área a inspeccionar se muestra en blanco)

Por condiciones de operación de la planta el panel se encuentra en movimiento constante a lo largo de una línea de producción. Se contempla además que puede presentar variaciones en el ángulo de rotación con el que llega a la estación más las variaciones dadas por las tolerancias del ensamble. Por último, el soporte del panel se encuentra restringido más no anclado completamente a la línea por lo cual presenta

además, movimientos oscilatorios. Por todo esto se contempla que se deberá diseñar un posicionador mecánico cuyo propósito será el de orientar la cámara con respecto al área de inspección de manera repetible y contemplando las condiciones antes mencionadas. Un diagrama de los elementos de la línea que se encuentran presentes se muestra en Figura 4-8.



**Figura 4-8** Diagrama de vista frontal de la estación

Este posicionador deberá contemplar varios elementos:

- Montura ajustable para la cámara
- Montura ajustable para el sistema de iluminación
- Punto de referencia para el sistema en general con respecto a área de inspección
- Elementos de protección contra impacto
- Control de la iluminación ambiental incidente sobre el área de inspección
- Puntos de agarre para manipulación por el operador

### 4.2.1. Evaluación de posiciones para cámara e iluminación

Antes de seleccionar la superficie que se utilizará de referencia se debe analizar la posición deseada de la cámara con respecto a la pieza a inspeccionar. Para realizar el análisis se utilizó un gimbal panorámico con montura para trípode el cual se muestra en la Figura 4-9. Este arreglo permite evaluar varias combinaciones de distancia y orientación de la cámara con respecto a la pieza.



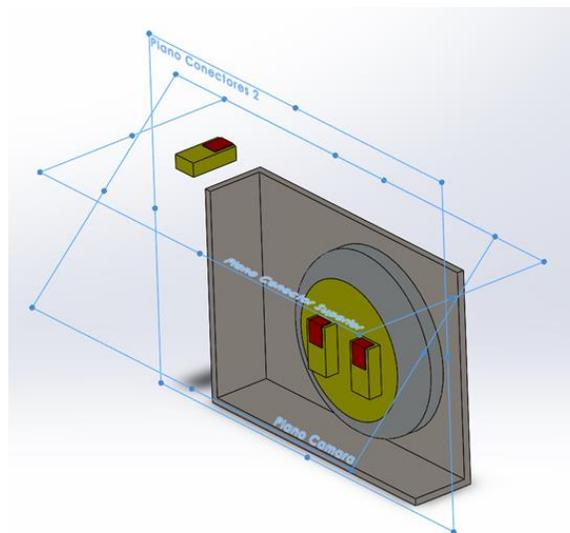
**Figura 4-9** Elementos para prueba de primera iteración (izq) gimbal y (der) trípode

Como se puede apreciar en la Figura 4-10 no se utilizó el sistema de iluminación en esta versión. Esto se debe a que lo principal, en la primer etapa, fue verificar que los conectores quedaran en cuadro de la cámara, enfocados y con el mayor número de píxeles por conector posibles.



**Figura 4-10** Iteración 1 del sistema de captura

Durante la evaluación lo primero fue evaluar la orientación de la cámara. Los tres conectores se encuentran ubicados en dos planos los cuales se encuentran perpendiculares entre sí. Esto complica el ubicar la cámara en una posición única, que enfoque de mejor manera a los tres. Partiendo de este supuesto se evaluaron ambas posiciones y se determinó que lo mejor sería un plano intermedio entre ambos de manera que a pesar de que ninguno de los conectores se encuentre en la mejor orientación con respecto a la cámara, la información de cada conector sea suficiente para realizar una clasificación. El primer plano intermedio por evaluar fue a 45 grados. Este se muestra en la Figura 4-11. Durante estas operaciones fue necesario ajustar la apertura de la cámara de acuerdo con lo indicado por la metodología para tratar de mantener el mejor enfoque posible sobre los tres conectores.



**Figura 4-11** Visualización de planos evaluados inicialmente

Al encontrar que un plano de aproximadamente 45 grados  $\pm$  10 grados era aceptable se procedió a determinar la distancia óptima. Al realizar las pruebas se determinó la distancia óptima para capturar la imagen con una orientación de 45 grados. Una distancia de 12 cm  $\pm$  1cm fue la que mejor resultados arrojó, por lo que se tomó como punto de partida para el diseño de la versión 2 del sujetador.

La versión 2 se distingue de la versión 1 al prescindir del trípode y ser la primera versión que incluye una montura referenciada a una superficie del panel, así como incluir la primera versión del sistema de iluminación. Este prototipo se fabricó en impresión 3D. En la Figura 4-12 se puede apreciar la versión 2 final, los elementos impresos en 3d son de color naranja. Se decidió utilizar el gimbal de la versión 1 por las facilidades con las que cuenta para determinar los ángulos actuales y la posición XYZ de la cámara.



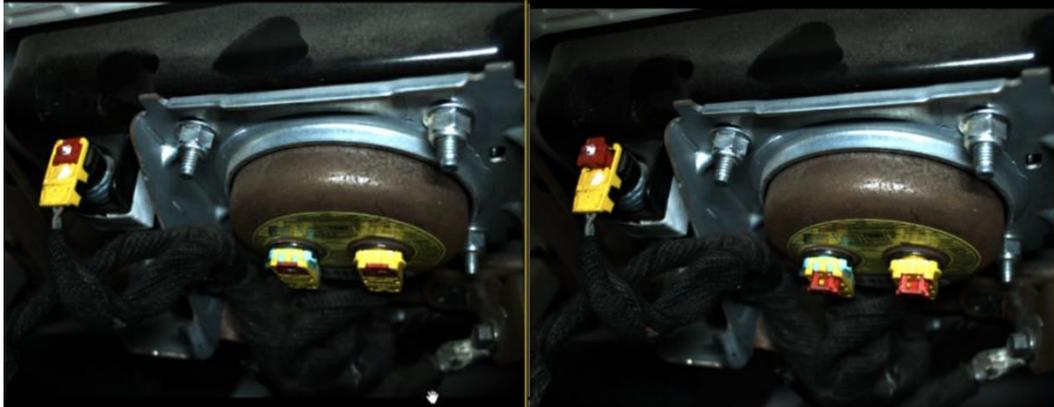
**Figura 4-12** Versión 2 de posicionador, impreso en 3D

La versión dos consistía en 3 piezas distintas las cuales en la Figura 4-12 se pueden ver identificadas como:

- a) Soporte de iluminación con 1 grado de libertad de rotación
- b) Soporte para iluminación con 1 grado de libertad lineal
- c) Soporte de gimbal con 1 grado de libertad lineal
- d) Gimbal con 2 grados de libertad lineal y 2 grados de libertad de rotación

El propósito principal de la versión 2 fue el de probar diferentes ángulos y posiciones, tanto de la cámara como de la iluminación relativas a la placa de conectores con una mayor precisión y repetibilidad que la versión 1 de manera que estas mediciones pudieran ser utilizadas para un diseñar la versión 3 la cual es la primera versión lista para ser probada en ambiente real. Hubo 3 grupos de orientación principal cada uno

con un diferente tipo de enfoque. En la Figura 4-13 se puede apreciar una orientación inicial, llamada superior, la cual presentó buenos resultados. El razonamiento tras la orientación superior era el mantener un enfoque sobre el conector izquierdo y la parte superior de los conectores central y derecho.



