

Diseño de un sistema de identificación para la clasificación automática de tornillos
metálicos usados en osteosíntesis.

Hazel David Pinzón Uribe

Camilo Enrique Sanmiguel Arenas

Trabajo de Grado para Optar el título de Ingeniero de Sistemas

Director

Andrés Leonardo González Gómez
PhD(c) en Ciencias de la computación

Codirector

Jaime Enrique Meneses Fonseca
PhD en Ciencias para la Ingeniería

Universidad Industrial de Santander
Facultad de Ingenierías Fisicomecánicas
Escuela de Ingeniería de Sistemas e Informática
Bucaramanga

2023

Dedicatoria

A mi madre, por estar conmigo desde la distancia, por velar trabajando para cuidarme y que nada me haga falta. A mi padre, por sus sabios consejos y sobre todo por su amor.

A mi abuela por criarme cuando mis padres estaban ocupados trabajando arduamente para que nunca me faltara nada.

A mi compañero Camilo por su arduo trabajo y desempeño con quien compartí, estude, trabaje y me divertí durante toda mi formación universitaria.

A mis amigos y compañeros que siempre confiaron en mí y estuvieron presentes en los buenos y malos momentos.

Hazel David Pinzón Uribe

Dedicatoria

A mi amada Mafe, por ser una persona muy importante en mi vida, quien me acompañó en cada momento en la realización de este proyecto y me dio su cariño y su apoyo incondicional.

A mi compañero y amigo Hazel con quien compartí, estude, trabaje y me divertí durante toda mi formación universitaria por ser una gran persona y haberse esforzado tanto.

A mis amigos Andrea, Sebastián, Leonardo y Mario quienes estudiaron conmigo y de alguna u otra forma aportaron para mi desarrollo personal y profesional.

Y, por último, pero no menos importante a mis amigos Jeison, Jose y Carlos que desde la distancia siempre me apoyaron.

Camilo Enrique Sanmiguel Arenas

Agradecimientos

A nuestras familias por estar con nosotros en todo momento. A nuestros amigos por hacer el camino de la vida más grato. A los profesores Andrés González y Jaime Meneses, por compartir tiempo y sabiduría con nosotros para el desarrollo de este proyecto.

Tabla de Contenido

Introducción	13
1. Planteamiento y justificación del problema	15
2. Objetivos	18
2.1 Objetivo general	18
2.2 Objetivos específicos	18
3. Sistema de adquisición	19
3.1 Microscopio digital	19
3.2 Tornillos de osteosíntesis	20
3.2.1 Tipos de tornillos en osteosíntesis.	21
3.3. Hardware	26
3.4. Configuración experimental	27
4. Metodología	28
4.1 Montaje experimental	28
4.1.1 Microscopio digital.	28
4.1.2 Iluminación.	30
4.1.3 Soporte.	31

4.2 Calibración	33
4.3 Conjunto de datos	37
4.4 Implementación de redes neuronales	41
4.5 Interfaz de usuario	45
4.5.1 Rotación de la Imagen.	49
4.5.2 Medición del tornillo.	53
4.5.3 Suavizado de Contorno.	55
5. Resultados	57
5.1 Resultados de red	57
5.2 Análisis de exactitud	59
5.2.1 Tornillo tipo B.	62
5.2.2 Tornillo tipo C	63
5.3 Análisis de precisión	64
6. Conclusiones	69
Referencias Bibliográficas	71

Lista de Figuras

Figura 1 Microscopio Digital USB y sus partes. Adaptado de Dino-Lite. (2021).	20
Figura 2 El trayecto del tornillo se perfora con una broca (a). El taladrado de un diámetro ligeramente superior al que tiene el tornillo en la parte más cercana a su cabeza permite obtener la máxima compresión (b) y (c). Tomado de (Cognet et al., 2009).	21
Figura 3 Tipos de tornillos de osteosíntesis. Adaptado de (Cognet et al., 2009).	23
Figura 4 Diferentes tipos de tornillos usados: (a) tornillo tipo A, (b) tornillo tipo B, (c) tornillo tipo C, (d) tornillo tipo D.	25
Figura 5 Portátil Asus x555dg.	26
Figura 6 Configuración experimental del microscopio Dino Lite Edge conectado al portátil.	27
Figura 7 Diagrama de la metodología implementada.	29
Figura 8 Tornillo con luz directa.	30
Figura 9 Base LED de luz de luz cálida, dimensiones 29,7 cm de ancho × 29,7 cm de alto, potencia de luz de 24W.	31
Figura 10 (a) Botón de liberación rápida y (b) perilla de enfoque fino del soporte vertical RK-10. Dino-Lite (2021).	32
Figura 11 Altura y montaje de la base junto al microscopio.	33
Figura 12 sistema calibración con una longitud 10 mm.	34

Figura 13 Implementación algoritmo binarización.	35
Figura 14 Sistema calibración binarizado y con longitud promediada medida en pixeles.	35
Figura 15 Algoritmo conversión de pixel a milímetro.	36
Figura 16 (a) captura con base LED (b) captura de un tornillo con la base LED.	38
Figura 17 Algoritmo detección tornillo.	39
Figura 18 (a) muestra (b) muestra binarizada.	39
Figura 19 Comparación muestra con imagen de fondo (a) contra imagen sin fondo (b).	40
Figura 20 Algoritmo sustraer fondo.	41
Figura 21 Muestra tornillos redimensionados (150 x 150) px.	43
Figura 22 Código data augmentation.	44
Figura 23 Esquema del modelo propuesto.	45
Figura 24 Ventana principal DinoControl.	46
Figura 25 Interfaz DinoControl.	48
Figura 26 Tornillo Binarizado y clasificado.	49
Figura 27 Imagen tornillo separado del fondo.	50
Figura 28 Algoritmo implementación autovectores.	52
Figura 29 Imagen tornillo horizontal.	53

Figura 30 Código para calcular ancho de los tornillos.	54
Figura 31 Código para calcular alto de los tornillos.	55
Figura 32 Algoritmo suavizado de contorno.	56
Figura 33 Grafica con suavizado de contorno.	56
Figura 34 Evaluación redes neuronales con red hecha manualmente.	58
Figura 35 Evaluación redes convolucionales MobileNet con Transfer learning.	59
Figura 36 Perfiles graficados de (a) tornillo tipo B y (b) tipo C con sus respectivos largo y ancho de tornillo.	60
Figura 37 Toma de medida del (a) tornillo B y (b) tornillo C con calibrador pie de rey.	61
Figura 38 Muestras de tornillos (a) tipo B y (b) tipo C en las cuatro posiciones establecidas a una distancia $Z = 36$ cm.	62
Figura 39 Muestras de tornillo B en diferentes posiciones a una distancia $Z = 36$ cm.	64
Figura 40 Función de dispersión.	66
Figura 41 Prueba normalidad.	67
Figura 42 Distribución de probabilidad de medidas experimentales para el ancho del tornillo.	68
Figura 43 Distribución de probabilidad de medidas experimentales para el largo del tornillo.	68

Lista de tablas

Tabla 1	Especificaciones ópticas del microscopio digital. Adaptado de Dino-Lite (2021).	28
Tabla 2	Funcionalidades Interfaz	46
Tabla 3	Medidas teóricas tomadas con el calibrador pie de rey de tornillos tipo B y tipo C.	61
Tabla 4	Medidas obtenidas para el tornillo B variando la distancia de referencia Z	63
Tabla 5	Medidas obtenidas para el tornillo C variando la distancia de referencia Z.	63
Tabla 6	Tabla de medidas del tornillo tipo B a una distancia $Z = 36$ cm.	65

Resumen en español

Título: Diseño de un sistema de identificación para la clasificación automática de tornillos metálicos usados en osteosíntesis *

Autores: Hazel David Pinzón Uribe - Camilo Enrique Sanmiguel Arenas **

Palabras Clave: Visión por computador, inteligencia artificial, sistema de control, redes convolucionales, osteosíntesis, clasificación.

Descripción: La implementación de un sistema automatizado de identificación y clasificación de tornillos ofrece numerosos beneficios. Al reducir los errores en la clasificación, se mejora la precisión y la eficiencia de los procedimientos quirúrgicos. Además, se optimizan los recursos humanos al apoyar el trabajo de los operarios. Esta puede ser una tarea propensa a errores, debido a la gran variedad de tornillos existentes en el mercado y a la dificultad de distinguir entre ellos. Además, el proceso manual de clasificación puede ser costoso en términos de tiempo, recursos humanos e inducir cansancio en los operarios, lo que puede afectar la eficiencia del proceso quirúrgico y aumentar el riesgo de errores y complicaciones. Por lo tanto, se necesita una solución automatizada que pueda clasificar de manera precisa y eficiente los tornillos de osteosíntesis para mejorar la seguridad de los procedimientos quirúrgicos, que apoyen la labor de operarios humanos, lo que hace al sistema más eficiente y efectivo. En este trabajo se presenta, un sistema de identificación que permita clasificar automáticamente tornillos metálicos a partir de imágenes bidimensionales implementando técnicas de visión por computador y redes neuronales convolucionales para reducir el nivel de error en procesos de identificación y clasificación de tornillos de osteosíntesis.

* Trabajo de grado

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: Andrés Leonardo González Gómez, PhD(c) en Ciencias de la computación. Codirector: Jaime Enrique Meneses Fonseca, PhD en Ciencias de la Ingeniería.

Abstract

Title: Design of an identification system for the automatic classification of metal screws used in osteosynthesis *

Authors: Hazel David Pinzón Uribe - Camilo Enrique Sanmiguel Arenas **

Keywords: Computer vision, artificial intelligence, control system, convolutional networks, osteosynthesis, classification.

Description: Implementing an automated screw identification and sorting system offers numerous benefits. By reducing errors in sorting, the accuracy and efficiency of surgical procedures is improved. In addition, human resources are optimized by supporting the work of the operators. This can be an error-prone task due to the wide variety of screws on the market and the difficulty in distinguishing between them. In addition, the manual sorting process can be costly in terms of time, human resources and induce operator fatigue, which can affect the efficiency of the surgical process and increase the risk of errors and complications. Therefore, there is a need for an automated solution that can accurately and efficiently sort osteosynthesis screws to improve the safety of surgical procedures, supporting the work of human operators, which makes the system more efficient and effective. In this work we present an identification system that allows the automatic classification of metal screws from two-dimensional images by implementing computer vision techniques and convolutional neural networks to reduce the level of error in identification and classification processes of osteosynthesis screws.

