

**Sistema de visión artificial para la detección de
imperfecciones en extrusión de filamento para
impresoras 3D**

Ing. Rubén Eduardo Aguilera Pérez

2026



**Universidad Autónoma de
Querétaro
Facultad de Ingeniería**

**Sistema de visión artificial para la detección
de imperfecciones en extrusión de filamento
para impresoras 3D**

Tesis

Que como parte de los requisitos para obtener el Grado
de

Maestro en Ciencias (Mecatrónica)

Presenta

Ing. Rubén Eduardo Aguilera Pérez

Dirigido por:

Dr. Jesús Rooney Rivera Guillén

San Juan del Río, Qro. a julio del 2026

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ciencias (Mecatrónica)

**Sistema de visión artificial para la detección de
imperfecciones en extrusión de filamento
para impresoras 3D**

TESIS

Que como parte de los requisitos para obtener el Grado de
Maestro en Ciencias (Mecatrónica)

Presenta:

Ing. Rubén Eduardo Aguilera Pérez

Dirigido por:

Dr. Jesús Rooney Rivera Guillén

Dr. Jesús Rooney Rivera Guillén

Presidente

Dr. Irving Armando Cruz Albarrán

Secretario

Dr. Juan Pablo Amézquita Sánchez

Vocal

Dr. Juan Primo Benítez Rangel

Suplente

M. en C. José Alberto Isidoro Olvera Rodríguez

Suplente

Centro Universitario, Querétaro, Qro.

Fecha de Aprobación por el consejo julio de 2026

México

Dedicatorias

A mis padres por haber estado siempre conmigo y no haberme dejado aún a mi edad, gracias a ustedes pude concentrarme en mi trabajo al saber que, si algo me pasaba, estarían a un lado de mí.

A mis abuelos y tíos abuelos, tanto en vida como en el otro lado, por haberme dado los ánimos para estudiar y haberme dado las enseñanzas para vivir solo sin tener problemas.

A mi novia, por siempre darme ánimos para continuar y ayudarme a recuperar mi cordura cuando el trabajo me sobrepasaba.

A mis mascotas, por siempre sacarme una sonrisa y darme algo para siempre buscar mejorarme.

Al doctor Eduardo Arturo Elizalde Peña, que en paz descansa, por haberme dado los ánimos y la oportunidad de estudiar un posgrado, siempre lo recordaré por tanto, doctor.

Agradecimientos

Se agradece a SECIHTI por la beca 4039485 que me permitió terminar de forma satisfactoria mi maestría.

A mis profesores, director de tesis y sinodales por haberme enseñado y guiado en los temas que me fueron indispensables para la finalización de mi maestría.

A la Universidad Autónoma de Querétaro por haber dispuesto sus instalaciones para las pruebas necesarias en el desarrollo de la presente tesis

Índice general

1. Introducción	1
1.1. Antecedentes	1
1.1.1. Revisión de literatura local	2
1.1.2. Revisión de literatura nacional	3
1.1.3. Revisión de literatura internacional	3
1.2. Justificación	5
1.2.1. Impacto Tecnológico	5
1.2.2. Impacto Científico	6
1.2.3. Impacto Social	6
1.3. Descripción del problema	7
1.4. Hipótesis	9
1.5. Objetivos	9
1.5.1. Objetivo general	9
1.5.2. Objetivos específicos	9
2. Fundamentación teórica	11

2.1.	Visión artificial aplicada al control de calidad	11
2.1.1.	Fundamentos de la visión artificial	11
2.1.2.	Adquisición de Imágenes	12
2.1.3.	Preprocesamiento	12
2.1.4.	Segmentación	12
2.1.5.	Extracción de Características	13
2.1.6.	Reconocimiento y Clasificación mediante Deep Learning	14
2.1.7.	Implementación de openCV	14
2.1.8.	Uso de ROIs para optimización computacional	15
2.1.9.	Calibración del sistema de visión artificial	16
2.1.10.	Calibración directa y calibración usando patrones	17
2.2.	Principios de la extrusora de un solo husillo y formación del filamento	18
2.2.1.	Dinámica de formación y calibración dimensional	19
2.3.	Proceso de extrusión y fundamentos reológicos	20
2.4.	Fundamentos de metrología dimensional en visión artificial	20
2.5.	Técnicas de medición de calidad en filamentos	21
2.5.1.	Métodos ópticos de medición dimensional	21
2.5.2.	Detección de defectos mediante procesamiento de imágenes	22
2.5.3.	Importancia de la iluminación en la medición óptica	23
2.5.4.	Norma ISO 5425:2023	25
2.6.	Factores que afectan la detección de defectos	27

2.6.1.	Sensor IMX317	27
2.6.2.	Influencia del color y transparencia	28
2.6.3.	Impacto del ruido en la detección de defectos	29
2.7.	Sensibilidad del sistema a condiciones ambientales	30
2.8.	Defectos: burbujas e impurezas	30
3.	Metodología	32
3.1.	Diseño mecánico y hardware de procesamiento	32
3.2.	Diseño del sistema de adquisición óptica	33
3.3.	Sistema de iluminación y calibración métrica	34
3.4.	Arquitectura de Software e Interfaz HMI	35
3.5.	Entrenamiento y validación del modelo de clasificación	39
3.6.	Construcción e integración del prototipo físico	45
3.6.1.	Análisis de costos y viabilidad	46
3.6.2.	Criterios de selección de hardware	47
4.	Resultados y discusión	48
4.1.	Validación de exactitud metrológica y análisis estadístico	48
4.2.	Evaluación y selección del modelo de Inteligencia Artificial	51
4.2.1.	Fase de Validación Estándar	51
4.2.2.	Fase de Benchmark: Latencia y Prueba de Estrés	52
4.3.	Desempeño de la Interfaz Hombre-Máquina (HMI)	55

4.3.1. Ventana principal de monitoreo	55
4.3.2. Panel dinámico de ingeniería	56
4.3.3. Demostración de detección de anomalías en tiempo real	60
4.4. Estrategias de control y acciones correctivas	62
5. Conclusiones	63
5.1. Trabajo Futuro	64
Referencias	66