**Figura 4-13** Orientación superior, izq. clip conectado, der. clip desconectado

Posteriormente se intentó un ángulo posicionado sobre el conector izquierdo, pero a un ángulo que permitiera observar una mayor cantidad de píxeles de las paredes laterales de las carcasas de los conectores, el cual se muestra en la Figura 4-14.



**Figura 4-14** Orientación superior izquierda

Por último, se evaluó una orientación frontal con un ligero ángulo al lado derecho del panel, dicha orientación se muestra en la Figura 4-15. Lo que se buscaba con la orientación frontal fue el maximizar la cantidad de información sobre los botones en cuanto a cantidad de píxeles que abarcan. También se tomó en cuenta en esta el

minimizar la diferencia de la distancia entre cada botón y el sensor de la cámara, a manera de que minimizara la profundidad de campo necesaria en la cámara para mantener un buen enfoque.



*Figura 4-15 Orientación frontal*

Una vez capturadas imágenes de referencia en cada una de las orientaciones y documentados los ángulos y distancias relevantes para un diseño, se procedió a evaluar la calidad de las imágenes obtenidas. Este análisis se realizó tomando en cuenta factores como el nivel de acutancia en los bordes y la cantidad de píxeles que representan al botón en posición correcta y en posición incorrecta. Se busca maximizar los 3 parámetros. En el caso de las 3 posiciones evaluadas la mejor fue la orientación frontal y como resultado se definió que esta orientación sería la adecuada, con el fin de seleccionar una superficie de referencia adecuada.

#### **4.2.2. Selección de superficies de referencia**

Para realizar el anclaje mecánico del posicionador con respecto a la pieza de inspección se debe considerar una superficie que cuente con elementos que permitan el diseño de dicho anclaje. Los factores para considerar al evaluar una superficie para anclaje son:

1. ¿Qué tanta variación relativa existe entre la superficie y el área de inspección?

2. ¿Cuenta la superficie con puntos de referencia como agujeros los cuales puedan ser utilizados para restringir el movimiento del posicionador?
3. ¿Qué tantos de los 12 grados de libertad se pueden restringir si se utiliza esta pieza como referencia?
4. ¿Qué tan fácil es mover el mecanismo hacia la posición seleccionada?

Para seleccionar correctamente la superficie de referencia y diseñar el sistema de posicionamiento en general con respecto a esta, se plantea seguir las técnicas propuestas por Karl Henriksen en su libro *Jig and Fixture Design Manual* (Henriksen, 1973). En este se incluyen varias técnicas y métodos para restringir el movimiento de piezas y el diseño de localizadores enfocados a procesos de manufactura y aseguramiento de calidad. Algunas de las cuales se vieron en la sección de metodología.

Analizando la superficie del panel se encuentran varios elementos que podrían servir como superficies de referencia y potenciales anclajes, uno de ellos fue el perfil tubular recto utilizado en la versión dos. Este presenta la desventaja de estar relativamente lejos del punto donde la cámara debe de estar, y como debe existir una conexión mecánica entre la cámara, iluminación y el punto de referencia, sería preferible minimizar la distancia entre los puntos.

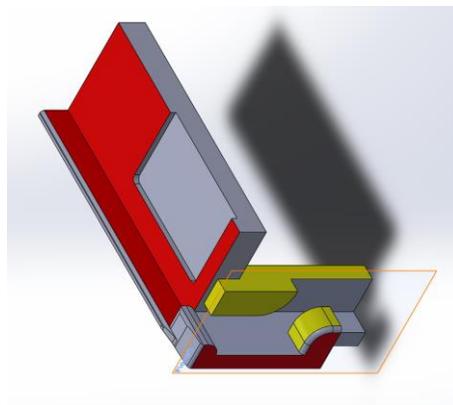


**Figura 4-16** Versión dos anclada a un perfil tubular recto

Además de los puntos descritos anteriormente algo importante a tomar en cuenta es que siendo el panel un ensamble, entre mayor sea la cantidad de elementos mecánicos entre la superficie de referencia y el panel de conectores, mayor será la variación acumulada definida por la acumulación de tolerancias de fabricación y ensamble, por lo que es deseable seleccionar una superficie cercana a los conectores.

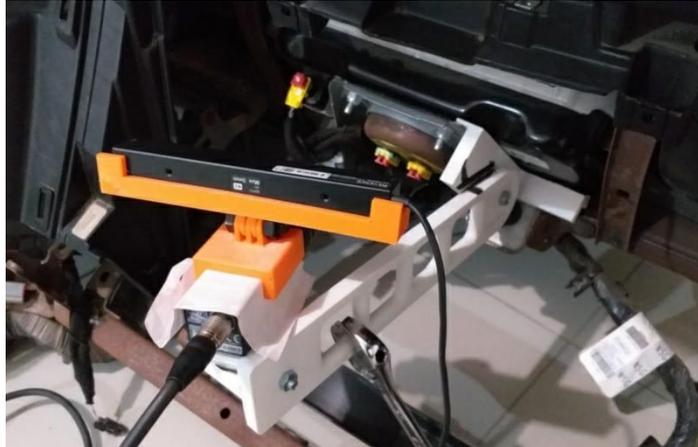
Con los criterios previamente mencionados en mente se definió que una aceptable posición sería en la placa de montaje del módulo de la bolsa de aire. Se seleccionó esta superficie por la proximidad al módulo de bolsa de aire y por presentar ángulos rectos y puntos que pudieran servir para un anclaje.

Como resultado de la elección se procedió al diseño mecánico del elemento posicionador. La etapa de diseño pasó por varias iteraciones donde se trató de disminuir el juego que presentaba y hacerlo suficientemente robusto como para volverse el punto de anclaje y soporte único del mecanismo. El diseño 3D antes de la fabricación del prototipo puede verse en la Figura 4-17, en ella se puede discernir 2 tipos de superficies, las rojas son superficies donde la pieza realiza contacto con el panel, restringiendo el movimiento lineal en X, Y y Z en una dirección, dada la geometría de la pieza se agregaron dos superficies, señaladas en color amarillo, las cuales bloquean los grados de libertad restantes al punto de que una vez insertado solo se puede remover con un movimiento de rotación en el plano XY en sentido horario. Para insertarlo se puede realizar de varias maneras.



**Figura 4-17** Superficies de referencia en rojo, superficies de candado en amarillo

Este prototipo también fue evaluado utilizando impresión 3d lo cual se puede apreciar en la Figura 4-18 donde se puede apreciar como la cámara se encuentra en la misma posición con respecto a los conectores que antes con la diferencia de que ahora el posicionador se encuentra completamente referenciado al panel.