* Bachelor Thesis

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: Andrés Leonardo González Gómez, PhD(c) en Ciencias de la computación. Codirector: Jaime Enrique Meneses Fonseca, PhD en Ciencias de la Ingeniería

Introducción

La clasificación manual de los tornillos es un proceso propenso a errores humanos, lo que puede tener graves consecuencias para el paciente, por esta razón, se hace necesario el desarrollo de un sistema de identificación automático que permita clasificar de manera rápida y precisa los tornillos de osteosíntesis. Este proyecto propone una estrategia para la clasificación de diferentes tipos tornillos de osteosíntesis, apoyándose en inteligencia artificial, junto a una interfaz de usuario, que permita su uso de manera sencilla. La implementación de este sistema pretende reducir errores al momento de clasificar los tornillos de osteosíntesis mediante un sistema de visión por computador que permite identificar un objeto en una imagen y clasificar dicho objeto basándose en sus características, con el propósito de reducir errores en el trabajo manual y a su vez de aumentar la productividad. Para el desarrollo de este proyecto de investigación se cuenta con el apoyo de un fabricante local, que proporciona las muestras necesarias, se pretende un alcance de aplicación para cualquier proceso en el que se requiera clasificar e identificar tornillos de este tipo.

Con el objetivo de proponer una posible solución a la identificación y clasificación automática de tornillos de osteosíntesis, se planea comenzar definiendo la configuración experimental necesaria para la correcta adquisición de imágenes del sistema de visión por computador, posteriormente la construcción de una base de datos implementando técnicas de aumento de datos para reducir tiempos y mejorar la diversidad de estos. Luego se implementa una red neuronal convolucional existente aplicando transferencia del aprendizaje para mejorar significativamente la eficiencia, así aplicarla en una interfaz gráfica desarrollada en lenguaje

Python con librerías open source que permita la toma de muestras y posteriormente clasificarlas de manera automática.

De esta manera se pretende minimizar los errores en la clasificación del producto y disminuir la incertidumbre de una implantación errónea en el tratamiento de osteosíntesis.

1. Planteamiento y justificación del problema

La osteosíntesis se define como la reducción de una fractura y su fijación con implantes metálicos (Ramos-Maza et al., 2016). Este procedimiento se describe en las siguientes etapas, la exposición de la lesión; la reducción y fijación temporal de la fractura; la fijación definitiva de la fractura y la sutura de las partes blandas (Ramos-Maza et al., 2016).

La osteosíntesis con placa y tornillos es una técnica conocida y utilizada por los cirujanos para la fijación de fragmentos óseos. Siendo los tornillos la herramienta básica para la fijación (Cognet et al., 2009). Respecto a los tornillos empleados, estos son clasificados a partir de tipos de cabezas y roscas o por la forma de uso, diseño, dimensiones de su diámetro, área de aplicación, características, función o mecanismo (L. Rodríguez., 2011).

Para la identificación y especificación convencional de los tornillos se requiere de herramientas, como calibradores y reglas, para medir el diámetro y la longitud del tornillo. Al manufacturar un tornillo de osteosíntesis, este debe pasar por un proceso de clasificación, que en muchas ocasiones se realiza por operarios que deben identificarlos de forma manual. Este procedimiento de clasificación manual implica que la eficiencia del proceso se vea comprometida además de incrementar la probabilidad de error debido a factores humanos.

La correcta identificación y clasificación es necesaria para un control de calidad, más estricto, que requieren los tornillos destinados a osteosíntesis. Ésta reduciría de manera significativa incidencias negativas en el proceso de producción, lo que repercute directamente en la disminución de posibles desperfectos que atraviesen el filtro del control de calidad y puedan afectar la confianza de los compradores.

Las posibles consecuencias de una incorrecta identificación y clasificación van desde la tardía identificación de un error en una parte previa de la cadena de producción, ralentización a la producción al requerir corregir el error, hasta la distribución de piezas incorrectas o imperfectas, lo que ultimadamente resultaría en riesgo a la salud de los pacientes tratados con esas piezas y desconfianza por parte de los centros que las usaron (Velásques Hernández, E. G., 2014).

La gran ventaja de los sistemas de clasificación por visión artificial es que pueden efectuar tareas repetitivas con rapidez y precisión, permitiendo distinguir detalles que no son visibles por el ojo humano, lo que conlleva al aumento del rendimiento en la cadena de producción y reducción de costos en la mano de obra, ya que permite el funcionamiento las 24 horas del día, evitando los errores humanos (Velásques Hernández, E. G., 2014).

Con base en lo expuesto se evidencia una problemática relacionada directamente con la clasificación de los diferentes tipos de tornillos, razón por la cual se plantea la siguiente pregunta de investigación, con la intención de contribuir a la solución del problema, ¿es posible optimizar la etapa de clasificación de tornillos de osteosíntesis, en la etapa del control de calidad, mediante un sistema de visión por computador que implemente modelos de aprendizaje profundo?

Teniendo en cuenta que las técnicas de visión por computador y procesamiento de imágenes otorgan a un sistema de control visual capacidades suficientes para adquirir y procesar imágenes del mundo real, que apoyan la labor de operarios humanos, lo que hace al sistema más eficiente y efectivo; y considerando que el uso de técnicas de “Aprendizaje Profundo” como las redes neuronales convolucionales resultan muy efectivas en los procesos de clasificación de imágenes, se plantea como hipótesis de entrada para esta propuesta de investigación, que: si es

posible optimizar el proceso de clasificación y automatización en la identificación de diferentes tipos de tornillos mediante la adecuada inclusión de estas técnicas.

Con este trabajo de investigación, se propone una solución para reducir el nivel de error en procesos de identificación y clasificación de tornillos de osteosíntesis mediante un sistema de visión por computador que implemente técnicas de aprendizaje profundo.

2. Objetivos

2.1 Objetivo general

Diseñar un sistema de identificación que permita clasificar automáticamente tornillos metálicos a partir de imágenes bidimensionales implementando técnicas de visión por computador y redes neuronales convolucionales.

2.2 Objetivos específicos

- Establecer las condiciones experimentales impuestas por el objeto de estudio, y definir la configuración experimental (hardware) apropiada.
- Crear un archivo digital de imágenes categorizadas de tornillos de osteosíntesis proporcionados por un fabricante local.
- Seleccionar e implementar la red convolucional que mejor se adapte a los requerimientos de la clasificación.
- Verificar los resultados obtenidos evaluando la arquitectura de red propuesta y realizar los ajustes pertinentes.
- Elaborar una interfaz de usuario que permita capturar las imágenes, procesarlas y clasificarlas para obtener la información métrica deseada de los tornillos de osteosíntesis.

3. Sistema de adquisición

En este capítulo se describen las herramientas que fueron necesarias para el desarrollo del proyecto tanto para adquirir la información como para el tratamiento de datos.

3.1 Microscopio digital

Para el desarrollo de este proyecto se usó un microscopio digital Dino-Lite Edge AM73915MZTL, con rango de magnificación entre 10x y 140x, un sensor CMOS de 5 MP, resolución espacial máxima de 2592x1944 píxeles, profundidad de campo ampliada entre 0.09 mm y 12 mm con una distancia de trabajo (distancia en Z) entre 23.45 cm y 3.05 cm, dimensiones de 11.9 cm (largo) x 3.3 cm (ancho), un peso de 110 g y 8 LEDs integrados controlables, en la figura 1 se puede ver al microscopio digital.

Dentro de las diferentes opciones disponibles en el mercado, se eligió este dispositivo por sus características ópticas adecuadas para la adquisición de imágenes de tornillos utilizados en osteosíntesis (ver tabla 1).

- Amplio rango de magnificación.
- Distancia de trabajo muy flexible.
- Profundidad de campo extendido.

Figura 1

Microscopio Digital USB y sus partes. Adaptado de Dino-Lite. (2021).

**3.2 Tornillos de osteosíntesis**


La osteosíntesis con placa y tornillos es una técnica conocida y utilizada por los cirujanos desde hace muchos años. En general, un tornillo se usa como medio de tracción para asegurar una compresión entre dos fragmentos óseos. La colocación de un tornillo en un hueso requiere una preparación previa de su trayecto, que se realiza mediante la perforación del hueso con un motor (Cognet et al., 2009).

La broca usada para esta perforación es de un diámetro ligeramente inferior al del tornillo. Por ejemplo, el uso de un tornillo cortical de 3.5 mm de diámetro necesita un orificio que se efectuará con una broca de 2.7 mm. Esta diferencia de diámetro permite que la rosca del tornillo se ancle al hueso (Cognet et al., 2009).

Para obtener un efecto de compresión máxima, el diámetro del orificio debe ser ligeramente superior al del tornillo en el lado de su cabeza (ver fig. 2(a)); como el anclaje del tornillo sólo se hace en su parte distal, el efecto de tracción se refuerza. El aterrajado permite crear un paso de tornillo en el hueso (ver fig. 2(b), 2(c)) (Cognet et al., 2009).

Figura 2

El trayecto del tornillo se perfora con una broca (a). El taladrado de un diámetro ligeramente superior al que tiene el tornillo en la parte más cercana a su cabeza permite obtener la máxima compresión (b) y (c). Tomado de (Cognet et al., 2009).



Estos implantes artificiales están compuestos a base de metales (vitalio, acero inoxidable, tantalio, titanio, etc.), material de cerámica, o plástico; siendo el níquel el cromo y el cobalto los metales más frecuentemente empleados para estas aleaciones (Alonso & Hernández., 1999).


3.2.1. Tipos de tornillos en osteosíntesis.

Los tornillos empleados son clasificados a partir de tipos de cabezas y roscas o por la forma de uso, diseño, dimensiones de su diámetro, área de aplicación, características, función o mecanismo. En general, algunos tipos de tornillos son (ver fig. 3) (Cognet et al., 2009).

- Tornillos de cortical.
- Tornillo de esponjosa.
- Tornillos canulados o perforados.
- Tornillos que permiten su colocación infra-articular.
- Tornillo de doble rosca tipo Herbert.
- Tornillos cónicos.
- Tornillos de compresión sin cabeza.
- Tornillos de cabeza bloqueada u otros tipos de tornillos bloqueados.
- Rosca corta o rosca larga.
- En cuanto a los tipos de cabezas en los tornillos, lo más usados son:
- Cruciforme.
- Hexagonal.
- En estrella.

Figura 3

Tipos de tornillos de osteosíntesis. Adaptado de (Cognet et al., 2009).



Las pruebas experimentales de este trabajo de investigación se realizan con 4 tipos de tornillos proporcionados por un fabricante local.

- **Tornillo cortical:**

El paso de rosca de estos tornillos está concebido para obtener una buena sujeción en el hueso cortical. En general, se usa para comprimir y fijar una placa al hueso. Suele tener rosca en toda su longitud, pero también puede tener un roscado parcial (Cognet et al., 2009).

- Tornillo de esponjosa:

Los tornillos de esponjosa tienen una relación diámetro exterior/alma del tornillo (diámetro interior) superior a la de los corticales para conseguir una mejor sujeción en el hueso esponjoso (Cognet et al., 2009).