Índice de tablas

1.	Tolerancias dimensionales aceptadas por la norma ISO 5425:2023	26
2.	Desglose de costos del hardware del prototipo.	47
3.	Mediciones obtenidas con micrómetro para determinar el diámetro real del patrón de calibración.	49
4.	Valores de la constante óptica de conversión (mm/px) por espejo.	49
5.	Registro comparativo de mediciones para evaluación de dispersión y exactitud.	50
6.	Acciones correctivas sugeridas según el defecto detectado.	62

Índice de figuras

1.	Diagrama de funcionamiento de una extrusora de filamento.	19
2.	A) Vista lateral mostrando la posición de la cámara, el filamento, los espejos y las luces. B) Vista frontal desde la perspectiva del sensor. (Autoría propia) .	34
3.	Vista frontal sin espejos del sistema de adquisición de imágenes del diagrama de luces, cámara y el filamento.(Autoría propia)	34
4.	A) Vista macro del patrón de calibración en la cámara con los espejos. B) Medición del patrón de calibración con micrómetro.(Autoría propia)	35
5.	Diagrama del funcionamiento de la interfaz HMI.(Autoría propia)	36
6.	Diagrama de funcionamiento interno del sistema.	38
7.	Montaje experimental para la adquisición del conjunto de datos. Se aprecia la calibración del sistema de iluminación indirecta y el arreglo catóptrico durante el paso del filamento. (Autoría propia)	40
8.	Muestras físicas utilizadas para el entrenamiento del modelo: A) Filamento con burbujas internas inducidas por humedad, B) Filamento con impurezas incrustadas en la matriz plástica, C) Filamento en estado normal. (Autoría propia)	41
9.	Proceso de obtención de ROIs y aumento de datos	42
10.	Proceso de entrenamiento y selección del mejor modelo	44

11.	Vista frontal del prototipo de inspección. A) Sistema inactivo. B) Sistema de iluminación LED encendido. (Autoría propia)	45
12.	Vista lateral del prototipo mostrando la distribución de la cámara, óptica, iluminación y cableado estructural. (Autoría propia)	46
13.	A) Medición de diámetro de filamento usando micrómetro. B) Captura de parámetros dimensionales en tiempo real mediante la interfaz del sistema. . .	51
14.	Curvas de aprendizaje (Precisión y Pérdida) del modelo EfficientNetB0 con tamaño de lote 4. (Autoría propia)	52
15.	Comparativa de Precisión y Pérdida en la fase de validación estándar para las tres arquitecturas evaluadas con diferentes tamaños de lote. (Autoría propia) .	52
16.	Resultados del benchmark masivo de modelos bajo la prueba de estrés con aumento de datos agresivo. Se compara precisión, latencia y peso. (Autoría propia)	53
17.	Distribución funcional de la ventana principal. A) Renderizado de video en tiempo real. B) Panel de metrología. C) Semáforos de inferencia de IA. D) Acceso a configuración. (Autoría propia)	56
18.	Vista detallada de panel de ingeniería: Módulos de Visualización y Óptica. . .	58
19.	Vista detallada de panel de ingeniería: Configuración de Geometría y Filtros.	59
20.	Vista detallada de panel de ingeniería: Ajustes de Tolerancias y Sistema (Ruta IA).	59
21.	Composición de la interfaz evaluando tres escenarios de calidad del filamento: A) estado normal, B) presencia de burbujas y C) contaminación. (Autoría propia)	61

Abreviaturas y siglas

CAD Diseño Asistido por Computadora (*Computer-Aided Design*).

CNN Red Neuronal Convolutiva (*Convolutional Neural Network*).

CPU Unidad Central de Procesamiento (*Central Processing Unit*).

FPS Fotogramas por Segundo (*Frames Per Second*).

GPU Unidad de Procesamiento Gráfico (*Graphics Processing Unit*).

HMI Interfaz Hombre-Máquina (*Human-Machine Interface*).

ISO Organización Internacional de Normalización (*International Organization for Standardization*).

JSON Notación de Objeto de JavaScript (*JavaScript Object Notation*).

LED Diodo Emisor de Luz (*Light-Emitting Diode*).

MB Megabyte. Unidad de medida de almacenamiento de datos.

mm Milímetro. Unidad de longitud del Sistema Internacional.

mm/px Milímetros por píxel. Constante de conversión de metrología óptica.

PETG Tereftalato de Polietileno Glicol (*Polyethylene Terephthalate Glycol*). Plástico utilizado en impresión 3D.

PLA Ácido Poliláctico (*Polylactic Acid*). Polímero biodegradable utilizado en impresión 3D.

RAM Memoria de Acceso Aleatorio (*Random Access Memory*).

ROI Región de Interés (*Region of Interest*). Área específica de una imagen analizada por visión artificial.

USB Bus Serie Universal (*Universal Serial Bus*).

Resumen en español

El aseguramiento de la calidad dimensional y superficial en los filamentos de impresión 3D es un factor crítico para garantizar la fiabilidad de las piezas manufacturadas. El presente trabajo de investigación detalla el diseño, desarrollo e implementación de un prototipo de inspección visual y metrología óptica en tiempo real, orientado a operar directamente en la línea de extrusión bajo un entorno de laboratorio. El sistema propuesto prescinde de los tradicionales micrómetros de contacto láser, optando por una arquitectura basada en un sensor 4K y un arreglo catóptrico de tres espejos que permite analizar el perímetro completo del material de forma simultánea. La metodología abordó la creación de un algoritmo de visión artificial clásico para la medición dimensional, logrando detectar desviaciones geométricas con una resolución de hasta 0.0058 milímetros por píxel. Para la detección de defectos superficiales e internos, como micro-burbujas y contaminantes, se construyó un conjunto de datos propio y se realizó un experimento comparativo entre tres arquitecturas de aprendizaje profundo (MobileNetV2, ResNet50 y EfficientNetB0). Los resultados demostraron que el modelo EfficientNetB0, con un tamaño de lote de 4, superó a las alternativas al alcanzar una precisión de clasificación del 99.33 % bajo condiciones de estrés, manteniendo una latencia de inferencia inferior a 80 milisegundos operando exclusivamente en CPU. Finalmente, la integración del sistema mediante una Interfaz Hombre-Máquina con procesamiento concurrente demostró la viabilidad de clasificar defectos y validar la geometría del filamento conforme a los estrictos límites de la norma internacional ISO 5425:2023, ofreciendo una solución de inspección industrial altamente eficiente, de bajo costo y de arquitectura abierta.