**Figura 4-18** Versión 3 con superficie de referencia y mecanismo referenciado a la misma

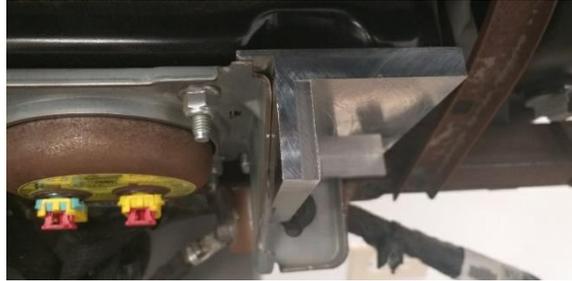
Una vez que los resultados de la validación en prototipo 3d fueron aceptados, se tomaron las medidas que caracterizan la posición relativa de la cámara y el sistema de iluminación con respecto a la pieza de montaje.

Con los parámetros de diseño finalizados se procedió a trabajar en la versión final, la cual fue fabricada en acero. En la Figura 4-19 se muestra la versión final maquinada.



**Figura 4-19** Elemento mecánico final en acero

En la Figura 4-20 se muestra como este elemento queda posicionado con respecto al panel de conectores de la bolsa de aire.



*Figura 4-20 Elemento de referencia en posición*

### 4.3. Adquisición de datos iniciales



*Figura 4-21 Orientación de prueba (foto de referencia)*

En el caso se plantea el uso de una cubierta opaca flexible, la cual impida el paso de la luz ambiental, seguido por el uso de una fuente de iluminación controlada tipo difusa generada por un arreglo de led. Utilizar una barrera y fuente de iluminación independiente es con el fin de tener un control sobre la iluminación y reducir la variación entre fotos lo cual implica que se elimina en gran parte la iluminación ambiental y por tanto se depende enteramente de la fuente de iluminación controlada con la que cuenta el sistema.

La calibración de iluminación se hizo de manera tal que siendo los conectores los componentes a analizar y por lo tanto, los únicos importantes, se busca que en ningún momento los pixeles que los representan lleguen a un punto de saturación, ya sea por

exceso de iluminación o falta de la misma. Si se aprecia por ejemplo que un valor dentro del área de conector, en la escala RGB llega a un valor de 255, el cual es el máximo de la escala, lo cual implica que probablemente la iluminación es demasiada. De igual manera si existen pixeles con un valor de 0 hay que analizarlos.

En el caso del enfoque lo que se busca es que los bordes del conector o las zonas donde hay cambios de color sean lo mas definidos posible. Como los 3 conectores se ubican en diferentes planos con respecto al plano de la cámara, solo puede enfocarse un conector en el punto óptimo y los otros dos quedan ligeramente desenfocados. Tras realizar la calibración de enfoque al punto donde se obtiene la mejor calidad de imagen para los 3 conectores la imagen resultante fue la Figura 4-22.



*Figura 4-22 Orientación de prueba (referencia de iluminación baja)*

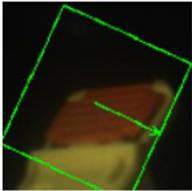
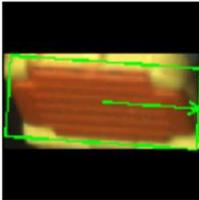
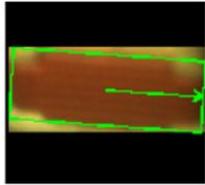
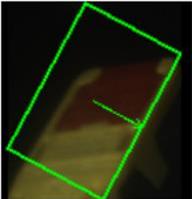
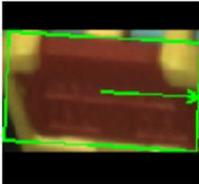
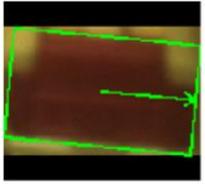
#### **4.3.1. Adquisición de datos para entrenamiento**

Se determinó que independientemente de la marca del vehículo existen 3 posiciones de conectores y que estos pueden fallar según lo descrito en la etapa de inmersión. En la Tabla 4-1 muestran los tres conectores tanto en buen estado como en falla crítica.

M1	LEFT	MID	RIGHT
OK			
NG (falla crítica)			

**Tabla 4-1** Conectores en buen estado y en falla

Posteriormente se identificó que los conectores de ambas marcas son diferentes en su geometría y color. En la Tabla 4-2 se muestra como el tinte es más rojo en la marca número dos y que la geometría es diferente de manera significativa.

	LEFT	MID	RIGHT
<b>M1</b>			
<b>M2</b>			

**Tabla 4-2** Variación en geometría y color entre marcas

En base a este análisis se determinó que existe un total de  $3 \times 2 \times 2 = 12$  clases a entrenar. Las doce clases deben ser representadas en la base de datos de entrenamiento y validación.

Se realizó un levantamiento compuesto por un total de 16,382 paneles. En los paneles analizados paneles se encontraron 482 fallas. Al no ser datos suficientes para realizar

un entrenamiento donde al menos el 20% de las muestras representaran errores, pero con más de 10,000 fotos para cada marca se le solicitó al operador crear los errores al no oprimir correctamente el conector. Finalmente se creó un conjunto de datos con 20,000 fotos en total de las cuales existen 700 fotos de cada conector en falla.

## 4.4. Pre-procesamiento de datos

Los datos adquiridos fueron pasados por una etapa de procesamiento donde se aplicaron filtros de iluminación y segmentación para crear 3 imágenes independientes de cada imagen adquirida. Aquí además se le agregó a cada nueva imagen la etiqueta de la clase a la que pertenece.

### 4.4.1. Localización y segmentación

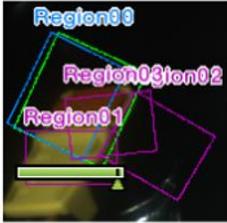
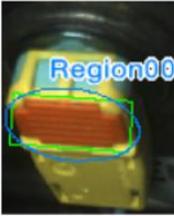
Para poder realizar la segmentación de imagen, debe encontrarse primeramente el conector. Se definió como región característica el clip del conector, pues indistintamente de si el conector se encuentra correcta o incorrectamente enclipado el clip de color rojo o naranja no presenta variaciones significativas.

Se entrenó un algoritmo de localización de patrones para encontrar el clip en una cierta región de búsqueda. La región de búsqueda fue definida en base a las coordenadas donde usualmente se encuentra todo el conector. Esta región de búsqueda se encuentra definida por el rectángulo azul y el patrón del conector como el rectángulo verde.



**Figura 4-23** Conector con región de búsqueda, patrón y orientación indicadas

Este algoritmo se programó con herramientas de visión artificial tradicional. Al final el algoritmo nos presenta con las coordenadas que definen el polígono donde se encontró el patrón. Utilizando las coordenadas del polígono se puede estimar la rotación del conector con respecto al entrenamiento de manera que la región a extraer en la imagen secundaria sea tal que ya se haya compensado la rotación del conector. La orientación visualmente queda indicada con las flechas de color verde que se pueden apreciar en la Figura 4-23. Finalmente, este proceso se repitió para los otros 5 conectores. La tabla de regiones de búsqueda y mascararas aplicadas se muestra a continuación en la Tabla 4-3.