- Tornillos canulados o perforados:

Los tornillos canulados tienen la peculiaridad de ser huecos y permiten el paso por su centro de una aguja que les sirve de guía. Esta aguja permite también una mayor precisión en la colocación del tornillo. Además, la aguja se usa para medir la longitud del tornillo con una regla (Cognet; **Error! No se encuentra el origen de la referencia.** et al., 2009).

- Tornillo de cabeza bloqueada u otros tipos de tornillos bloqueables:

Este tipo de tornillo se usa sólo con placas. El roscado de la cabeza permite su bloqueo en las placas previstas para ello. Una vez bloqueados, tornillo y placa forman un implante único y estable de ángulo fijo. Como el tornillo debe sobre todo resistir fuerzas de flexión, la relación entre el diámetro de su alma y el diámetro exterior es esencial. La ventaja de este tipo de implante es la estabilidad que se obtiene tanto en fracturas complejas como en el hueso osteoporótico. Por tanto, es posible la fisioterapia postoperatoria precoz (Cognet et al., 2009).

Para el desarrollo de este trabajo de investigación un fabricante local proporcionó muestras de cuatro tipos de tornillos de diferente forma y tamaño (ver fig. 4). El trabajo se realizó con 10 tornillos los cuales se dividen en cuatro tipos de tornillos.

- Tornillo A: bloqueado 39.17 mm Ti AR Torx 12 con referencia T1-424-2ART12.
- Tornillo B: esponjoso canulado 20,44 mm SS R.Parcial AP Hex 24 con referencia T1-90-1RPAPH24.
- Tornillo C: esponjoso cortical 30,75 mm SS R.Parcial AP Hex 24 con referencia T1-90-1RPAPH24.
- Tornillo D: cortical 26.79 mm Ti AR Torx 12 con referencia T1-424-2ART12.

Figura 4


Diferentes tipos de tornillos usados: (a) tornillo tipo A, (b) tornillo tipo B, (c) tornillo tipo C, (d) tornillo tipo D.




(a)



(b)



(c)




(d)

3.3. Hardware

Gracias al gran avance tecnológico en el desarrollo de equipos de cómputo portátiles, actualmente no es necesario de un equipo especializado, con las nuevas familias de procesadores que se fabrican para los computadores de uso personal se alcanzan las velocidades de ejecución que son necesarias para cubrir la mayor parte de las necesidades y puede esto convertirse en una unidad de control adecuada. Para la realización del proyecto se ha desarrollado en un portátil Asus X555DG cuyas especificaciones se muestran en la figura 5.

Figura 5

Portátil Asus x555dg.



- Tipo de procesador: AMD A10-8700P
- Velocidad del procesador: 1.80 GHz
- Número de procesadores: 2
- Capacidad de la memoria RAM: 12 GB
- Tipo de memoria del ordenador: DDR3L


- Capacidad del disco duro: 1 TB
- Coprocesador gráfico: AMD
- Descripción de la tarjeta gráfica: AMD Radeon R6 Graphics
- Plataforma de Hardware: Windows

3.4. Configuración experimental

El microscopio Dino Lite Edge con una resolución espacial de 2592x1944 píxeles, profundidad de campo ampliada de 12 mm, con una distancia larga de trabajo de 36 cm se conectó mediante USB a un portátil para capturar las imágenes de los tornillos, estas imágenes se pueden guardar en formato bmp o jpg con diferentes resoluciones utilizando el software con el que viene integrado el microscopio. En la figura 6 se puede ver un ejemplo de la configuración experimental para la toma de datos.

Figura 6

Configuración experimental del microscopio Dino Lite Edge conectado al portátil.



4. Metodología

En este capítulo se define la metodología planteada que se enfoca en la identificación automática de los tornillos utilizados en osteosíntesis. Se selecciona un dispositivo óptico-digital que cumple con los requerimientos necesarios para la adquisición de imágenes de objetos, posteriormente se definen las condiciones experimentales. Finalmente, a partir de los datos experimentales obtenidos, se detalla la identificación de imágenes, la creación del dataset y el proceso de clasificación automática de los tornillos a través de una interfaz open source desarrollada en Python denominada DinoControl, la cual implementa funcionalidades adecuadas para la clasificación e identificación de imágenes bidimensionales.

4.1 Montaje experimental

4.1.1 Microscopio digital.

Se usó un microscopio digital USB 3.0 Dino-Lite (ver fig.1) con el que se capturaron imágenes bidimensionales de los tornillos, lo cual es fundamental para el desarrollo del proyecto (tabla 1).

Tabla 1

Especificaciones ópticas del microscopio digital. Adaptado de Dino-Lite (2021)

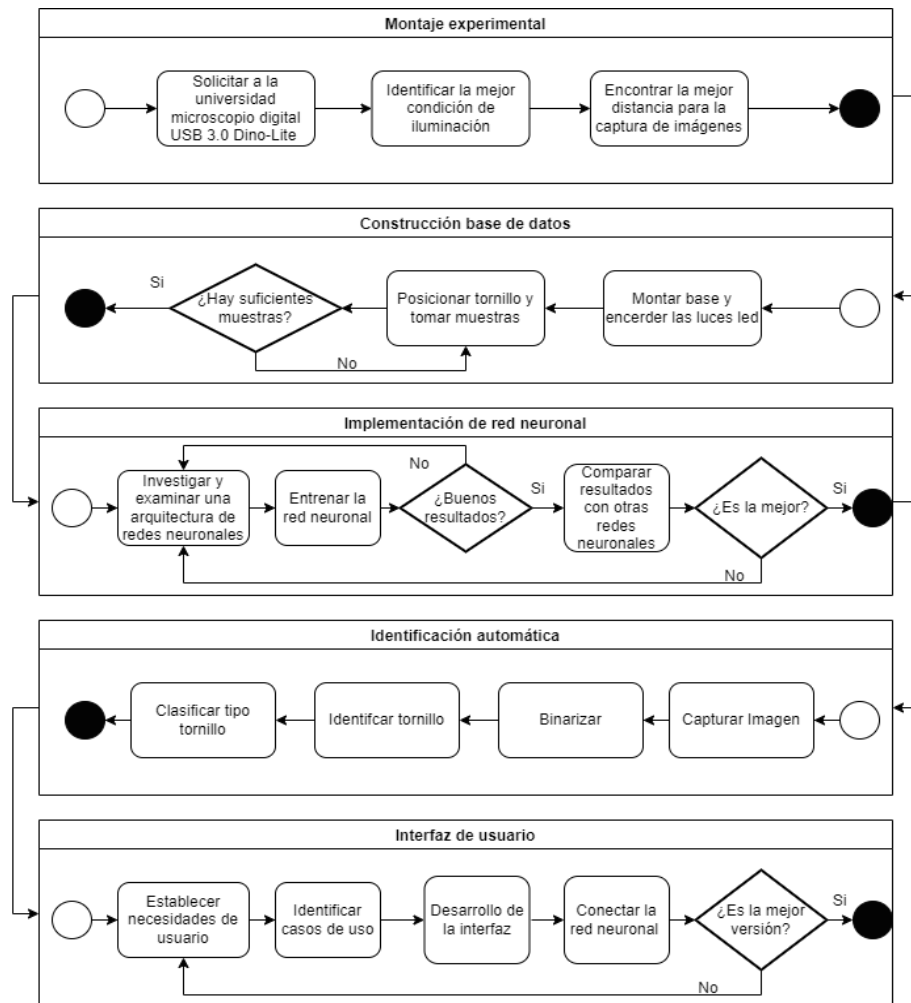
Magnificación [x]	10	20	30	40	50	60	70	80	90	100	110	120	130	140
Distancia de trabajo [mm]	234,5	112,5	72,5	54,5	43,5	37,5	33,7	31,3	29,9	29,2	29,1	29,3	29,8	30,5
Campo de observación (H) [mm]	39	19,5	13	9,8	7,8	6,5	5,6	29,9	4,3	3,9	3,5	3,3	3,1	2,8
Campo de observación (V) [mm]	29,2	14,6	9,7	7,3	5,8	4,8	4,2	4,3	3,2	2,9	2,6	2,4	2,2	2,1
Profundidad de campo [mm]	12	4,5	3,1	1,8	1,2	0,9	0,6	3,2	0,37	0,28	0,22	0,17	0,12	0,09

Las características ópticas de este microscopio digital son adecuadas para la adquisición de imágenes ya que posee un amplio rango de magnificación, un sistema de lentes diseñado para proporcionar aumento a una distancia más larga en comparación con los microscopios típicos, además una distancia de trabajo muy flexible y una profundidad de campo extendido.

En la figura 7 se detalla la metodología a seguir.

Figura 7

Diagrama de la metodología implementada.



4.1.2 Iluminación.

Se experimentó con dos tipos de iluminación: directa y a contraluz. Al aplicar iluminación directa mediante los LEDs integrados del microscopio (ver fig. 1), se perdían segmentos en las imágenes binarizadas del tornillo, resultando en imágenes con cierta deformación debido al reflejo presente gracias a la estructura metálica del objeto (ver fig. 8).

Figura 8

Tornillo con luz directa.



Con el uso de una base LED (ver fig. 9) se realizó la iluminación a contraluz (ver fig. 16 (a)), con la cual se obtuvo un contorno del tornillo más visible, debido a que los rayos de luz inciden por debajo del tornillo logrando una mejor binarización de las imágenes con respecto al uso de iluminación directa.

Figura 9


Base LED de luz de luz cálida, dimensiones 29,7 cm de ancho × 29,7 cm de alto, potencia de luz de 24W.



4.1.3 Soporte. El soporte universal Dino-Lite RK-10 es una plataforma de mesa compatible con el microscopio digital USB, la cual cuenta con una perilla de ajuste fino (movimiento suave) y un botón de liberación rápida (movimiento rápido), como se puede ver en la figura 10, siendo el movimiento suave una característica muy útil cuando se definen variaciones de distancias pequeñas muy precisas. Para la etapa de toma de muestras se mantuvo fijo en un eje de referencia $Z=36\text{cm}$ debido que era la distancia más cómoda para la toma de estas, sin embargo, para los análisis de resultados este terminó variando de 23 cm a 43 cm

Figura 10


(a) Botón de liberación rápida y (b) perilla de enfoque fino del soporte vertical RK-10. Dino-Lite (2021).



Usando el soporte y una extensión mecánica se establece una distancia de 36 cm entre el microscopio y la base donde se ubican los tornillos (ver fig.11), para obtener un campo de observación de 6.5 cm de ancho y 4.8 cm de alto, necesario para obtener imágenes completas de los tornillos, desde el más corto hasta el de mayor longitud (ver fig.11).

Figura 11

Altura y montaje de la base junto al microscopio.