Palabras clave: impresión 3D, control de calidad, metrología óptica, aprendizaje profundo, visión artificial..

Abstract

The assurance of dimensional and surface quality in 3D printing filaments is a critical factor in guaranteeing the reliability of manufactured parts. This research work details the design, development, and implementation of a real-time visual inspection and optical metrology prototype, aimed at operating directly on the extrusion line under a laboratory environment. The proposed system dispenses with traditional laser contact micrometers, opting for an architecture based on a 4K sensor and a three-mirror catoptric array that allows the complete perimeter of the material to be analyzed simultaneously. The methodology addressed the creation of a classical computer vision algorithm for dimensional measurement, achieving the detection of geometric deviations with a resolution of up to 0.0058 millimeters per pixel. For the detection of surface and internal defects, such as micro-bubbles and contaminants, a custom dataset was built, and a comparative experiment was conducted between three deep learning architectures (MobileNetV2, ResNet50, and EfficientNetB0). The results demonstrated that the EfficientNetB0 model, with a batch size of 4, outperformed the alternatives by reaching a classification accuracy of 99.33 % under stress conditions, maintaining an inference latency of less than 80 milliseconds operating exclusively on CPU. Finally, the integration of the system through a Human-Machine Interface with concurrent processing demonstrated the feasibility of classifying defects and validating the filament geometry according to the strict limits of the ISO 5425:2023 international standard, offering a highly efficient, low-cost, and open-architecture industrial inspection solution.

Keywords: 3D printing, quality control, optical metrology, deep learning, computer vision.

Capítulo 1

Introducción

1.1. Antecedentes

La impresión 3D, o manufactura aditiva, es un proceso de fabricación que crea objetos tridimensionales mediante la deposición controlada de capas de material, ofreciendo ventajas sobre los métodos tradicionales como menor desperdicio y la posibilidad de producir geometrías complejas. Su adopción se ha extendido a industrias como la aeroespacial, biomédica, diseño de productos, arquitectura y educación, debido a su capacidad para fabricar objetos personalizados y reducir costos.

Los antecedentes de la impresión 3D se remontan a los experimentos de polimerización localizada de los años 60. En la década de 1980, surgieron tecnologías como la estereolitografía, el sinterizado selectivo por láser (SLS) y la fusión por haz de electrones (EBM). En 1989, la deposición de material fundido (FDM) marcó un hito, y su adopción masiva comenzó en 2005 tras la liberación de patentes, impulsada por movimientos de código abierto como RepRap, que democratizaron la tecnología y aceleraron avances en FDM y en impresión con resinas (Su y Al'Aref, 2018).

Los polímeros dominan la impresión 3D por su facilidad de procesamiento y bajo costo. Materiales como el PLA, ABS, PETG, y elastómeros como TPU han ampliado las aplicaciones, mientras que polímeros de ingeniería como el nylon y el policarbonato ofrecen alta resistencia mecánica y térmica. También se emplean materiales de soporte como HIPS y PVA, y

compuestos avanzados como PC/ABS para sectores especializados (Iftekar, Aabid, Amir, y Baig, 2023).

En la tecnología FDM, la calidad del filamento es crítica: variaciones en diámetro, impurezas o contaminaciones afectan directamente la extrusión y la calidad de las piezas. Irregularidades provocan desde defectos superficiales hasta fallos completos de impresión, por lo que el uso de filamentos uniformes y de alta pureza, junto con un control térmico preciso, es esencial para mantener la estabilidad del proceso (Valerga, Batista, Salguero, y Girot, 2018).

Con esta base, se presenta a continuación una revisión de la literatura relacionada, abarcando antecedentes locales, nacionales e internacionales sobre la calidad de filamentos para impresión 3D y las tecnologías de monitoreo basadas en visión artificial.

1.1.1. Revisión de literatura local

La revisión de la literatura en el repositorio de la Universidad Autónoma de Querétaro no arrojó resultados con una similitud significativa con el presente trabajo; sin embargo, se identificaron algunas tesis con información relevante.

En la tesis de Gasca (Gasca, 2022) se analiza el impacto de la impresión 3D en la ingeniería a través del desarrollo de un pedal para el control de aceleración. Un aspecto destacado de este trabajo es la discusión sobre los problemas asociados con la impresión 3D, en particular una posible falla de calibración que impidió que la pieza se adhiriera correctamente a la cama de impresión. Este problema podría estar relacionado con imperfecciones dimensionales en el material. Además, el estudio incluye un análisis de la resistencia a la tracción en diferentes marcas y pigmentos de filamento.

Por otro lado, la tesis de Reséndiz (Reséndiz Carranza, 2025) aborda los desafíos de la impresión 3D con nylon 6, demostrando sus aplicaciones prácticas y la necesidad de realizar ajustes para garantizar una impresión exitosa. Se documentan los problemas encontrados durante el proceso y las modificaciones implementadas para solucionarlos, lo que resalta la complejidad de trabajar con este material y la importancia de la optimización de parámetros de impresión.

A diferencia de los trabajos presentados, el trabajo propuesto clasificará los errores que se presenten en el filamento, evitando algunos de los errores que se presentan en los trabajos

anteriores.

1.1.2. Revisión de literatura nacional

En el ámbito nacional se tuvo un éxito mayor, ya que se encontraron artículos que hablan directamente de las pruebas y consideraciones para un filamento utilizable y las pruebas para certificar que un filamento se puede utilizar en una aplicación muy especializada.