	LEFT	MID	RIGHT
M1			
M2			

*Tabla 4-3 Regiones de búsqueda y mascararas aplicadas*

## 4.5. Entrenamiento de modelo

El entrenamiento de un modelo, como se ha mencionado en secciones anteriores consiste en una serie de pasos. Los pasos en la implementación se dividieron en:

- Construir la expresión matemática para el modelo general
- Declarar las variables que deben ser actualizadas conforme se realiza el entrenamiento

- Obtener una expresión para la pérdida la cual es la diferencia entre el modelo y la observación
- Crear un optimizador con la función de pérdida y llamarle la función de minimizar.
- Ejecutar la sesión de entrenamiento.

#### 4.5.1. Importar conjunto de datos

Con el fin de importar el conjunto de datos al entorno donde se desarrolló el modelo se creó un directorio con las imágenes el cual contiene una carpeta para el set de entrenamiento y otra carpeta para el set de validación. Además, cada una contiene doce subcarpetas, cada una de las cuales corresponde a una de las posibles categorías de clasificación. El programa tiene dado de alta un directorio para cargar el set de entrenamiento y el set de validación como conjunto de datos independientes y utilizarlos en el algoritmo. La arquitectura del conjunto se muestra en la Figura 4-24.



**Figura 4-24** Estructura de base de datos

Se crearon varias versiones del conjunto de datos, una con mayor cantidad de fotos que la otra. En la primera se utilizan 10,000 imágenes de conectores, en la segunda se utilizan 20,000. Esta primera iteración, en la que se utilizan las 1800 imágenes únicamente, se probaron varias arquitecturas de modelos con el fin de realizar pruebas rápidas hasta encontrar algo que luciera prometedor para implementar. Esto consistió en variar el número y orden de las capas de convolución principalmente, así como las

dimensiones de estas. Una vez encontrada una que fue considerada eficiente se procedió a la siguiente etapa que fue configurar la red y realizar el proceso de validación y entrenamiento con el conjunto de datos de 20,000 fotos. Este proceso se detalla a continuación.

#### **4.5.2. Seleccionar tipo de modelo**

El objetivo de esta etapa fue el de formular el modelo de una CNN, para esto se debe definir:

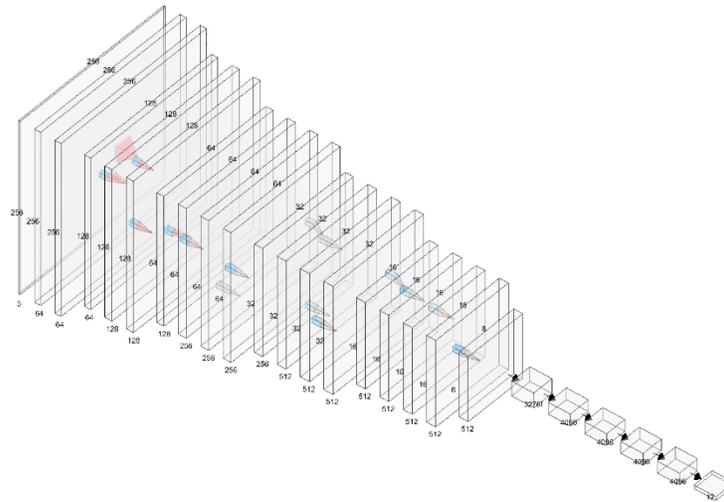
- El tipo de entrada, lo cual incluye el tamaño y los canales.
- El arreglo de capas de convolución y pooling, implica definir el número de capas de cada uno, el número de filtros en cada una y el tamaño de los filtros.
- Crear una capa de aplanado (flatten) y la capa completamente conectada, la cual implica crear al menos suficientes elementos a la salida como para que exista al menos uno por cada categoría a analizar.

La definición de las variables para el modelo final se ilustra en la Tabla 4-4.

Tipo de Capa	Forma a la salida
conv2d_1 (Conv2D)	N, 256,256,64
conv2d_2 (Conv2D)	N, 256,256,64
max_pooling2d_1 (Maxpooling2D)	N, 128,128,64
conv2d_3	N, 128,128,128
conv2d_4	N, 128,128,128
max_pooling2d_2 (Maxpooling2D)	N, 64,64,256
conv2d_5	N, 64,64,256
conv2d_6	N, 64,64,256
conv2d_7	N, 64,64,256
max_pooling2d_3 (Maxpooling2D)	N, 32,32,256
conv2d_8	N, 32,32,512
conv2d_9	N, 32,32,512
conv2d_10	N, 32,32,512
max_pooling2d_4 (Maxpooling2D)	N, 16,16,512
conv2d_11	N, 16,16,512
conv2d_12	N, 16,16,512
conv2d_13	N, 16,16,512
max_pooling2d_5 (Maxpooling2D)	N, 8,8,512
flatten_1 (Flatten)	32768
dense_1 (Dense)	4096
dropout_1 (Dropout)	4096
dense_2 (Dense)	4096
dropout_2 (Dropout)	4096
dense_3 (Dense)	12

**Tabla 4-4** Arquitectura de red final

Las redes neuronales pueden visualizarse de varias maneras, uno de los estándares más utilizados es la representación en el estilo Alexnet. El estilo Alexnet se utilizó ya que permite una visualización más densa de redes complejas en el cual se puede apreciar como cada capa y kernel actúan sobre la entrada como se puede ver en la Figura 4-25.



*Figura 4-25 Visualización de la red en estilo Alexnet*

### 4.5.3. Crear modelo

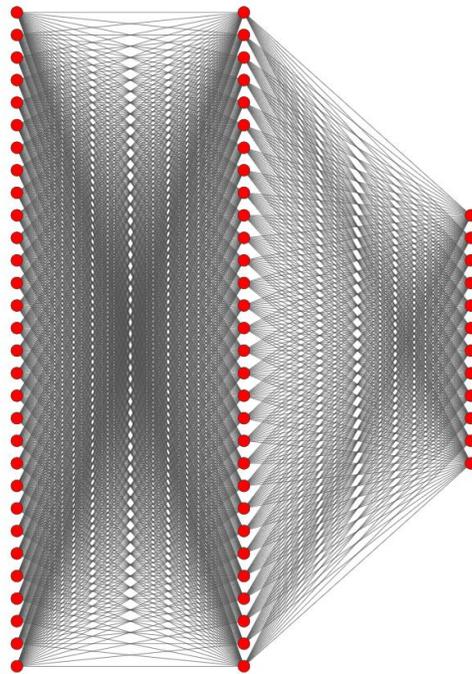
La secuencia de creación del modelo, basado en la tabla de la topología es la siguiente:

- Crear 2 capas de convolución de 64 canales cada una con un kernel 3x3
- Crear una capa de maxpool con un tamaño de 2x2 y un paso de 2x2
- Crear 2 capas de convolución de 128 canales cada una con un kernel 3x3
- Crear una capa de maxpool con un tamaño de 2x2 y un paso de 2x2
- Crear 3 capas de convolución de 256 canales cada una con un kernel 3x3
- Crear una capa de maxpool con un tamaño de 2x2 y un paso de 2x2
- Crear 3 capas de convolución de 512 canales cada una con un kernel 3x3
- Crear una capa de maxpool con un tamaño de 2x2 y un paso de 2x2
- Crear 3 capas de convolución de 512 canales cada una con un kernel 3x3
- Crear una capa de maxpool con un tamaño de 2x2 y un paso de 2x2