4.2 Calibración

Un sistema de calibración puede ayudar a corregir las distorsiones en las imágenes capturadas, lo que puede mejorar la precisión y la confiabilidad de los resultados de la clasificación. Se procedió a tomar una medición manual de los tornillos, las medidas de ancho y largo del área del campo de observación se hallan convirtiendo las medidas de la resolución

espacial en píxeles a unidades métricas de longitud mediante un factor de escala, por lo que se recortaron cuadrados de 10 mm por cada lado para ser usados como sistema de calibración (ver fig. 12).

Figura 12

Sistema calibración con una longitud 10 mm.



Con el sistema configurado y con las imágenes capturadas se prosiguió a binarizar (convertir la imagen a escala de grises). Dichas imágenes son binarizadas para que el software detecte los patrones de la calibración (ver fig. 13), se halla el contorno de los patrones detectados, luego a esos contornos se le hace una aproximación poligonal, se verifica la aproximación de un polígono de 4 vértices, y luego con la posición de cada vértice se halla la longitud promedio entre

los lados de polígono, con la medida promedio de los lados del patrón en pixeles como se muestra en la figura 14, en la cual se distingue la región blanca del cuadrado con respecto al fondo negro.


Figura 13

Implementación algoritmo binarización.

```
def binarizar_imagen(self, imagen, umbral_min, umbral_max):  
    imagen_gris = cv2.cvtColor(imagen, cv2.COLOR_BGR2GRAY)  
    _, imagen_binarizada = cv2.threshold(imagen_gris, umbral_min, umbral_max,  
                                         cv2.THRESH_BINARY)  
    return imagen_binarizada
```

Figura 14

Sistema calibración binarizado y con longitud promediada medida en pixeles.



Finalmente, para calibrar el sistema se calcula la equivalencia entre la distancia conocida en unidades métricas de longitud y la distancia conocida en píxeles denominada factor de escala k , esto se representa en la ecuación (5) :

$$k = D_{um} / D_{px}, \quad (5)$$

Donde D_{um} es la longitud promedio de los lados del cuadrado en escala métrica y D_{px} es el valor del ancho del tornillo en píxeles. Por lo tanto, como la longitud conocida $D_{um} = 10$ mm, reemplazando en el factor de escala experimental k se define la ecuación (1):

$$k = \frac{10}{D_{px}} \text{ [mm/px]}. \quad (1)$$

Es importante tener en cuenta el tamaño del sistema de calibración ya que con este se va a realizar la conversión de pixel a milímetro (ver fig. 15).

Figura 15

Algoritmo conversión de pixel a milímetro.

```
if self.calibrar == 1:
    ancho, imagen = self.calibrar_imagen_calibracion(imagen)
    self.medida = 10 / ancho
    self.unidad = 'mm'
```

4.3 Conjunto de datos


La creación de un conjunto de datos (dataset) para tornillos de osteosíntesis consiste en recolectar una gran cantidad de imágenes de tornillos de diferentes tipos y tamaños para garantizar una representación adecuada en la forma, tamaño y características de los tornillos de osteosíntesis. El conjunto de datos contiene imágenes del perfil de los tornillos segmentados y binarizados, estas imágenes están divididas en 4 tipos para los 10 tornillos suministrados junto a sus diferentes variaciones y sus respectivas diferencias.

Con un total de 250 imágenes se usó el 80% de estas para entrenar la red neuronal, mientras que el 20% restante para realizar las pruebas de evaluación del modelo. Este proceso se divide en dos etapas la primera etapa evalúa la capacidad del modelo en identificar características visuales relevantes. La segunda división tiene como fin evaluar la capacidad del modelo para clasificar los tipos de tornillos.

Adquisición de muestras: con el sistema montado se procede a la toma de datos con una resolución de 2560 píxeles para el largo y 1920 píxeles para el ancho (2560 x 1920) (px) a una distancia de calibración de 36 cm (ver fig. 6). Luego, es binarizada a partir de un algoritmo aplicado en Python. Este método facilita una correcta segmentación entre el fondo y el tornillo por la iluminación a contraluz (ver fig. 16).

Figura 16

(a) captura con base LED (b) captura de un tornillo con la base LED.



(a)



(b)

Detección del tornillo. Obteniendo la imagen bidimensional del tornillo, adquirida con iluminación a contraluz y luego binarizada a partir del algoritmo descrito en la figura 17. Este facilita una correcta segmentación entre el fondo y el tornillo, ya que la región del objeto en la imagen se encuentra bien definida por la iluminación a contraluz, se genera una máscara de la región blanca del tornillo y se ubica sobre un fondo completamente negro para crear una imagen segmentada del tornillo.

Es importante tener en cuenta que el tornillo debe estar ubicado en el centro de la base de luz con el fin de evitar errores de procesamiento en la adquisición de muestras (ver fig. 18).

Figura 17

Algoritmo detección tornillo.

```

def identificar_imagen(self, imagen):
    puntos = []

    cnts = cv2.findContours(imagen, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)[0]
    cnts = sorted(cnts, key=cv2.contourArea, reverse=True)
    cnts = list(filter(lambda cnt: cv2.contourArea(cnt) > imagen.size * 0.001, cnts))

    for i, c in enumerate(cnts):
        x, y, w, h = cv2.boundingRect(c)
        x1, x2, y1, y2 = self.hallar_cordenadas([x, y, w, h], 4)

        cv2.rectangle(imagen, (x1, y1), (x2, y2), (255, 0, 0), 2)
        puntos.append([x, y, w, h])

    return imagen, puntos


```

Figura 18

(a) muestra (b) muestra binarizada.



(a)




(b)


A pesar de tener luz indirecta esta luz no termina de realizar un buen contorno del tornillo, para evitar esto se hizo uso de una imagen de fondo, siendo esta una foto de la base sin tornillo (ver fig. 16) para restar así el área entre la imagen con tornillo y la imagen sin este, así generar una imagen que resalta de manera más detallada del contorno del tornillo (ver fig. 19) esto fue implementado gracias a una funcionalidad de OpenCV (código implementado en la figura 20). Debido a que cada tornillo posee características distintivas se necesita tener una mejor imagen de cada tornillo.

Figura 19

Comparación muestra con imagen de fondo (a) contra imagen sin fondo (b).



(a)



(b)

Figura 20

Algoritmo sustraer fondo.

```
def eliminar_fondo(self, imagen_fondo, imagen):  
    if imagen_fondo is not None:  
        imagen_sin_fondo = cv2.subtract(imagen_fondo, imagen)  
    else:  
        imagen_sin_fondo = imagen.copy()  
    return imagen_sin_fondo
```

Una vez que se han recolectado las imágenes, se etiquetaron manualmente en base a la información de las características de la imagen que corresponden a cada tipo de tornillo y su respectiva clasificación con la información proporcionada por el fabricante local, esto se hace para que el modelo de aprendizaje automático pueda aprender a reconocer las características de cada tipo de tornillo.

Luego, las imágenes de los tornillos detectados, perfilados, binarizados y etiquetadas se pueden utilizar para entrenar y validar entrenamiento de la red neuronal.

4.4 Implementación de redes neuronales

Inicialmente, para el proceso de identificación y clasificación de tornillos de osteosíntesis, se implementó una red neuronal creada manualmente. Sin embargo, después de realizar pruebas con este modelo, se encontró que esta red no proporcionaba los resultados deseados y precisos. Por lo tanto, se decidió optar por una solución alternativa, y se utilizó una arquitectura de red neuronal pre-entrenada, como MobileNet, que demostró ser altamente efectiva para la tarea de

clasificación de los tornillos de osteosíntesis. Con MobileNet, se obtuvieron resultados mucho más precisos y consistentes, lo que permitió una clasificación más eficiente y eficaz de los tornillos de osteosíntesis.

Estos modelos pre-entrenados han sido entrenados en grandes conjuntos de datos y tienen la capacidad de identificar patrones comunes en imágenes, lo que los hace muy eficaces para tareas de clasificación de imágenes. Además, estos modelos pueden ser afinados o ajustados para adaptarse a las características específicas del conjunto de datos del problema en cuestión.

Uso MobileNet: MobileNet es una arquitectura de red neuronal convolucional (CNN) diseñada para aplicaciones de visión por computadora desarrollada por Google. Fue entrenada en el conjunto de datos ImageNet, que contiene millones de imágenes etiquetadas. Sin embargo, si se desea ajustar la red para una tarea de clasificación específica, se debe entrenar nuevamente la última capa de la red, conocida como capa de clasificación, con un nuevo conjunto de datos etiquetados, en el caso de este proyecto se usa el conjunto de imágenes etiquetado de los tornillos creado de manera manual para el uso de este proyecto.

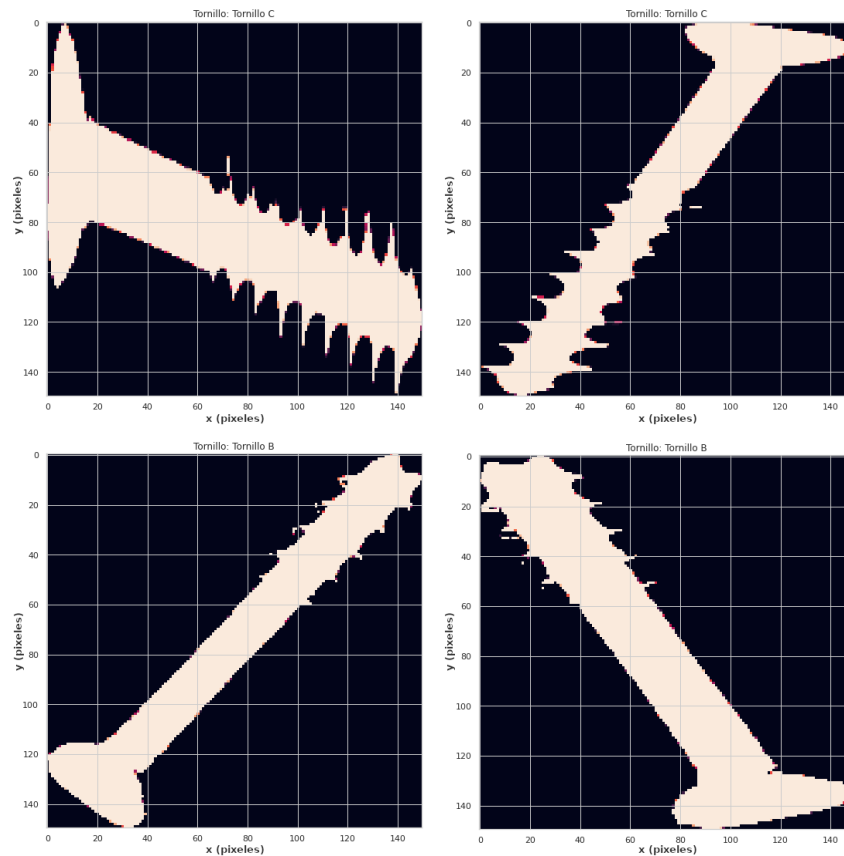
MobileNet utiliza una técnica llamada convolución separable profunda, que divide la convolución en dos etapas: una primera que opera en el plano de los canales de entrada, y una segunda que opera en el plano espacial. Esto reduce significativamente la cantidad de operaciones necesarias para procesar una imagen, lo que permite que la red sea más eficiente en términos de recursos y más rápida.