En la tesis de Rodríguez & Medina (Hernández Rodríguez y Valle Medina, 2018) se trata directamente de los desafíos de la extrusión de filamento, poniendo especial énfasis en que ellos están usando un material reciclado, tanto sin y con aditivos, también discuten el impacto de las burbujas y las impurezas en la morfología y resistencia del filamento, dejando en claro que las burbujas producen roturas en los puntos donde se encuentran.

En el trabajo de investigación de Herrarte et al. (Herrarte López, Steven, y Villamil, 2024) se diferencia fuertemente de otras máquinas de extrusión ya que su materia prima es cinta de botellas PET en lugar de pellets, a pesar de esto, muestra herramientas para encontrar problemas dimensionales en el filamento que producen, haciendo hincapié en los errores dimensionales bajos que obtuvieron, así como algunas burbujas presentes por el tipo de proceso que se ha llevado a cabo.

El sistema de inspección que se plantea en este trabajo se mejoran estos enfoques al integrar algoritmos de visión artificial con una óptica adaptativa, logrando detectar imperfecciones con alta precisión sin depender exclusivamente de la observación posterior a la impresión.

1.1.3. Revisión de literatura internacional

Para la literatura internacional se obtuvieron múltiples trabajos que tienen una relación directa con el presente trabajo, a continuación, se muestran los dos principales.

El trabajo de Aniulis et al. (Aniulis, Dudzik, y Abramski, 2024) se habla del uso de la permitividad eléctrica con el fin de medir las contaminaciones o los cambios en la densidad del filamento, esta capacidad permite poder detectar contaminaciones que no serían visibles de otra forma, como partículas en filamentos oscuros o una contaminación de otro tipo de

plástico con color idéntico. El uso de un encoder longitudinal permite el poder mapear toda la longitud del filamento, lo que es especialmente útil, ya que se hace uso de 3 calipers basados en rodamientos y sensores de efecto hall que permiten detectar con gran precisión las dimensiones del filamento, estos 3 calipers se ponen en 3 ángulos distintos para poder medir, con una mayor capacidad, la ovalidad del filamento. Además, se usa un medidor láser para compensar la compresión que se da en uno de los calipers debido a la fuerza del resorte en ellos y de esta forma compensar el resto.

En el uso de sensores sin contacto, el trabajo de Petsiuk & Pearce (Petsiuk y Pearce, 2021) se distingue, ya que utiliza visión artificial para las mediciones de los 3 ángulos, como el pasado trabajo, pero en este caso es haciendo uso de espejos. Se usan ROI (Regions Of Interest, Regiones de Interés) para poder leer solamente una parte del filamento correspondiente a cada uno de los ángulos, y así bajar la carga computacional. Con los 3 ROI se puede simular la forma del filamento, permitiendo así que se pueda tener su diámetro, ovalidad y variación de ambos. Aunque su trabajo se trató principalmente para filamentos reciclados, su sistema y metodología es perfectamente aplicable para filamentos de materiales vírgenes.

En resumen, la impresión 3D ha revolucionado la manufactura al permitir la producción eficiente de objetos personalizados con menor desperdicio. Aunque la literatura muestra avances significativos en el control de calidad del filamento, persisten limitaciones en la implementación práctica de sistemas de inspección que sean verdaderamente efectivos y accesibles.

Con base en los trabajos analizados, resulta deseable contar con un sistema de inspección sencillo y versátil, fundamentado en visión artificial, que permita superar las limitaciones actuales. Idealmente, una solución óptima no debería depender de sensores invasivos de contacto ni de sistemas mecánicos complejos, sino que debería ofrecer un análisis óptico multivista con capacidad de calibración mediante patrones físicos y reportar anomalías en tiempo real, haciéndolo viable para líneas de producción compactas.

A partir de este análisis del estado del arte, en este trabajo se propone un sistema integral de monitoreo basado en visión artificial multivista, calibrado con patrones físicos, el cual es capaz de identificar variaciones dimensionales, ovalidad, burbujas e impurezas en tiempo real con alta precisión. A diferencia de los estudios previos, se ofrece una solución sin contacto, adaptable, económica y con visualización inmediata mediante una interfaz gráfica, lo que representa una mejora tangible para los procesos industriales de extrusión orientados a la impresión 3D.

1.2. Justificación

La detección temprana de defectos, como variaciones en el diámetro, la ovalidad, impurezas y burbujas, permite evaluar problemas de extrusión, la presencia de contaminantes o humedad en la materia prima, evitar el desperdicio de lotes completos de filamento, reducir fallos en la impresión y minimizar la producción de piezas defectuosas. Esto se traduce en una reducción significativa de desechos tanto en la producción como en el uso del filamento (3devo, 2020). El sistema desarrollado en este trabajo tiene como finalidad verificar la calidad del filamento para impresoras 3D, asegurando que opere correctamente en equipos de alta velocidad mediante una extrusión uniforme y una precisión dimensional óptima (Cardona, Curdes, y Isaacs, 2016).

1.2.1. Impacto Tecnológico

La implementación de este sistema representa un avance tecnológico clave, ya que la integración de una cámara de alta resolución, iluminación indirecta y un arreglo de espejos permite obtener mediciones precisas sin contacto físico con el filamento. Este enfoque no solo mejora la precisión y estabilidad de las mediciones, sino que también lo hace adaptable a condiciones de baja solidez del filamento, un aspecto crítico en la manufactura de filamentos. Al evitar el contacto directo, se reduce el riesgo de contaminación y se optimiza la clasificación de filamentos, diferenciando entre aquellos que son óptimos, utilizables o defectuosos, lo que facilita la separación de secciones inutilizables. Además, al liberar potencia de cálculo en la impresora, se abre la posibilidad de integrar mejoras adicionales, como la compensación de vibraciones y otros controles avanzados. Cabe destacar que este trabajo también tiene el objetivo de generar tecnología propia para la universidad y el país, abriendo una nueva línea de investigación en áreas aún poco exploradas en nuestro contexto.