Un modelo no se considera completo solo con la entrada de datos y las capas de pooling y convolución que es lo que se ha detallado hasta el momento. Para poder terminarlo se deben agregar una capa de aplanado (flatten) seguida por una o más capas densas con una activación de cierto tipo. En el caso del estudio propuesto se utiliza una activación tipo ReLu, o de unidad lineal rectificada para las primeras dos

capas densas. Ambas capas densas se agregaron con un número arbitrario suficientemente grande de perceptrones en las primeras dos, se configuró con 4,096. Esto implica que a la salida de las capas de convolución y pooling se aplana la salida y se cuenta con 32,768 elementos los cuales cada uno se conecta a cada uno de los elementos de la primera capa densa ( $4,096 \times 32,768$  conexiones). Los 4,096 de estos perceptrones se conecta a la siguiente capa densa ( $4,096 \times 4,096$  conexiones) generando así otras 4,096 salidas. Las 4,096 salidas son finalmente utilizadas para conectarse cada una a otra capa densa, pero esta de solo 12 nodos. Estos nodos pertenecen a la clasificación de cada categoría que fue dada de alta en el modelo. Al final cada uno de los 12 nodos termina con un valor de pertenencia o semejanza que nos indica qué tanto la imagen pertenece a la categoría del perceptrón. Dicho valor se puede utilizar para finalmente decidir a qué clase pertenece la imagen que fue analizada. La última capa densa, la de clasificación, utiliza un tipo diferente de activación, la cual es llamada softmax. La última capa dará un valor entre 0 y 1 para cada nodo basado en la confianza del modelo sobre a qué clase pertenece cada imagen.

Para efectos de prueba y documentación se decidió agregar un paso donde en vez de tener dos capas densas de 4,096 nodos cada una, el número se redujo a solo 30 por capa y manteniendo 12 a la salida para la categorización. Este ejemplo se ve en la siguiente imagen y será el que, en la siguiente etapa, la de entrenamiento se ilustrará. Como se puede apreciar las capas densas están completamente interconectadas entre sí y con la última capa que al final otorga 12 salidas.



**Figura 4-26** Visualización de las 3 capas finales de un modelo de 30 nodos

Las líneas de conexión entre cada nodo llevan un peso sináptico del cual, el algoritmo estará modificando en base al entrenamiento para así obtener los resultados óptimos. Es decir, el algoritmo estará modificando el valor de cada conexión vía los pesos en base a qué tanto aporta para una correcta activación.

El último paso de esta etapa es el de compilar el modelo para esto hay que terminar de definir el optimizador y la velocidad o tasa de aprendizaje. Para efectos de la implementación se utilizó un optimizador Adam para alcanzar el mínimo global y una tasa de aprendizaje de 0.001.

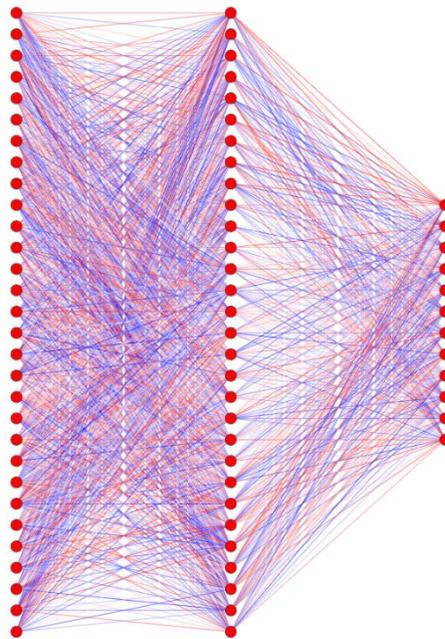
#### **4.5.4. Entrenar modelo**

El entrenamiento del modelo todavía requiere de algunos elementos de configuración adicionales a lo que se especificó anteriormente. Se debe asignar un parámetro de los resultados del modelo para utilizar como referencia para el entrenamiento. El parámetro utilizado en la implementación es `val_acc` o `validation accuracy`. Si el `validation accuracy` de una época o iteración es mayor al de la anterior el modelo se

guardará en el disco duro de la computadora. Otro parámetro que configurar es el evento para detener el entrenamiento, en el caso de la implementación se decidió que si en 50 épocas el modelo no ve mejoraría en `val_acc` se debe detener el entrenamiento del modelo. A este parámetro también se le llama paciencia.

Las imágenes, si bien están disponibles y accesibles en el entorno de programación no han sido cargadas al modelo. Para cargarlas se debió configurar cuantos pasos por época se desean lo cual configura el tamaño del paquete que se procesa.

Una vez realizado esto se puede ejecutar el entrenamiento. Si se tratara de describir en pocas palabras lo que el entrenamiento realiza, pudiera decirse que juega con el peso de las conexiones de manera que la predicción sea más acertada. Por ejemplo, para el caso de la red de 30x30x12 que se está analizando como ejemplo ilustrativo el resultado del entrenamiento después de 422 épocas se muestra en la Figura 4-27.



**Figura 4-27** Visualización de las 3 capas con pesos de conexión

No todas las conexiones tienen el mismo nivel de importancia para las clasificaciones. En la Figura 4-27 contrario a la Figura 4-26, se puede apreciar el peso de cada conexión. Los valores azules tienen un peso positivo, los valores rojos tienen un peso

negativo. Esto nos indica que algunas conexiones son más relevantes que otras para ciertos nodos. Aquí entra el análisis de la red, de lo cual podríamos derivar dos conclusiones dependiendo de los resultados. Se podría percibir que algunas conexiones y por lo tanto nodos no tienen una significancia suficiente como para mantenerlos dentro del modelo y pudieran ser eliminados simplificando así la red. El caso contrario podría indicar que hacen falta más perceptrones o lo que es lo mismo, que la complejidad de la red no es suficiente para interpretar la complejidad de la imagen y categorización que se desea.

Que la complejidad no sea suficiente implicaría realizar cambios al modelo y realizar nuevos entrenamientos. El proceso de configuración y entrenamiento se realizó varias veces con diferentes arquitecturas hasta terminar con la que anteriormente fue presentada en la Tabla 4-4 la cual dio resultados satisfactorios a la hora de clasificación.

## **4.6. Evaluación de modelo**

Los datos resultantes pueden ser presentados y evaluados de diferentes maneras dependiendo de lo que se quiera analizar. Las representaciones que fueron más relevantes se presentan en esta sección.