Se usó en el aprendizaje por transferencia, que es una técnica de aprendizaje automático en la que se utiliza una red pre-entrenada en una tarea para inicializar los pesos de otra red que se entrenará en una tarea diferente.

Fue determinante fijar un tamaño de resolución para cada imagen binarizada, el cual corresponden a (150 x 150) (px) para que estas estén a la misma dimensión y así facilitar el trabajo al clasificar (ver fig. 21).

Figura 21

Muestra tornillos redimensionados (150 x 150) px.



Aumento de datos. Para mejorar la predicción de la red neuronal se usó la técnica de “data augmentation” en la etapa de entrenamiento. Consiste en variar la forma, tamaño, posición de una imagen para que la red neuronal reciba una mayor cantidad de información a pesar de que esta sea la misma pero mostrada de forma diferente. Con ello se consigue que la cantidad de información que la red recibe sea mucho más elevada y que, por tanto, la precisión de sus respuestas sea mucho mayor y así se aumente la cantidad de muestras ya tomadas (ver fig. 22).

Figura 22

Código data augmentation.

```
datagen = ImageDataGenerator(
    featurewise_center=False, # establecer la media de entrada en 0 sobre el conjunto de datos
    samplewise_center=False, # establecer la media de cada muestra en 0
    featurewise_std_normalization=False, # dividir las entradas por la media del conjunto de datos
    samplewise_std_normalization=False, # dividir cada entrada por su std
    zca_whitening=False, # aplicar el blanqueamiento ZCA
    rotation_range=10, # girar aleatoriamente las imágenes en el rango (grados, 0 a 180)
    zoom_range = 0.1, # Ampliar la imagen aleatoriamente
    width_shift_range=0.2, # desplazar aleatoriamente imágenes en sentido horizontal (fracción del ancho total)
    height_shift_range=0.2, # desplazar aleatoriamente imágenes en sentido vertical(fracción de la altura total)
    horizontal_flip=True, # voltear imágenes al azar
    vertical_flip=False) # voltear imágenes al azar

datagen.fit(x_train)
```

El modelo propuesto está compuesto por 12 capas, 4 capas de convolución y una capa final softmax para clasificar (ver fig. 23), debido que son 4 tipos de tornillos se elabora este proceso 4 veces por cada uno de estos.

Figura 23. Esquema del modelo propuesto.

4.5 Interfaz de usuario

DinoControl tiene como objetivo principal brindar una experiencia satisfactoria para el usuario, que pueda realizar de manera automática la identificación y clasificación de los diferentes tipos de tornillos de osteosíntesis. Este proyecto tiene una ventana principal, una barra de herramientas que permite diferentes funcionalidades como el manejo del microscopio digital USB, escoger otro dispositivo en función de cámara para la captura de imágenes, junto a esta están las opciones de binarización, contorno, captura de imagen, etc. (ver fig. 24). En la tabla 2 se puede ver con más detalle las funcionalidades de cada una de estas.

Figura 24

Ventana principal DinoControl.




Tabla 2

Funcionalidades Interfaz.

Nombre	Funcionalidad	Sección ventana de herramientas
Abrir Imagen	Abrir imágenes del tipo JPG y PNG	Archivo
Guardar Imagen	Guardar imágenes del tipo JPG y PNG	Archivo
Cerrar Pestaña	Cierra la pestaña que se esté usando en el momento	Archivo
Abrir Imagen Fondo	Abrir en segundo plano una imagen que funcione como base	Archivo
Abrir Imagen Calibración	Abrir en otra pestaña la imagen de calibración que se requiera	Archivo
Salir	Cierra el software	Archivo

Seleccionar DinoLite	Seleccionar entre los dispositivos USB conectados para la captura de imágenes	DinoLite
Resolución	Identifica las resoluciones del dispositivo y permite el uso de las disponibles	DinoLite
Prender LED	Encender luces del microscopio digital	DinoLite
Apagar LED	Apagar luces del microscopio digital	DinoLite
Congelar Visualización	Hacer captura de la imagen reproducida en el microscopio	DinoLite
Capturar Imagen Fondo	Hacer captura de la imagen que se tenga de fondo	DinoLite
Seleccionar Todos	Seleccionar todas las opciones dentro de Herramientas	Herramientas
Sustraer Fondo	Eliminar el fondo restando la imagen que esté cargada para mejorar la binarización	Herramientas
Binarizar	Binarizar la imagen cargada	Herramientas
Invertir	Invertir color de negro a blanco	Herramientas
Identificar	Identificar tornillo en la imagen cargada	Herramientas
Contornear	Realizar contorno del tornillo en la imagen cargada	Herramientas
Clasificar	Clasifica el tipo de tornillo en la imagen cargada	Herramientas

La ventana principal de la interfaz es un menú lateral de herramientas que permite diferentes funciones como el manejo del microscopio digital USB, la captura de muestras de imágenes, detección de tornillos, clasificación de tornillos, la identificación de tornillos y la medición automática de las muestras.

Python posee una gran cantidad de librerías y plataformas software para el análisis de imágenes como lo es OpenCV planteada para programar en Python desarrollo de redes neuronales.

En la figura 25 se puede ver la interfaz junto a una imagen cargada de uno de los varios tornillos con los que se realizaron las muestras y a partir de estas se generaron los resultados (ver fig. 26).

Figura 25

Interfaz DinoControl.

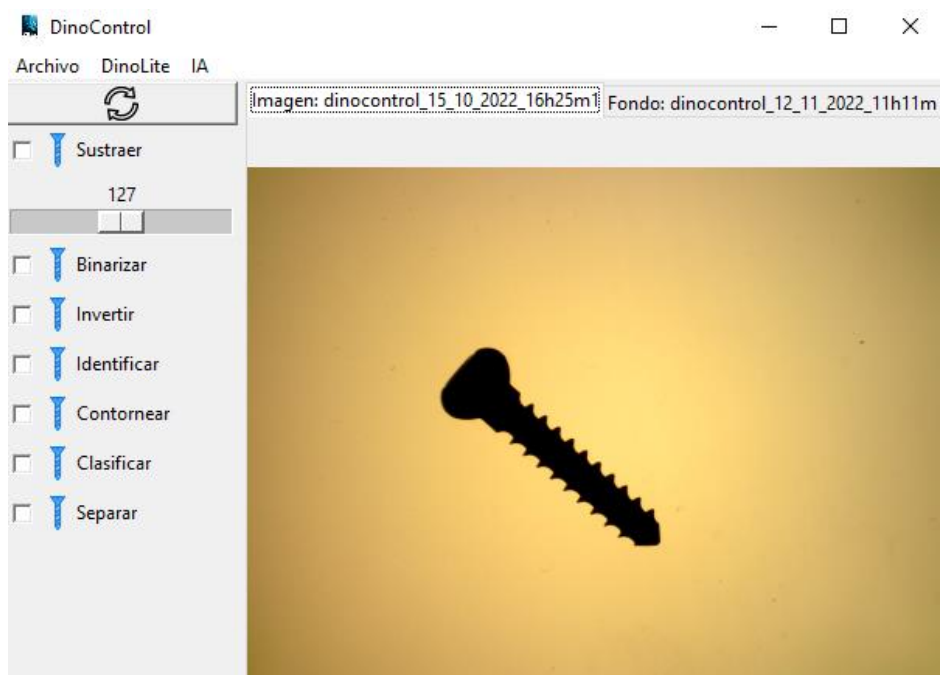




Figura 26*Tornillo Binarizado y clasificado.*

4.5.1 Rotación de la Imagen.

Un problema que se tuvo al momento de separar la imagen del fondo fue que los tornillos quedan en la misma posición en la que se encontraba en el momento de capturar la imagen (ver fig. 27), por lo tanto, para hacer mediciones se realizó una rotación en la imagen para que los tornillos quedaran de manera horizontal. Fue necesario aplicar herramientas de procesamiento de imagen como lo es momentos de imagen (ver figura. 28). Un momento de imagen es cierto promedio ponderado particular de las intensidades de los píxeles de una imagen o una función de tales momentos.

Figura 27

Imagen tornillo separado del fondo.



Los momentos de imagen son útiles para describir objetos luego de una segmentación. Algunas propiedades simples de la imagen se obtienen a partir de esos momentos.

Centroide. El centroide de una región $\bar{X} = (\bar{x}, \bar{y})$ es el punto de equilibrio, es decir el centro de gravedad. Este puede ser calculado a partir de la media aritmética de los puntos coordenados $P_i = (x_i, y_i)$ como se muestra en la ecuación (2) (Burger and Burge, 2016):

$$\bar{X} = \frac{1}{|R|} \cdot \sum_{P_i \in R} P_i, \quad (2)$$

La orientación y la excentricidad se pueden obtener de los momentos centrales, construyendo una matriz de covarianza y calculando sus autovalores y autovectores, representado en la ecuación (3).

$$cov[I(x, y)] = \begin{bmatrix} \mu'_{20} & \mu'_{11} \\ \mu'_{11} & \mu'_{02} \end{bmatrix}. \quad (3)$$

El autovector dominante (el correspondiente al mayor autovalor) indica la orientación. alternativamente, el ángulo del eje mayor respecto del eje cartesiano más cercano (eje x o eje y) se puede calcular directamente a partir de los momentos centrales.

Cuadro delimitador alineado al eje mayor. Teniendo una región binaria y su respectivo contorno, es posible obtener el cuadro delimitador que la encierra a partir del ángulo de orientación del contorno, donde θ es calculado a partir de la ecuación (4) (Burger and Burge, 2016):

$$\theta = \frac{1}{2} \arctan\left(\frac{\mu'_{11}}{\mu'_{20} - \mu'_{02}}\right), \quad (4)$$

Siendo $\mu'_{11}, \mu'_{20}, \mu'_{02}$ los momentos centrales estadísticos calculados con la ecuación (5)

$$\mu_{pq}(R) = \sum_{(x,y \in R)} (x - \bar{x})^p \cdot (y - \bar{y})^q, \quad (5)$$

donde $(\bar{x}; \bar{y})$ es el punto coordenado del centroide \bar{X} hallado. El ángulo θ se expresa entre -45° y 45° . Así pudiendo girar el tornillo de manera horizontal (ver fig. 29).