Adicionalmente, el sistema propuesto posee el potencial de servir como una herramienta para la certificación de filamentos por la norma ISO 5425:2023 (International Organization for Standardization, 2023). Al proporcionar mediciones precisas y objetivas sobre la calidad dimensional y la detección de defectos. Esto facilitaría la implementación de protocolos de control de calidad en entornos industriales, asegurando que únicamente los filamentos que cumplan con especificaciones rigurosas sean utilizados en la impresión 3D, lo que redundaría en una mayor fiabilidad y eficiencia en la manufactura aditiva.

1.2.2. Impacto Científico

El desarrollo de algoritmos de visión artificial para determinar el diámetro y la ovalidad del filamento, junto con la detección y clasificación de anomalías internas, abre nuevas posibilidades en el ámbito de la inspección de materiales. Estos algoritmos son aplicables no solo a la impresión 3D, sino también a otros productos manufacturados, como tubos, cables o fibras ópticas. La metodología, basada en el análisis de imágenes y calibrada mediante patrones de referencia, contribuye al avance del conocimiento en control de calidad sin contacto, permitiendo evaluar con precisión la estructura interna de los materiales. Asimismo, la capacidad de determinar el tamaño y la distribución de imperfecciones puede utilizarse para diseñar materiales con estructuras controladas, ampliando su aplicación en diversas áreas científicas e industriales.

Más allá de su implementación en la manufactura aditiva, el principio de inspección catóptrica y procesamiento neuronal concurrente desarrollado en este trabajo tiene un alto potencial de escalabilidad hacia otros sectores estratégicos. La capacidad del sistema para detectar variaciones micro-dimensionales sin contacto físico puede adaptarse de manera directa a la supervisión de líneas de extrusión de tuberías de grado médico (como catéteres y sondas), la fabricación de fibras ópticas de telecomunicaciones y la inspección del revestimiento de cables eléctricos. En todas estas industrias, la homogeneidad del polímero extruido es un factor de seguridad crítico, lo que amplía significativamente el horizonte de aplicación de esta tecnología.

1.2.3. Impacto Social

El sistema propuesto tiene un impacto social significativo, ya que mejora la seguridad y el bienestar de los operarios al eliminar la necesidad de realizar mediciones manuales del filamento, reduciendo su exposición a altas temperaturas y vapores generados durante la extrusión. Esto contribuye a crear un entorno de trabajo más seguro y confortable. Además, la optimización en la clasificación y uso del material contribuye a la reducción del desperdicio, generando beneficios económicos y ambientales que promueven una manufactura más sostenible y responsable. Adicionalmente, el sistema podría contribuir indirectamente a aplicaciones en el área médica, como la creación de prótesis. En el caso de prótesis externas, por ejemplo, el uso de filamentos de alta calidad no solo mejora la estética del dispositivo, sino

que también puede devolver al usuario una mayor independencia y funcionalidad, impactando positivamente en su calidad de vida.

En el ámbito de los Programas Nacionales Estratégicos (PRONACES), este trabajo contribuye a la reducción de desechos plásticos de dos formas. De manera directa, se identifican los lotes de filamento que presentan problemas y que, aunque no sean aptos para impresión de alta calidad, pueden utilizarse en aplicaciones donde dichas imperfecciones no sean determinantes, evitando que terminen como desechos. De forma indirecta, al verificar la calidad del filamento antes de su uso, se previenen fallos en la impresión que puedan dejar piezas incompletas, lo que reduce la necesidad de desechar impresiones defectuosas.

1.3. Descripción del problema

Las variaciones de diámetro, la ovalidad del filamento o la presencia de impurezas o burbujas son las principales causas de inconsistencias en la impresión, como la formación de cavidades, atascos en la boquilla e irregularidades en la superficie de las piezas. Por ello, para garantizar la estabilidad y precisión de los filamentos para impresión 3D, es crucial verificar su impresión.

Los encoders son sistemas que pueden mantener un volumen constante de plástico extruido, pero se ven limitados por la velocidad volumétrica máxima del extrusor. Por ejemplo, un estándar reportado para PLA es de , lo que, utilizando una boquilla de y una altura de capa de , se traduce en un avance teórico de . Incluso los extrusores más rápidos, con , alcanzarían un máximo teórico de ; sin embargo, en la práctica se recomienda operar a velocidades inferiores, alrededor del 80 % del máximo, para evitar tensiones excesivas en el sistema (Prusa Research, 2020).

Estos límites sugieren que el extrusor puede requerir variar su velocidad para compensar filamentos demasiado delgados o gruesos, lo que incrementa el riesgo de atascos y subextrusión. Además, las variaciones constantes en el flujo pueden generar problemas adicionales por la inercia del material, y la propia presencia de burbujas e impurezas puede arruinar la impresión por sí sola. Estos cambios bruscos tienden a dejar una superficie irregular en el filamento, similar al efecto “ghosting” reportado en la comunidad de impresión 3D, un problema que se agrava cuando los filamentos no son verificados antes de ser utilizados a altas velocidades,

por lo que no resulta práctico ni conveniente dejar que la impresora 3D compense los errores dimensionales del filamento. El desarrollo de un sistema de inspección previo reduciría la complejidad del control en la impresora, permitiendo operaciones a altas velocidades con menos aceleraciones y desaceleraciones del filamento, y liberando potencia de cálculo para otras mejoras, como la compensación de vibraciones (Klipper, s.f.).

Para ser eficaz, el sistema de monitorización de filamento deberá registrar defectos a velocidades de entre 30 y 60 mm/s (Aniulis et al., 2024) y debe interactuar mínimamente con el filamento, evitando deformaciones incluso cuando el material se encuentre caliente. Además, dado que los filamentos varían ampliamente en color y composición, desde blancos y transparentes hasta negros, y de PLA o PETG a materiales ingenieriles como ASA y Nylon, el sistema debe ser lo suficientemente flexible.