La evaluación del modelo se realizó tanto en simulación como en campo. Primeramente, en simulación se realizó una serie de validaciones con diferentes grupos de datos para obtener un promedio de clasificación del 99.6% en el modelo final. Con este fin se utilizó el conjunto de datos de 20,000 fotografías con tamaño de lote de prueba del 10%. Los resultados generales se aprecian en la Tabla 4-5

Tamaño	Batch	Precisión general	Correctamente clasificadas	Incorrectamente clasificadas
2000	1	99.45	1989	11
2000	2	99.35	1987	13
2000	3	99.25	1985	15
2000	4	99.95	1999	1
2000	5	99.95	1999	1
2000	6	99.8	1996	4
2000	7	99.5	1990	10
2000	8	99.7	1994	6
2000	9	99.55	1991	9
2000	10	99.5	1990	10
20000	Promedio	99.6	19920	80

**Tabla 4-5** Resultados de precisión generales

Se aprecia que la precisión promedio de clasificación correcta del sistema es del 99.60%. El valor es representativo pero los resultados pueden analizarse aún más si la información se divide entre conectores en buen estado y conectores en mal estado en cada paquete. La diferencia entre los resultados de la división se puede evaluar comparando la Tabla 4-6 con la Tabla 4-7, siendo la primera sobre conectores en buen estado y la segunda sobre conectores en mal estado. En este caso un conector en buen estado que es clasificado incorrectamente es rechazado, lo cual, si bien es una molestia para la armadora, no es un error tan grave como el error de tipo dos, el cual implica que un conector que debiera ser rechazado es aceptado y “engaña” al sistema.

Conectores en buen estado en batch	Correctamente clasificados	Incorrectamente clasificados	Precisión error tipo 1
1622	1611	11	99.32
1486	1475	11	99.26
1595	1581	14	99.12
1609	1608	1	99.94
1616	1615	1	99.94
1603	1599	4	99.75
1565	1556	9	99.42
1573	1567	6	99.62
1532	1523	9	99.41
1599	1589	10	99.37
15800	15724	76	99.52

**Tabla 4-6** Precisión clasificando conectores en buen estado

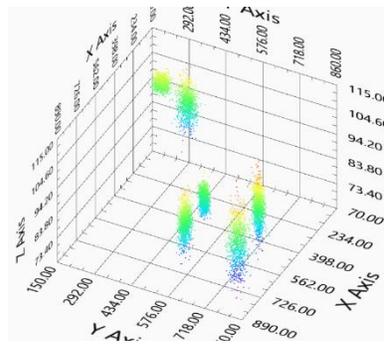
Como se puede apreciar la precisión del sistema cuando se analiza conectores en buen estado es menor al promedio general (99.6% contra 99.52%). Por otro lado, esto implica que la precisión cuando se analizan conectores en mal estado debe ser mayor al promedio.

Conectores en mal estado en batch	Correctamente clasificados	Incorrectamente clasificados	Precisión error tipo 2
378	378	0	100.00
514	512	2	99.61
405	404	1	99.75
391	391	0	100.00
384	384	0	100.00
397	397	0	100.00
435	434	1	99.77
427	427	0	100.00
468	468	0	100.00
401	401	0	100.00
<b>4200</b>	<b>4196</b>	<b>4</b>	<b>99.91</b>

**Tabla 4-7** Precisión clasificando conectores en mal estado

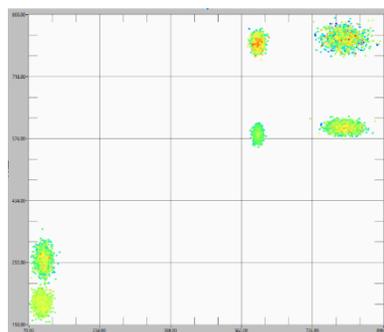
La precisión cuando se analizan conectores en mal estado sube hasta 99.91% cuando se trata de clasificar correctamente los conectores en mal estado. Esto no es al azar, el sistema fue entrenado y modificado para ser más exigente a la hora de rechazar un conector con un grado de pertenencia a la clase de mal estado.

Además del análisis antes mencionado se realizó un análisis secundario para evaluar la calidad del posicionador mecánico de manera indirecta. Para efectos del análisis de calidad del posicionador se consideraron únicamente los paneles de la marca 1. Una vez clasificados en las 6 clases que pertenecen a la marca 1, se graficaron en base a su centroide definido como las coordenadas x,y (escaladas de 0 a 1000) en donde se encuentran en la imagen y el eje Z de la gráfica es un valor de pertenencia (escala 0 a 120). La visualización tridimensional de los datos se observa en la Figura 4-28.



**Figura 4-28** Dispersión 3D de conectores antes de agrupar

Los resultados apuntan a lo esperado, se pueden distinguir los 6 grupos que se esperaban visualizar. En el caso de que el posicionador mecánico tuviera problemas, se esperaría que las agrupaciones en la Figura 4-29 fueran de mayor área. El hecho de que no lo sean nos indica que el diseño mecánico es adecuado, la separación existente entre los centroides en el ángulo seleccionado es tal que permite distinguir los 6 grupos uno del otro utilizando únicamente el parámetro de ubicación X,Y del conector. En caso de que existiera un mal posicionamiento estos grupos se apreciarían más próximos los unos a los otros. La variabilidad de la posición también se ve representada con la zona de dispersión que cada grupo tiene. Si el posicionador mecánico tuviera “juego” los grupos tendrían una mayor dispersión cuando se visualizan en el eje XY lo cual tendría efectos sobre la clasificación porque existiría más variación también en las imágenes con respecto al ángulo en el que aparecen los conectores con respecto a la imagen.