Figura 28*Algoritmo implementación autovectores.*

```

299     cnts = cv2.findContours(imagen, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)[0]
300     cnts = sorted(cnts, key=cv2.contourArea, reverse=True)
301     c = cnts[0]
302
303     M = cv2.moments(c)
304     cX = int(M["m10"] / M["m00"])
305     cY = int(M["m01"] / M["m00"])
306
307     u20 = (M["m20"] / M["m00"]) - (cX * cX)
308     u02 = (M["m02"] / M["m00"]) - (cY * cY)
309     u11 = (M["m11"] / M["m00"]) - (cX * cY)
310
311     angulo = 1 / 2 * np.arctan(2 * u11 / (u20 - u02))
312     angulo = np.degrees(angulo)
313
314     if u02 > u20:
315         angulo = - angulo - 90
316     else:
317         angulo = - angulo
318
319     imagen_rotada = imutils.rotate_bound(imagen, angulo)
320
321     cnts = cv2.findContours(imagen_rotada, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)[0]
322     cnts = sorted(cnts, key=cv2.contourArea, reverse=True)
323     c = cnts[0]
324     x, y, w, h = cv2.boundingRect(c)
325     x1, x2, y1, y2 = self.hallar_cordenadas([x, y, w, h], 4)

```

Figura 29*Imagen tornillo horizontal.*

4.5.2 Medición del tornillo.

Para medir una distancia se puede tomar una herramienta de medición y usar esta para determinar dicha distancia, pero para medir una distancia dentro de una imagen se procede a medir tanto en el eje horizontal (x) para el largo como en el eje vertical (y) para el ancho del objeto, en este caso un tornillo, esto se logra mediante técnicas de visión por computador, para ello se usa OpenCV con Python (ver fig. 30).

Para poder obtener la distancia en píxeles y luego transformarla en distancia en milímetros es necesario conocer el primer píxel que se encuentre a la izquierda y el píxel que esté de último a la derecha, para de este modo saber la longitud que los separa. Para determinar cuál de ellos está a la izquierda o derecha, se va a comparar sus coordenadas en el eje x. En esta condición tenemos

que el contorno x_{min} es menor, es decir está a la izquierda, mientras que x_{max} a la derecha. Se procede a aplicar la diferencia entre el punto más alejado x_{max} y el punto del primer contorno x_{min} .

Figura 30

Código para calcular ancho de los tornillos.

```
# Dibuja la Cota Del Ancho total
ymin = np.min(y_superior)
ymax = np.max(y_superior)
xmin = x_inferior[0]
xmax = x_inferior[-1]

cota = np.max(y_superior) * 0.05
cota_texto = np.max(y_superior) * 0.07

ancho = str(round(x_superior[len(x_superior) - 1] - x_superior[0], 2))
ax.text(xmin + (xmax / 2), ymax + cota_texto, ancho + ' ' + self.unidad)
ax.hlines(y=ymax + cota, xmin=xmin, xmax=xmax)
ax.vlines(x=xmin, ymin=ymin, ymax=ymax + cota, color='b', linestyle='dashed')
ax.vlines(x=xmax, ymin=ymin, ymax=ymax + cota, color='b', linestyle='dashed')
```

A su vez se repite el proceso en el eje y para calcular el ancho del tornillo, y_{min} como el pixel más bajo y y_{max} como el más alto. Nuevamente hallado el ancho total con las diferencias $(y_{max} - y_{min})$ (ver fig. 31).

Figura 31

Código para calcular alto de los tornillos.

```
# Dibujar Alto del tornillo
ymin = np.min(y_inferior)
xmin = x_inferior[y_inferior.index(ymin)]
ymax = np.max(y_superior)
xmax = x_superior[y_superior.index(ymax)]

cota = np.max(x_inferior) * 0.05
cota_texto = np.max(x_inferior) * 0.07

alto = str(round(ymax - ymin, 2))
ax.text(xmin - cota_texto, ymin + (ymax / 2), alto + ' ' + self.unidad, rotation=90)
ax.vlines(x=xmin - cota, ymin=ymin, ymax=ymax, color='b')
ax.hlines(y=ymin, xmin=xmin - cota, xmax=xmin, linestyle='dashed')
ax.hlines(y=ymax, xmin=xmin - cota, xmax=xmin, linestyle='dashed')
```

Una vez teniendo la información del largo y ancho en píxeles del objeto, se aplica el factor de conversión obtenido con los valores de la calibración en la ecuación (1) esta nos dará su medida en centímetros.

4.5.3 Suavizado de Contorno. Media móvil es una técnica utilizada para suavizar los datos de series de tiempo para reducir el ruido en los datos e identificar más fácilmente patrones y tendencias. Las medias móviles son una lista de números en la cual cada uno es el promedio de un subconjunto de los datos originales. Esto se implementó gracias a la librería de pandas con el comando `pd.Series(x).rolling` (ver fig. 32). Se hicieron diferentes pruebas validando a través de una gráfica con estos datos, así como se puede ver en la figura 33 y se halló que da un mejor resultado o un contorno más suave cuando se implementa con 5 vecinos.

Figura 32

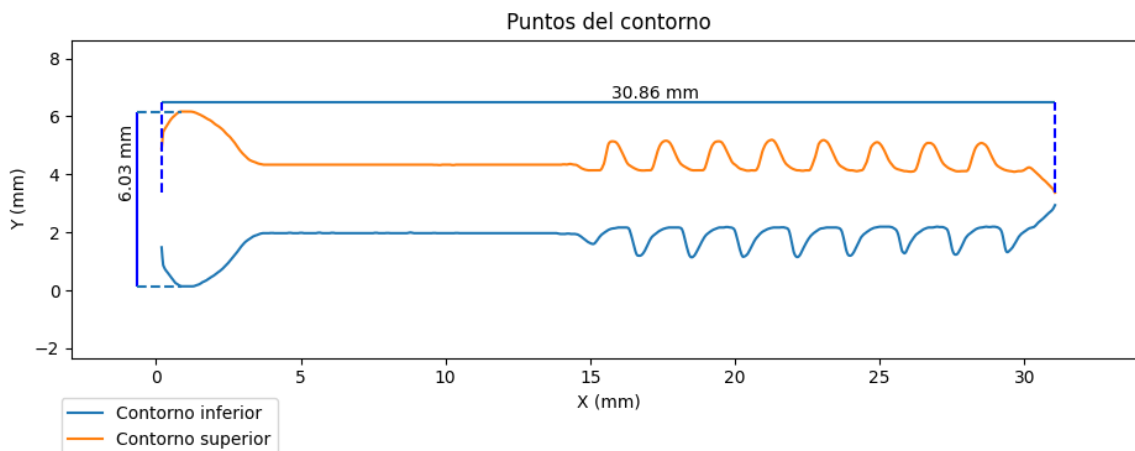
Algoritmo suavizado de contorno.

```
389 def suavizar_contorno(self, x, y, vecino):  
390     mitad = int((vecino - 1) / 2)  
391     x_media = pd.Series(x).iloc[mitad:-mitad].values  
392     y_media = pd.Series(y).rolling(window=vecino).mean().iloc[vecino - 1:].values  
393     return x_media, y_media
```

Así se obtiene un promedio para generar una gráfica definida y evitando el ruido que se tiene con solo los puntos del contorno.

Figura 33

Gráfica con suavizado de contorno.



5. Resultados

5.1 Resultados de red

Para comprobar la precisión total de los experimentos es útil aplicar el método de validación (evaluate). El método consiste en la obtención de distintas medidas de evaluación sobre diferentes particiones y calcular una media aritmética de los resultados.

El método “evaluate” toma dos argumentos: el conjunto de datos de prueba y las etiquetas de prueba. Luego, utiliza estos datos para calcular una métrica de rendimiento como la precisión.

La precisión en el modelo de evaluación representa la fracción de predicciones correctas realizadas por el modelo en el conjunto de datos de prueba. Es la cantidad de predicciones correctas dividida por el total de predicciones realizadas por el modelo en el conjunto de datos de prueba. Es comúnmente utilizada para evaluar modelos de clasificación. Un valor alto de precisión indica que el modelo es capaz de hacer predicciones precisas en el conjunto de datos de prueba (4.3 Conjunto de datos).

Se evaluó primero el modelo usando redes neuronales que se entrenaron manualmente, con este entrenamiento se obtuvo una precisión de clasificación del 87% (ver fig. 34) por lo que se puede considerar un buen resultado pero no el más confiable.

Figura 34

Evaluación redes neuronales con red hecha manualmente.

```
evaluate = modelo.evaluate(data_gen_validacion)
print(evaluate)

8/8 [=====] - 0s 35ms/step - loss: 0.3918 - accuracy: 0.8724
[0.3918000769615173, 0.8723943376541138]
```

Evaluación del modelo con redes neuronales convolucionales (CNN): A pesar de tener un buen resultado en la precisión de la anterior red neuronal se hizo otro entrenamiento de redes para comparar los resultados y escoger al más confiable. Este modelo se ha escogido debido que han demostrado tener un gran éxito en la tarea de clasificación y detección de objetos en imágenes. Una de las principales ventajas de las CNN es su capacidad para aprender automáticamente características importantes de las imágenes a partir de los datos de entradas.

Junto a esto se usó una herramienta llamada Transfer learning, donde un modelo de red neuronal previamente entrenado se utiliza para el aprendizaje de la red convolucional. En lugar de entrenar un modelo completamente desde cero, se utilizan los pesos de un modelo previamente entrenado para inicializar el modelo y luego se ajustan estos pesos a la nueva tarea. Esto puede ser beneficioso porque el modelo previamente entrenado ya ha aprendido características generales útiles en tareas de aprendizaje profundos.

Por lo que se implementó el mismo método el método de validación utilizado en el modelo hecho manualmente para hacer una comparación directa entre la precisión de ambos modelos.

Con este entrenamiento se obtuvo una precisión de predicción por encima del 90% (ver fig. 34) por lo que se puede considerar un buen resultado para una clasificación confiable.

Figura 35

Evaluación redes convolucionales MobileNet con Transfer learning.

```
evaluate = model.evaluate(x_test, y_test)
print(evaluate)

2/2 [=====] - 0s 14ms/step - loss: 0.1613 - accuracy: 0.9444
[0.16131816804409027, 0.9444444179534912]
```

5.2 Análisis de exactitud


El sistema de control planteado (ver fig. 6) es validado en términos de precisión y exactitud métrica a partir de los siguientes tipos de análisis:

- Análisis de exactitud: distancia Z variable y posición del tornillo variable. Para cada Z, se toman muestras del tornillo ubicado en cuatro posiciones establecidas.
- Análisis de precisión: distancia Z fija y posición del tornillo variable. Para un Z, se toman muestras del tornillo ubicado en quince posiciones al azar.

En general, el proceso consiste en obtener los perfiles graficados (ver fig. 36) y las mediciones de los tornillos para todas las muestras adquiridas mediante el algoritmo de medición automática. Los resultados son agrupados por variaciones en la distancia en el eje de referencia Z:

Figura 36

Perfiles graficados de (a) tornillo tipo B y (b) tipo C con sus respectivos largo y ancho de tornillo.