Por último, es fundamental considerar la contracción de los polímeros al enfriarse, la cual depende del grado de cristalinidad y de las condiciones de enfriamiento. No tener en cuenta el tipo y color del filamento puede generar falsos positivos o negativos; por ejemplo, el PLA, el ABS y el PETG presentan coeficientes de contracción de 0.21 %, 0.594 % y 0.304 %, respectivamente en sus componentes (Revilla Días, 2006), valores que pueden presentar cambios con la inclusión de colorantes y/o aditivos. Es esencial determinar si el material aún se encuentra sin solidificar o si simplemente se está enfriando, para diferenciar entre dimensiones erróneas y variaciones normales por contracción, de lo contrario tendremos una medición que puede desembocar en un filamento de diámetro erróneo.

Es esencial determinar si el material aún se encuentra sin solidificar o si simplemente se está enfriando, para diferenciar entre dimensiones erróneas y variaciones normales por contracción, de lo contrario tendremos una medición que puede desembocar en un filamento de diámetro erróneo. Para efectos de las pruebas experimentales desarrolladas en este trabajo, se empleó policarbonato (PC) como material de estudio, el cual presenta un factor de contracción térmica que oscila entre el 0.5 % y el 0.7 %. Este parámetro fue integrado en la configuración dinámica de la interfaz HMI para compensar las lecturas dimensionales en tiempo real.

Para abordar y corregir los problemas previamente identificados en la impresión 3D, este trabajo propone el desarrollo de un sistema de inspección de filamentos mediante visión artificial. Este sistema permitirá detectar y clasificar defectos como variaciones de diámetro, ovalidad, burbujas e impurezas antes de que el filamento sea utilizado en impresoras 3D. Al

implementar esta solución, se busca garantizar una extrusión uniforme y precisa, reduciendo la incidencia de fallos en la impresión y mejorando la calidad final de las piezas producidas. Además, al identificar y eliminar filamentos defectuosos previamente, se optimiza el proceso de impresión, disminuyendo el desperdicio de material y los tiempos de producción.

1.4. Hipótesis

Con un sistema de medición basado en una cámara, un arreglo de espejos y algoritmos de visión artificial, es posible monitorear la calidad de filamentos para impresión 3D, detectando y clasificando irregularidades dimensionales externas que excedan tolerancias de ± 0.1 mm en un filamento nominal de 1.75 mm, además de identificar anomalías internas como impurezas y burbujas con un tamaño superior a 0.01 mm.

1.5. Objetivos

1.5.1. Objetivo general

Desarrollar un sistema de monitoreo para una máquina de extrusión de filamento destinada a impresoras 3D, capaz de detectar burbujas de aire, impurezas y variaciones dimensionales (como diámetro no uniforme u ovalidad excesiva) mediante la medición dimensional basada en visión artificial con el fin de cuantificar los resultados sobre las imperfecciones detectadas con el sistema propuesto.

1.5.2. Objetivos específicos

1. Diseñar y calibrar un arreglo óptico catóptrico y un sistema de iluminación indirecta para obtener tres vistas simultáneas de alta definición, permitiendo la extracción de parámetros morfológicos del filamento sin contacto físico.
2. Implementar rutinas de procesamiento de imágenes para la extracción de Regiones de Interés (ROI) y detección de bordes, evaluando los filtros morfológicos óptimos para el

análisis del contorno del material.

3. Determinar el diámetro y la ovalidad del filamento estableciendo una constante de conversión geométrica precisa (píxeles a milímetros) a partir de las tres vistas capturadas mediante algoritmos de visión artificial.
4. Validar la exactitud metrológica del sistema óptico utilizando patrones físicos cilíndricos de diámetro conocido, garantizando la fiabilidad y trazabilidad de las mediciones generadas.
5. Detectar y clasificar anomalías en la matriz del filamento (burbujas e impurezas), así como desviaciones dimensionales, mediante algoritmos de visión artificial y aprendizaje profundo para garantizar una alta tasa de precisión en tiempo real.
6. Desarrollar una Interfaz Hombre-Máquina (HMI) intuitiva que centralice el monitoreo del proceso e integre un panel de ingeniería para la modificación dinámica de parámetros sin necesidad de alterar el código fuente.
7. Evaluar el desempeño integral del prototipo en condiciones simuladas de producción industrial, comprobando la robustez del sistema frente a filamentos de diversas propiedades reflectivas y colores.
8. Documentar y exponer los resultados obtenidos en un foro de divulgación académica, contribuyendo al estado del arte con el análisis del desempeño del sistema mecatrónico y neuronal desarrollado.

Capítulo 2

Fundamentación teórica

En los siguientes apartados se presentan los fundamentos teóricos que respaldan el desarrollo de este trabajo. Se describen los conceptos esenciales relacionados con la impresión 3D, la calidad del filamento, la visión artificial y el procesamiento de imágenes, así como los criterios técnicos que justifican la elección de tecnologías y metodologías. Esta fundamentación permite comprender el enfoque adoptado y su relevancia en el contexto actual de la manufactura aditiva.

2.1. Visión artificial aplicada al control de calidad

2.1.1. Fundamentos de la visión artificial

Se entiende como visión artificial al acto de reproducir de forma artificial el sentido de la vista humano para las máquinas. Es de especial importancia su uso ya que el ser humano es un animal principalmente visual, por lo que la mayoría de la información que maneja es de forma visual (Gómez-Allende, 1994).

A continuación, se desglosan los pasos para llevar a cabo la visión artificial:

2.1.2. Adquisición de Imágenes

El primer paso es capturar la imagen del objeto o escena, lo cual se realiza mediante cámaras o sensores especializados. La calidad de esta imagen influye directamente en la efectividad del procesamiento posterior, ya que entre mayor sea la resolución, más detalles se podrán captar en una sola toma; sin embargo, esto implica una mayor cantidad de información a procesar y, por lo tanto, un incremento en el tiempo de cómputo. Lo ideal es encontrar un compromiso entre alta calidad y bajo tiempo de procesamiento. Además, no se puede dejar de lado la importancia de una iluminación adecuada, ya que de esta dependerá que el sensor sea capaz o no de detectar detalles específicos que podrían ser críticos para el análisis (Duque-Domingo, Gómez-García-Bermejo, y Zalama-Casanova, 2024).