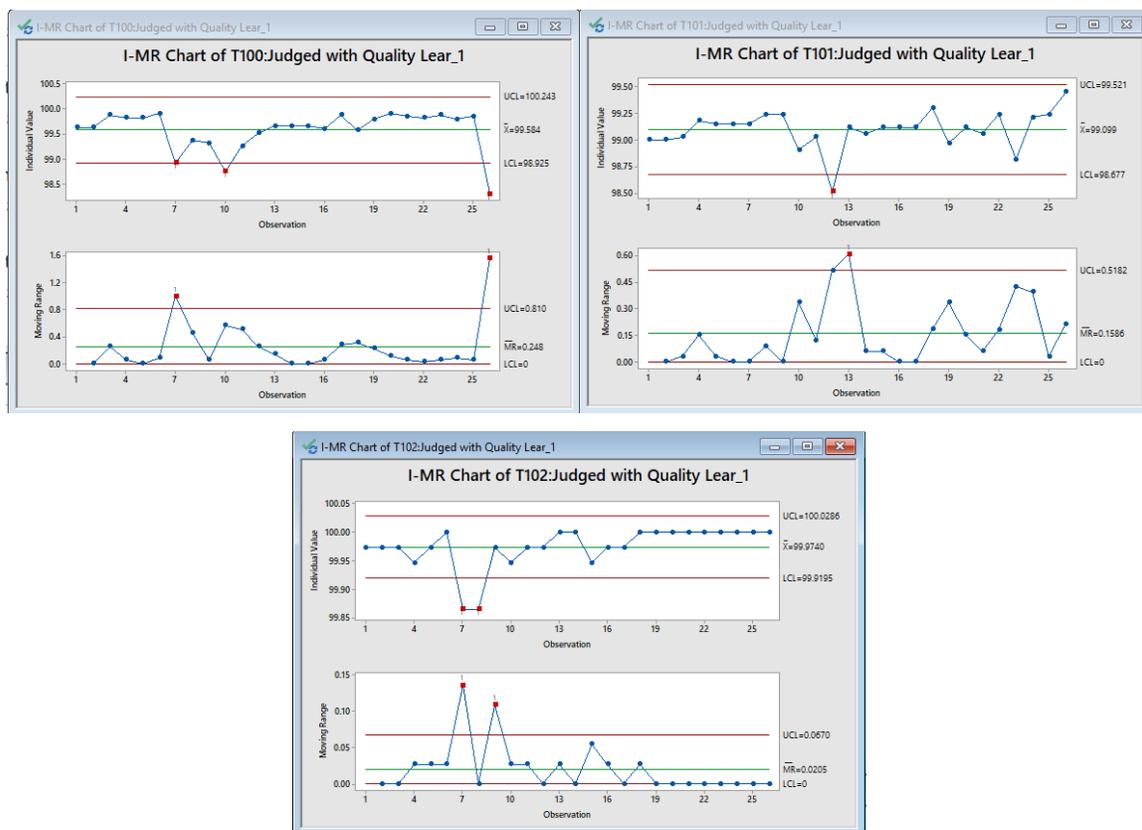


**Figura 4-29** Dispersión de conectores antes de agrupar en XY

Una vez implementado en la línea de producción el clasificador sirvió para generar los gráficos de control donde se utiliza el valor de pertenencia a la clase, si bien en algunos

casos con un escalamiento aplicado al valor, como un indicador para determinar si un conector pasa los criterios de calidad.

Analizando los datos de salida del clasificador se crearon gráficos de control, los cuales fueron útiles para evaluar el desempeño del algoritmo y evaluar si se requería algún tipo de reentrenamiento. Cuando se encontraron valores atípicos las imágenes utilizadas para ese registro fueron evaluadas. En algunos casos la causa era algo que podía ser ignorado y en otros casos era algo que requería mayor atención. En el gráfico de control de la Figura 4-30 se muestran los resultados de una prueba en línea donde se encontraron 3 valores atípicos.



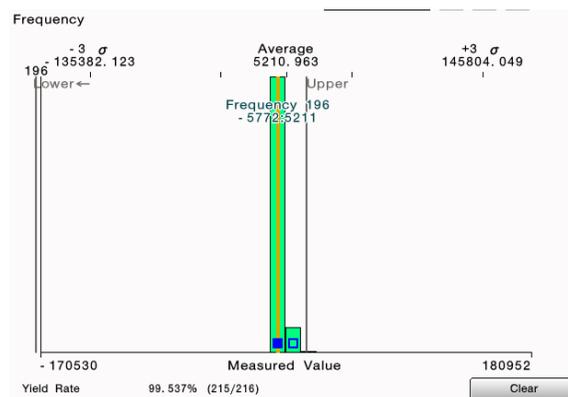
**Figura 4-30** Gráficos de control

Dos de los tres casos fueron atribuidos a variaciones en el conector ocasionadas por el proveedor, las cuales no debían ser usadas por el operador cuando el sistema clasificador por visión estaba en funcionamiento. En el tercer caso se encontró que era

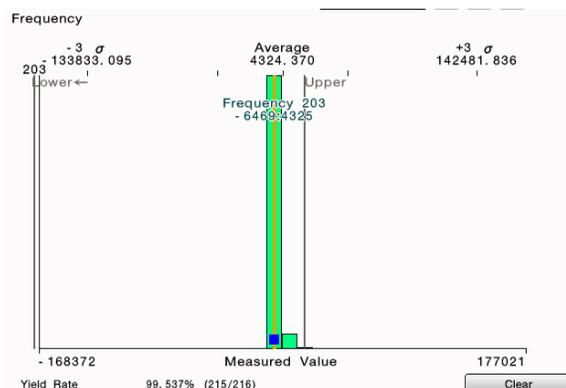
una etiqueta colocada físicamente en el conector (sticker) que imposibilitaba que el sistema pudiera realizar una clasificación con certeza. A pesar de el sistema le asigno un valor relativamente alto de pertenencia a los conectores con la información que se le alimentó sin ser suficientemente alto como para declarar que pertenece a un conector en buen estado.

Además de los gráficos de control se crearon histogramas del valor medido en corridas de prueba para estimar dónde se encontraba la media de las medidas. Los resultados de las pruebas varían de acuerdo al conector y el entrenamiento utilizado.

En el histograma de la Figura 4-31 se puede apreciar 215 de las 216 piezas fueron aceptadas y estas contaban con un valor promedio de 5210.963 con algunas piezas llegando a valores más altos de pertenencia. Para la elaboración de las gráficas se usó el score real no escalado entre 0 y 1 para poder realizar comparaciones entre diferentes conectores de manera más adecuada. Se puede apreciar el desempeño del caso ideal que son conectores en buen estado sin daños y solo variando en el ángulo en el que aparecen en la imagen dentro de los márgenes esperados.

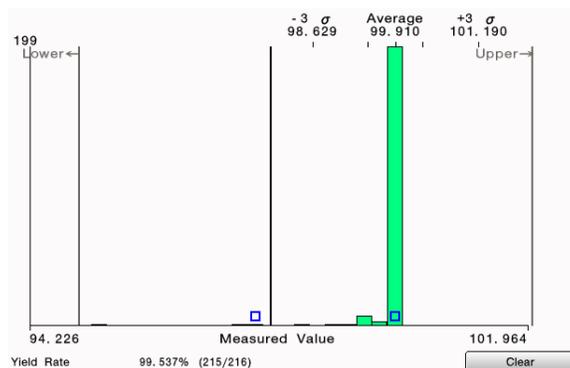


**Figura 4-31** Marca 1 conector medio



**Figura 4-32** Marca 1 conector derecho

Cambiando la vista a valores escalados del 0 al 100% como se aprecia en la Figura 4-33 se aprecia que la mayoría de los valores de las muestras analizadas se encuentran en el intervalo 99.91 % de pertenencia. Evidentemente algo no puede superar el 100% de pertenencia por lo cual no se forma la distribución normal como se hubiera esperado.

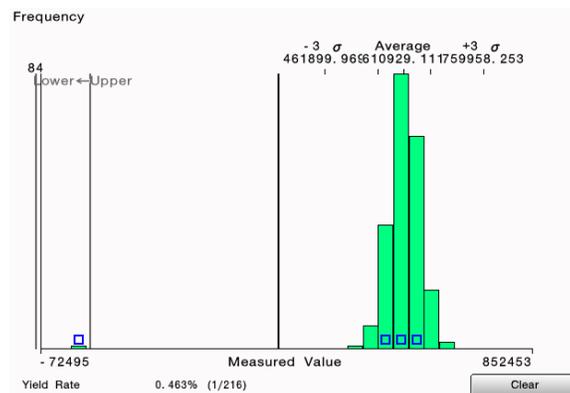


**Figura 4-33** Marca 1 conector izquierdo

Las pruebas se realizaron en campo y en ocasiones se encontraron conectores con error, los cuales el sistema correctamente clasificó como inadecuados ya sea por no pertenecer a una clase OK, lo cual implica un valor bajo con respecto al límite o threshold establecido o una pertenencia a una clase de NG o no aceptado, un score muy alto en una de las clases NG.