Finalmente, el largo y ancho de los tornillos son medidos con el calibrador pie de rey como se muestra en la figura 37 para obtener las medidas de referencia o teóricas (ver tabla 3). Estos valores se comparan respecto las medidas experimentales obtenidas por el sistema de control, calculando el error relativo porcentual, ecuación (6).

$$\text{Error} = \frac{|V_T - V_{EXP}|}{V_T} * 100, \quad (6)$$


donde V_T es el valor teórico y V_{EXP} es el valor experimental. A partir de la ecuación se calculan los errores para el ancho y largo en comparación a los resultados medidos con el calibrador (pie de rey).

Figura 37

Toma de medida del (a) tornillo B y (b) tornillo C con calibrador pie de rey.



(a)



(b)

Tabla 3

Medidas teóricas tomadas con el calibrador pie de rey de tornillos tipo B y tipo C.

Tipo	Ancho[mm]	Largo [mm]
B	5.98	19.97
C	5.9	29.94


Para analizar la exactitud del sistema, los tornillos B y C son capturados a tres diferentes distancias de referencia Z:

- Para el tornillo tipo B, los valores de Z son de 43 cm, 36 cm y 29 cm.
- Para el tornillo tipo C, los valores de Z son de 43 cm, 36 cm y 29 cm.

Para cada distancia Z propuesta, los tornillos se posicionan aproximadamente en ángulos de 0° , 45° , 90° y 135° con respecto a la abscisa (ver fig. 38), obteniendo un total de 12 muestras para cada tornillo. Los resultados de este análisis se encuentran en las secciones **5.2.1 Tornillo tipo B** y **5.2.2 Tornillo tipo C**.

Figura 38

Muestras de tornillos (a) tipo B y (b) tipo C en las cuatro posiciones establecidas a una distancia $Z = 36$ cm.



5.2.1 Tornillo tipo B. Para el tornillo B las medidas obtenidas se tabulan en la tabla 4. El error máximo se presenta a una distancia $Z = 43$ cm con 0.502% y 1.352% para ancho y largo respectivamente. Las medidas más exactas se encuentran a una distancia $Z = 36$ cm en la posición de 90° y 135° , siendo de 0.17% para ancho y 0.05 % para largo.

Tabla 4

Medidas obtenidas para el tornillo B variando la distancia de referencia Z.

Tornillo B	Tornillo DinoControl (mm)		error relativo porcentual		
	Ancho	Largo	Ancho	Largo	Angulo
z1=43cm	5.99	20.24	0.167	1.352	0
	5.95	20.19	0.502	1.102	45
	5.99	20.14	0.167	0.851	90
	6.01	20.04	0.502	0.351	135
z2=36	6	20.02	0.33	0.25	0
	6	20.11	0.33	0.70	45
	5.99	20.02	0.17	0.25	90
	5.96	19.98	0.33	0.05	135
z3=29	5.97	20.26	0.17	1.45	0
	5.98	20.2	0.00	1.15	45
	6	20.18	0.33	1.05	90
	5.97	20.2	0.17	1.15	135

5.2.2 Tornillo tipo C. Para el tornillo C las medidas obtenidas se tabulan en la tabla 5.

Tabla 5

Medidas obtenidas para el tornillo C variando la distancia de referencia Z.

Tornillo C	Tornillo DinoControl (mm)		error relativo porcentual		
	Ancho	Largo	Ancho	Largo	Angulo
z1=43cm	5.87	30.27	0.508	1.136	0
	5.92	30.32	0.339	1.303	45
	5.97	30.22	1.186	0.969	90
	5.95	30.19	0.847	0.869	135
z2=36	5.86	30.02	0.678	0.301	0
	5.89	30.07	0.169	0.468	45
	5.88	30.13	0.339	0.668	90
	5.86	29.93	0.678	0.000	135
z3=29	5.89	30.09	0.169	0.535	0
	5.89	30.04	0.169	0.368	45
	5.8	30.09	1.695	0.535	90
	5.93	30.18	0.508	0.835	135

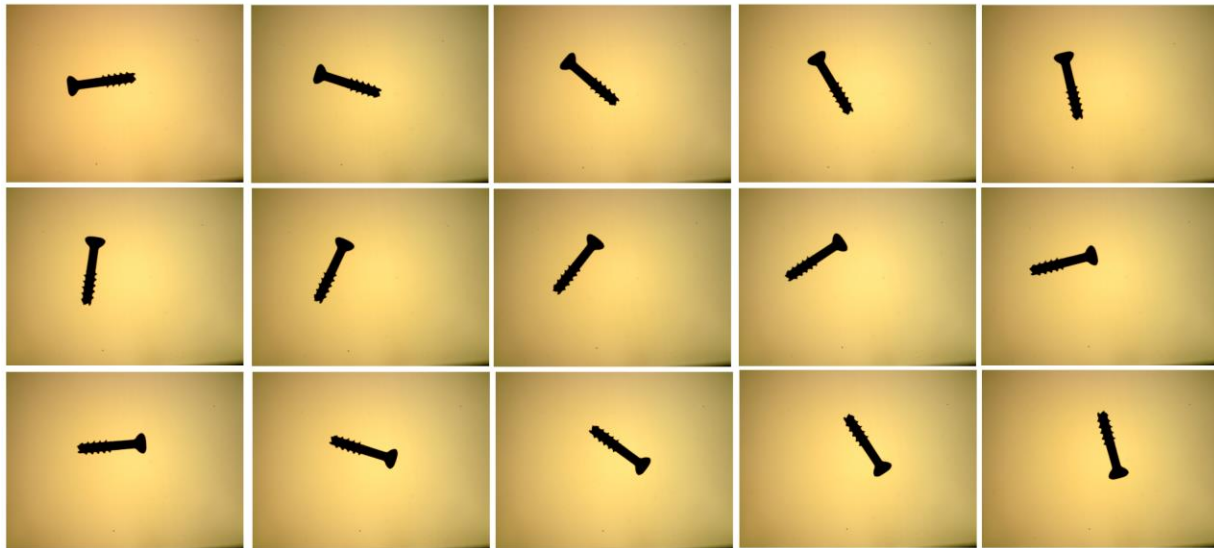
El error máximo para el ancho se presenta a una distancia $Z = 29$ cm con 1.695% y en largo a una distancia $Z = 43$ con 1.303%. Por otro lado, las medidas registradas más exactas se encuentran a una distancia $Z = 36$ cm en la posición de 90° , siendo de 5.89 mm para ancho y 29.93 mm para largo.

5.3 Análisis de precisión

La precisión del sistema se evalúa por medio de 15 muestras del tornillo B (ver fig. 39) a una distancia fija de referencia $Z = 36$ cm donde se varía el ángulo y posición del tornillo B sobre la base LED. Los resultados obtenidos son mostrados en la tabla 6.

Figura 39

Muestras de tornillo B en diferentes posiciones a una distancia $Z = 36$ cm.



Los valores obtenidos para el ancho se encuentran dentro de un rango de 5.98 mm y 6.01 mm, con un promedio de 5.98 mm con error de 0.32%. Por otro lado, los valores para el largo se encuentran dentro de un rango de 20.16 mm y 19.98 mm, con un promedio de 20.05 mm con error

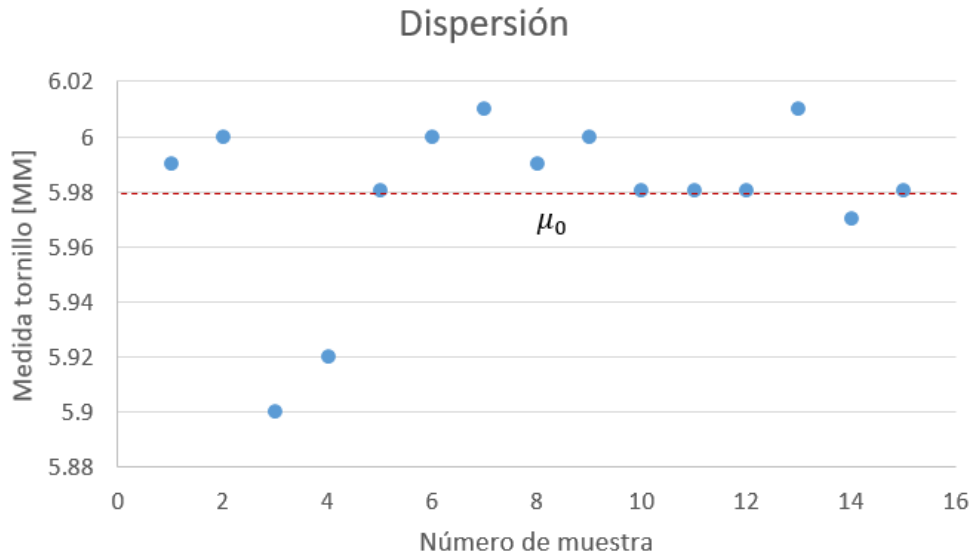
del 0.41%. Por lo tanto, se observa que las medidas son casi exactas a las obtenidas por el pie de rey sin importar la posición en la que se encuentre el tornillo.

Tabla 6

Tabla de medidas del tornillo tipo B a una distancia Z = 36 cm.

Tornillo B	Tornillo DinoControl (mm)		error relativo porcentual	
	Ancho	Largo	Ancho	Largo
z2=36	5.99	20.02	0.17	0.25
	6	20.11	0.33	0.70
	5.9	20.02	1.34	0.25
	5.92	19.98	1.00	0.05
	5.98	20.07	0.00	0.50
	6	20.02	0.33	0.25
	6.01	20.16	0.50	0.95
	5.99	20.04	0.17	0.35
	6	20.04	0.33	0.35
	5.98	20.07	0.00	0.50
	5.98	19.99	0.00	0.10
	5.98	20	0.00	0.15
	6.01	20.16	0.50	0.95
	5.97	20.1	0.17	0.65
	5.98	20	0.00	0.15
	Promedio:	5.98	20.05	0.32

Para este análisis de datos, se debe hacer un gráfico de dispersión (ver fig. 40), es una herramienta para visualizar la relación entre dos variables. Al observar la distribución de los puntos en el gráfico, es posible identificar patrones o tendencias en los datos. Además, se puede observar la dispersión de los datos alrededor de la media. Si los puntos en el gráfico están muy juntos, esto indica que hay una baja dispersión de los datos. Por el contrario, si los puntos están más alejados entre sí, hay una mayor dispersión de los datos. La distancia de los puntos alrededor de la media también puede indicar la variabilidad de los datos y su grado de concentración alrededor de un valor central.


Figura 40*Función de dispersión.*

El gráfico de dispersión muestra una relación positiva entre el número de muestras para el eje (X) y las medidas de tornillos para el eje (Y). Al observar la distribución de los puntos en el gráfico, se puede notar que los datos están relativamente bien dispersos alrededor de la media (μ_0). Además, se observa que hay algunos puntos que se encuentran alejados de la tendencia general, lo que indica una dispersión más amplia de los datos en esas regiones. Este patrón de dispersión de los datos sugiere que los valores de la variable Y son más variables en ciertos rangos de valores de la variable X.