2.1.3. Preprocesamiento

Antes de analizar la imagen, se aplican técnicas de preprocesamiento para mejorar la calidad visual, con el objetivo de que la entrada sea lo más fiel posible a la realidad. Entre estas técnicas se encuentra el filtrado y la eliminación de ruido, donde se utilizan filtros como el de mediana para suavizar la imagen y eliminar interferencias que puedan dificultar la detección de características relevantes.

También se realiza la normalización y corrección de iluminación, ajustando el brillo y el contraste para obtener una imagen uniforme, independientemente de las variaciones en la iluminación ambiental. La normalización puede implicar tomar un promedio de un conjunto de imágenes o aplicar un estándar que asegure que todas las capturas tengan características similares. Gracias a estas técnicas, se logra que las imágenes resalten únicamente los detalles distintivos, evitando la presencia de información irrelevante que podría afectar la identificación o inducir errores en los clasificadores automáticos (Sudeep y Pal, 2017).

2.1.4. Segmentación

Este proceso consiste en dividir la imagen en regiones o segmentos. La segmentación facilita la identificación de objetos y defectos al reducir las áreas en las que el sistema debe concentrarse, disminuyendo así la carga de procesamiento. Uno de los métodos más comunes es la

umbralización, que se basa en el uso de un valor umbral para separar el fondo del objeto. Esta separación se realiza considerando la intensidad y/o el color de cada píxel. En la ecuación (1) se muestra la ecuación de la umbralización, donde $I_{x,y}$ es la intensidad del píxel en la posición (x,y) , T es el umbral predefinido o adaptativo y $I'_{x,y}$ es el píxel de la imagen segmentada.

$$I'_{x,y} = \begin{cases} 1, & \text{si } I_{x,y} \geq T \\ 0, & \text{si } I_{x,y} < T \end{cases} \quad (1)$$

Depender de un umbral T estático definido manualmente presenta un alto riesgo de fallo ante ligeros cambios en la iluminación ambiental o al alternar entre filamentos de distintos colores. Para solucionar esta vulnerabilidad, el sistema emplea el método de binarización de Otsu. Este algoritmo estadístico analiza el histograma de la imagen en tiempo real y calcula de forma autónoma el umbral óptimo T que minimiza la varianza intra-clase (la variación dentro de los píxeles del fondo y del objeto). Hoy en día, el método de Otsu sigue siendo un estándar indispensable como etapa de preprocesamiento automático en arquitecturas modernas de visión artificial para la detección de defectos superficiales (Han y Kutbay, 2025).

2.1.5. Extracción de Características

Una vez segmentada la imagen, se extraen las características relevantes que permitirán la identificación y clasificación de los objetos.

Entre las técnicas utilizadas se encuentra el análisis de formas y patrones, que reconoce figuras geométricas y texturas a través de la comparación con formas conocidas, así como mediante el uso de histogramas y matrices de concurrencia. También se realiza la extracción de color, usando modelos como RGB o HSV para obtener información sobre las combinaciones cromáticas presentes en la imagen. Esta información es especialmente útil en el reconocimiento por textura, ya que aporta datos adicionales sobre la superficie del objeto.

Finalmente, se aplican transformaciones como la Transformada de Hough, que permite detectar líneas y círculos transformando la imagen al espacio paramétrico. Esta técnica es útil para verificar la precisión de contornos y bordes, especialmente cuando se busca comprobar la regularidad o simetría de las estructuras detectadas (Kranthi Kumar, Chaduvula, y Rao Markapudi, 2020).

2.1.6. Reconocimiento y Clasificación mediante Deep Learning

Para la clasificación final de las imperfecciones, se descartaron los clasificadores clásicos (como las Máquinas de Soporte Vectorial) debido a su rigidez ante variaciones complejas, optando en su lugar por el Aprendizaje Profundo (Deep Learning).

Específicamente, se implementó una Red Neuronal Convolutiva (CNN) basada en la arquitectura EfficientNetB0. Las redes convolucionales operan aplicando múltiples filtros o núcleos matemáticos a la imagen, extrayendo mapas de características que van desde bordes simples en las primeras capas, hasta patrones complejos (como la refracción de una burbuja interna) en las capas más profundas.

La elección particular de la arquitectura EfficientNetB0 se fundamenta en su innovador método de "escalado compuesto". A diferencia de otras redes que aumentan su tamaño de forma arbitraria, esta arquitectura escala la profundidad, el ancho y la resolución de la red de manera balanceada. Esto permite lograr un nivel de precisión superior en la clasificación multiclase manteniendo un costo computacional sumamente bajo. Esta eficiencia algorítmica es el pilar que permite evaluar rápidamente una imagen con una alta confianza (Tan y Le, 2019).

2.1.7. Implementación de openCV

OpenCV es la librería de visión artificial más ampliamente utilizada a nivel mundial. Escrita en C y C++, cuenta con soporte para varios lenguajes de programación, entre ellos Python, que se empleará parcial o totalmente en el presente trabajo debido a su flexibilidad y legibilidad. Uno de los aspectos más sobresalientes de OpenCV es su alto nivel de eficiencia y rendimiento, lo que le permite operar en entornos con recursos limitados, como mini PC o teléfonos móviles de gama baja. Esta capacidad hace que sea ideal tanto para aplicaciones industriales como domésticas. Además, su compatibilidad con entornos de cómputo paralelo maximiza su desempeño en sistemas de múltiples núcleos, lo que la convierte en una herramienta poderosa para el procesamiento en tiempo real.

Gracias a esta eficiencia, OpenCV permite diseñar sistemas capaces de capturar, analizar y reaccionar ante imágenes en tiempo real, lo cual es fundamental en líneas de producción industrial para detectar errores de fabricación de manera inmediata. La biblioteca también ofrece herramientas avanzadas para la clasificación y segmentación de imágenes, lo que faci-

lita la identificación de objetos y la distinción de características específicas dentro de escenas complejas. Estas funciones se apoyan en clasificadores, algoritmos de clustering y técnicas de segmentación basadas en bordes o regiones, reduciendo la necesidad de depender de software externo y garantizando un alto rendimiento.