Con las pruebas realizadas se apreció un fenómeno interesante; a pesar de que un conector sea de la marca 1 activa algunos de los perceptrones correspondientes al

clasificador de la marca 2. La activación parcial se debe a que a pesar de ser diferentes los conectores presentan algunas similitudes y el modelo las toma en cuenta. A pesar de las similitudes el valor medido al final de activación del clasificador de la marca dos no es suficientemente alto como para ser considerado perteneciente a la clase. Esto se puede apreciar en la Figura 4-34 donde se ve que el valor es registrado, pero no es suficientemente alto para ser aceptado.



**Figura 4-34** Marca 2 conector derecho cuando es mostrado marca 1

## **5. CONCLUSIONES RECOMENDACIONES Y TRABAJO FUTURO**

Como conclusión se logró reducir el tiempo de inspección de 35 segundos a solo 10 y reducir el espacio utilizado de 3 estaciones a solo 1. El sistema alcanzó una precisión del 99.6% bajo las condiciones de evaluación y el arreglo mecánico de posicionamiento fue suficientemente robusto y fácil de utilizar para ser aceptado en la empresa. Los datos generados fueron almacenados en una base de datos la cual posibilita el desarrollo de herramientas de trazabilidad.

Para las organizaciones es de suma importancia contar con sistemas que puedan asegurar la calidad de sus productos para cumplir con las expectativas de sus clientes. Los métodos de inspección por visión artificial son compatibles con esta meta. Particularmente los nuevos desarrollos en el área de redes neuronales pueden ser de gran ayuda para obtener sistemas capaces de clasificar imágenes en tiempo real y realizar decisiones con un alto grado de precisión. El uso de este tipo de tecnologías posibilita la implementación de inspecciones sobre el 100% de la producción y esto en consecuencia permite que el manejo de la calidad en la organización sea implementado en mayor grado.

A futuro pudiera mejorarse el hardware utilizado para implementar cámaras con mejores elementos como enfoque automático. También pudiera trabajarse con entrenamiento en línea de producción es decir que conforme más paneles analicen en la línea el sistema vaya aprendiendo a clasificar de mejor manera.

## 6. REFERENCIAS

- Hanaysha, J., Hilman, H. y Abdul-ghani, N.H., 2014. Direct and Indirect Effects of Product Innovation and Product Quality on Brand Image: Empirical Evidence from Automotive Industry. *International Journal of Scientific and Research Publications*, 4(11). Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.651.7100&rep=rep1&type=pdf>.
- Weckenmann, A., Akkasoglu, G. y Werner, T., 2015. Quality management – history and trends P. Vidosav Majstorovic and Dr Albert Weckenmann, ed. *The TQM Journal*, 27(3), pp.281–293.
- Xu, Z., Dang, Y. y Munro, P., 2018. Knowledge-driven intelligent quality problem-solving system in the automotive industry. *Advanced Engineering Informatics*, 38, pp.441–457.
- Szeliski, R., 2011. Image processing. En R. Szeliski, ed. *Computer Vision: Algorithms and Applications*. Texts in Computer Science. London: Springer, pp. 87–180. Disponible en: [https://doi.org/10.1007/978-1-84882-935-0\\_3](https://doi.org/10.1007/978-1-84882-935-0_3)
- Malamas, E.N. et al., 2003. A survey on industrial vision systems, applications and tools. *Image and Vision Computing*, 21(2), pp.171–188.
- Janke, J., Castelli, M. y Popovič, A., 2019. Analysis of the proficiency of fully connected neural networks in the process of classifying digital images. Benchmark of different classification algorithms on high-level image features from convolutional layers. *Expert Systems with Applications*, 135, pp.12–38.
- Semeniuta, O. et al., 2018. Towards increased intelligence and automatic improvement in industrial vision systems. *Procedia CIRP*, 67, pp.256–261.
- HajiRassouliha, A. et al., 2018. Suitability of recent hardware accelerators (DSPs, FPGAs, and GPUs) for computer vision and image processing algorithms. *Signal Processing: Image Communication*, 68, pp.101–119.
- Feng, X. et al., 2019. Computer vision algorithms and hardware implementations: A survey. *Integration*, 69, pp.309–320.
- Lecun, Y. et al., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp.2278–2324.
- Wason, R., 2018. Deep learning: Evolution and expansion. *Cognitive Systems Research*, 52, pp.701–708.

- LeCun, Y., Bengio, Y. y Hinton, G., 2015. Deep learning. *Nature*, 521(7553), pp.436–444.
- Chen, W. y Shi, K., 2019. A deep learning framework for time series classification using Relative Position Matrix and Convolutional Neural Network. *Neurocomputing*, 359, pp.384–394.
- Iwahori, Y. et al., 2018. Defect Classification of Electronic Board Using Dense SIFT and CNN. *Procedia Computer Science*, 126, pp.1673–1682.
- Ayub, M.A., Mohamed, A.B. y Esa, A.H., 2014. In-line Inspection of Roundness Using Machine Vision. *Procedia Technology*, 15, pp.807–816.
- Keyence, 2019. Keyence Machine Vision Academy. Disponible en: [https://www.controldesign.com/assets/10WPpdf/100208\\_Keyence\\_Machine\\_Vision.pdf](https://www.controldesign.com/assets/10WPpdf/100208_Keyence_Machine_Vision.pdf)
- Erik K. Hendriksen, 2010. *Jig and Fixture Design Manual*, New York, United States: Industrial Press. Disponible en: <http://archive.org/details/JigAndFixtureDesignManual>
- Keyence Corporation, 2016. Engineer's know-how Machine Vision. Disponible en: [https://www.keyence.com/mykeyence/?ptn=001&dLangType=en-US&dLangId=.](https://www.keyence.com/mykeyence/?ptn=001&dLangType=en-US&dLangId=)
- Qiao, Y., Truman, M. y Sukkarieh, S., 2019. Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming. *Computers and Electronics in Agriculture*, 165, p.104958.
- National instruments, 2004. IMAQ - IMAQ Vision for LabVIEW User manual. Disponible en: <http://www.ni.com/pdf/manuals/371007a.pdf>.
- Santos, T.T. et al., 2020. Grape detection, segmentation, and tracking using deep neural networks and three-dimensional association. *Computers and Electronics in Agriculture*, 170, p.105247.
- Vaidya, O.S. y Gandhe, D.S.T., 2019. Improvement in Image Alignment using Hybrid Warping Technique for Image Stitching. , 12(3), p.7.
- ankur6ue, 2019. Neural Network Loss Visualization – Telesens. Disponible en: <http://www.telesens.co/2019/01/16/neural-network-loss-visualization/>
- Li, H. et al., 2018. Visualizing the Loss Landscape of Neural Nets. *arXiv:1712.09913 [cs, stat]*. Disponible en: <http://arxiv.org/abs/1712.09913>

Arpe, M., Connectors for automotive safety restraints | Connector Supplier. *A Connector Can Save Your Life*. Disponible en: <https://www.connectorsupplier.com/connectors-for-automotive-safety-restraints-101513/>

leda, K., 2014. A connector can save your life. *SlideServe*. Disponible en: <https://www.slideserve.com/leda/a-connector-can-save-your-life>