Con estos datos se realiza una prueba de normalidad para comprobar si se pueden aproximar con una distribución normal, en la figura 41 se puede concluir que se aproxima a una distribución normal para una variación de las lecturas procesadas.

Figura 41

Prueba normalidad.



En la figura 42 y 43 se ilustra la distribución de probabilidad a partir de las medidas experimentales del ancho y largo del tornillo, calculadas con el algoritmo desarrollado para el proyecto. De esta manera, es posible representar gráficamente la precisión del sistema del control en términos métricos. Para el ancho se obtiene una media (μ_1) de 5.98 mm y una desviación estándar σ_1 de 0.03 mm, y para el largo se observa una media (μ_2) de 20.05 mm con una desviación estándar σ_2 de 0.05 mm.

Figura 42

Distribución de probabilidad de medidas experimentales para el ancho del tornillo.

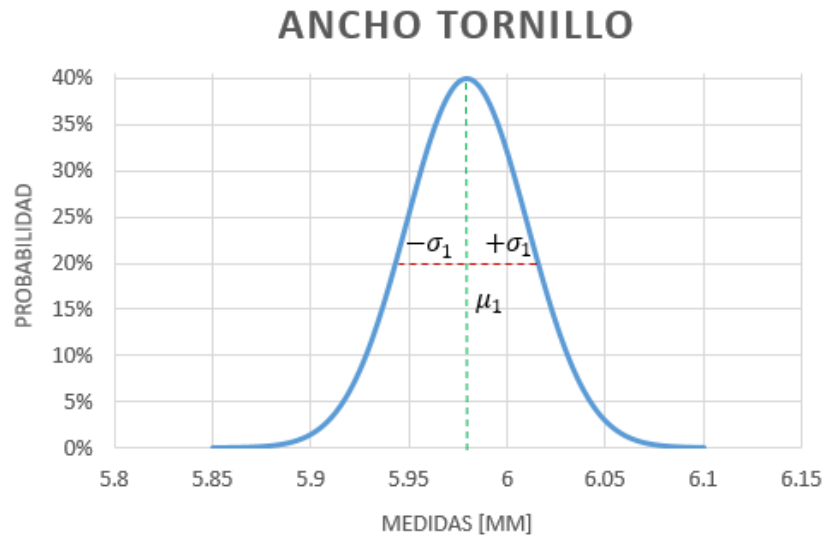
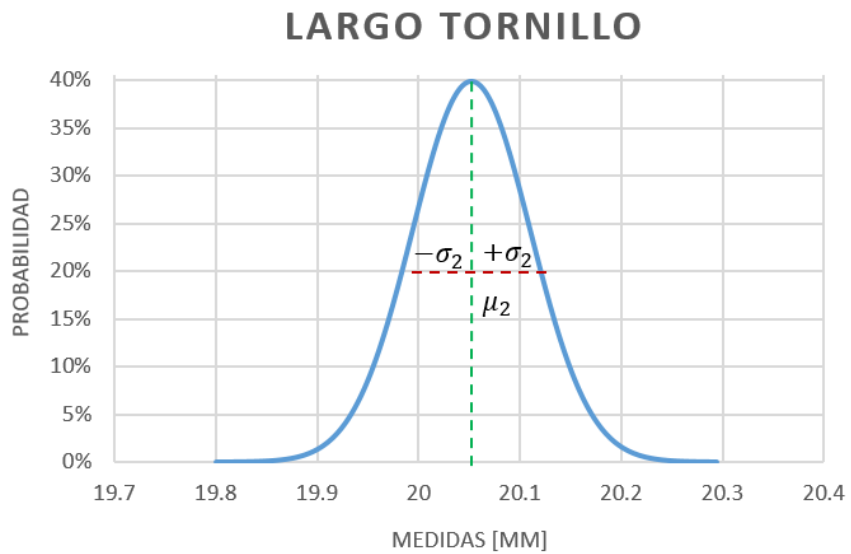


Figura 43 *Distribución de probabilidad de medidas experimentales para el largo del tornillo.*



6. Conclusiones

La calidad de las imágenes adquiridas es crucial para la clasificación e identificación de tornillos de osteosíntesis. las condiciones de iluminación como el tipo y flujo de iluminación suministrado por la base LED definida como luz indirecta, garantizan la reducción de errores estocásticos provocados por la reflectividad del material y la iluminación del entorno. Además, una correcta calibración del equipo y adquisición de muestras dependen de parámetros como la distancia de trabajo como lo fue en este proyecto un eje de referencia $Z = 36$ cm y la resolución del microscopio digital (2560 x 1650) (px), ya que estos influyen significativamente en los errores sistemáticos presentados en la ejecución de las redes neuronales.

Se procedió a capturar un promedio de 30 imágenes de cada tornillo de osteosíntesis proporcionado por el fabricante local, desde diferentes ángulos variando entre 10° grados para obtener una visión completa de cada uno de ellos. En total, se capturaron 250 imágenes con una resolución de (2560 x 1920) (px). Cada imagen tiene un peso promedio de 864 KB, lo que resulta en un tamaño total de archivo de 260 MB para todas las imágenes. Se organizó y almacenó el conjunto de imágenes en un archivo digital con una estructura de carpetas que refleja las diferentes categorías de tornillos, lo que permite un fácil acceso y recuperación de imágenes específicas en el futuro. Además, se creó un archivo adicional que contiene información detallada sobre cada imagen, como las características del tornillo, que se utilizará para el entrenamiento de la red neuronal.

Implementando técnicas de visión por computador como sustracción de imágenes, al eliminar el fondo de esta se da como resultado el tornillo aislado lo cual permite mejorar el resultado del algoritmo de binarización. La red neuronal tiene un porcentaje de precisión por encima del 90% lo cual representa en menor cantidad de tiempo de clasificación y mejor precisión en la etapa de control a diferencia a los operarios que realizaban esta tarea de manera manual, esto se traduce en una mejora en el trabajo, evitando el error humano y el desgaste que conlleva.

Se llevaron a cabo una serie de pruebas de evaluación de la arquitectura de red propuesta. Estas pruebas incluyeron el uso de conjuntos de datos de prueba y validación para medir el rendimiento de la red en términos de precisión y pérdida. Se realizaron ajustes en la estructura de la red y en los parámetros de entrenamiento, y se evaluó nuevamente el rendimiento de la red en los conjuntos de datos de prueba y validación. Debido que la primera red propuesta no dio unos resultados de precisión lo suficientemente satisfactorios, se implementó el entrenamiento con un modelo de red neuronal pre entrando el cuál fue MobileNet. Se continuó este proceso de ajuste y evaluación hasta que se lograron resultados satisfactorios y se verificó que la arquitectura de red cumplía con unos buenos resultados de precisión.

Con base en el análisis experimental, se comprueba que el nivel de precisión y exactitud de las medidas de largo y ancho de un tornillo ubicado en cualquier posición sobre la base LED no es directamente proporcional a la distancia de referencia debido que los resultados variaron con distancias Z. En cuanto a la orientación del tornillo es un factor que no altera notablemente los resultados, ya que se evidencia un mayor error en las medidas al variar Z que al variar la orientación del tornillo a una distancia Z fija.

DinoControl es un sistema de código abierto implementando tecnologías de libre acceso e intuitivo para un fácil uso, cumpliendo con los objetivos propuestos, a su vez reduciendo de forma significativa el margen de error en procedimientos de inspección manual. Aplicando herramientas de identificación automática que aportan además precisión y rapidez, optimizando el proceso de distinguir y clasificar en términos de precisión mediante la implementación de algoritmos de clasificación por medio de inteligencia artificial siendo todo este proceso a tiempo real dando como resultado una automatización al clasificar tornillos de osteosíntesis con alta exactitud.

En la actualidad, la eficiencia y la precisión son elementos clave para cualquier empresa al momento de clasificar un producto. Sin embargo, utilizar herramientas manuales como el calibrador y el microscopio puede ser lento y propenso a errores humanos, lo que puede afectar y retrasar a la clasificación e identificación. Por lo tanto, es necesario implementar nuevas herramientas y tecnologías que puedan mejorar significativamente el proceso de clasificación. Las máquinas de medición por coordenadas y los sistemas de visión artificial son algunas de las herramientas que podrían ayudar a automatizar y mejorar el proceso de medición, reduciendo la necesidad de intervención humana, aumentando la precisión y la eficiencia.

Para un trabajo futuro se recomendaría: automatizar el proceso de inspección acoplado a una cinta transportadora para trasladar los tornillos hacia un punto de inspección, el cual funcione con el sistema de control planteado. De esta manera, clasificando y midiendo en un menor tiempo. Además, adaptar el algoritmo de medición automática para el análisis bidimensional de otras partes del tornillo según requerimientos específicos de diseño de fabricantes.

Referencias Bibliográficas

- A. De la Escalera. (2001). *Visión por computador: fundamentos y métodos*. Pearson, Prentice Hall.
- Alonso Pareyon, Batalla Hernández. (1999). Dermatitis a material de osteosíntesis. Revisión del tema. *Rev Cent Dermatol Pascua*, 121-124.
- Burger, W. and Burge, M. (2016). *Digital Image Processing: An Algorithmic Introduction Using Java (2nd ed)*. Texts in Computer Science..Springer-Verlag London.
- Cognet, J.-M. Altman, M., and Simon, P. (2009). Material de osteosíntesis: tornillos y placas. *EMC - Técnicas Quirúrgicas - Ortopedia y Traumatología*, 1(1): 1–10.
- Dino-Lite. (2021). AM73915MZTL. Obtenido de <https://www.Dinolite.us/en/am73915mztl>.
- L. Rodríguez, Manzanero, D., Campos, W., Millano, V., and Valbuena, C. (2011). Falla de implantes ortopédicos metálicos en hospitales de la ciudad de maracaibo, venezuela. *Multiciencias*, 11(1):85–91.
- Pesciallo, C. Á. (2019). Errores de osteosíntesis en fracturas laterales de cadera tratadas con placa/tornillo deslizante. *Revista de la Asociación Argentina de Ortopedia y Traumatología*, 84(4).
- Ramos-Maza, E., García-Estrada, F., Domínguez-Barrios, C., Chávez-Covarrubias, G., Meza-Reyes, G., and Buffo-Sequeira, I. (2016). Principios biomecánicos para la osteosíntesis, reevolución. *Acta Ortopédica Mexicana*, 30(S1):S1–S8.
- Velásques Hernández, E. G. (2014). Simulación sistema de clasificación de objetos basado en visión artificial. *Reponame:Repositorio Institucional de La Universidad Nacional Abierta y a Distancia*.