Otro aspecto clave de OpenCV es su capacidad para calibrar cámaras, eliminando distorsiones ópticas causadas por defectos en la lente o el sensor. Esta característica es esencial en sistemas que realizan mediciones dimensionales, ya que asegura que las imágenes capturadas representen con precisión la realidad física, evitando errores adicionales que comprometan la validez de los datos. En el contexto de este trabajo, esta capacidad resulta crítica para garantizar que las dimensiones medidas a través de visión artificial sean confiables.

A pesar de contar con una gran cantidad de herramientas propias, OpenCV también ofrece una notable compatibilidad con otras bibliotecas de inteligencia artificial y aprendizaje profundo, como TensorFlow y PyTorch. Esta integración permite ampliar sus capacidades cuando se requiere aplicar modelos más complejos de análisis o clasificación. Además, OpenCV es fácilmente ampliable mediante funciones personalizadas desarrolladas por el usuario, lo que proporciona una gran flexibilidad para abordar problemas específicos.

Finalmente, la comunidad activa que respalda a OpenCV, junto con una documentación extensa y detallada, facilita su aprendizaje y aplicación práctica. Existen numerosos ejemplos, tutoriales y proyectos similares que permiten acelerar el desarrollo y resolver rápidamente problemas comunes. Esta accesibilidad convierte a OpenCV en una herramienta no solo robusta, sino también amigable para desarrolladores con distintos niveles de experiencia (Bradski y Kaehler, 2008).

2.1.8. Uso de ROIs para optimización computacional

El ROI (Región de interés, por sus siglas en inglés) es una técnica ampliamente utilizada dentro de la visión artificial, ya que permite, en primera instancia, concentrar la aplicación de los algoritmos en una región muy específica, esto permite que no se tenga que preocupar por lidiar con una gran cantidad de datos que no son relevantes, esto también repercute en que se tenga que hacer uso de una menor cantidad de poder computacional ya que es menos cantidad de píxeles a procesar.

Se le considera a los ROI como sub imagen, ya que se forma una nueva imagen a partir de los puntos que estaban dentro de la imagen original, estas sub imágenes son muy útiles para poder separar la información de una toma completa, estas tomas son muy comunes en el ámbito industrial, ya que es más fácil que se tome una imagen de cuadro completo que una parte muy específica, con el fin de ahorrar de recursos, debido a que se procesan menos pixeles, mejorando las capacidades de ejecución en tiempo real del sistema que haga uso de los ROI. También ayuda a la mejora de la eficiencia de algoritmos de alta eficiencia al no tener que entrenarlos para ignorar datos irrelevantes y sólo darle datos que le sean relevantes (Hossain y cols., 2023).

2.1.9. Calibración del sistema de visión artificial

La calibración de una cámara es el proceso por el cual se toma una imagen y se compara con un patrón conocido, de esta forma, se observan los errores que se puedan presentar en la imagen tomada y se compensan para que la imagen tomada corresponda correctamente con la realidad.

Una cámara ideal tendría como modelo de cámara estenopeica o cámara pinole, es decir como una caja con un agujero muy pequeño, en este modelo, la imagen se forma perfectamente y sin distorsiones. El modelo de esta cámara está dado en la ecuación (2) donde se toma un punto tridimensional con coordenadas (X, Y, Z) proyectado a un plano bidimensional con coordenadas (x, y) , donde f será la distancia focal de la cámara. Lamentablemente, las cámaras realmente no siguen este modelo debido a que tienen lentes que son las que doblan la luz.

$$\begin{bmatrix} x \\ y \end{bmatrix} = \frac{1}{Z} \begin{bmatrix} f \cdot X \\ f \cdot Y \end{bmatrix} \quad (2)$$

Entre los principales problemas que se pueden presentar están los defectos de deformidad de la lente y de descentralización.

Uno de estos problemas es la distorsión radial, esta distorsión se da cuando la lente no está perfectamente tallada y tiene errores al formar la curva del lente, esta distorsión provoca que las líneas rectas se curven, esta curvatura provoca problemas en la dimensión vista. Existen

dos tipos principales de distorsión, la distorsión de barril y de cojín, el primero se da cuando las rectas parecen curvarse hacia afuera del campo visual, muy común en lentes de gran angular. Y el segundo es cuando las rectas se curvan hacia dentro del campo visual.

La ecuación para la corrección radial se muestra en la ecuación (3) donde tenemos a la distancia r que es la distancia radial del punto al centro óptico, r' sería la distancia radial corregida y k_1, k_2, k_3 siendo los coeficientes de corrección que provienen del uso de tableros de ajedrez o cuadrículas que son usados como patrones conocidos para la calibración.

$$r' = r(1 + k_1r^2 + k_2r^4 + k_3r^6) \quad (3)$$

Otro problema es el descentrado de las lentes, en este problema la lente o lentes no está perfectamente alineado con el centro del receptor, este problema se puede presentar por alguna inexactitud de los soportes de la lente o de la misma lente que no fue tallada perfectamente céntrica. Este error induce problemas de enfoque en la imagen o generando zonas borrosas.

Para corregir este problema, se hace uso de matrices de transformación, que ajustan el punto central de la cámara con la ecuación (4), en la que se puede ver la ecuación de corrección para cada una de las coordenadas del centro de la cámara, donde (x', y') son las coordenadas corregidas y $(\Delta x, \Delta y)$ los desplazamientos causados por el descentrado.

$$x' = x + \Delta x, \quad y' = y + \Delta y \quad (4)$$

El proceso para la corrección de los errores de calibración es: se toman múltiples imágenes de un objeto conocido, como un tablero de ajedrez; se detectan los puntos clave; se calculan los parámetros de las ecuaciones de corrección; y finalmente se aplican las correcciones a las configuraciones de la cámara para tener una imagen más precisa (Zhong y Dong, 2015).

2.1.10. Calibración directa y calibración usando patrones

En una calibración directa se toman en cuenta únicamente las características de la cámara, la distancia al objetivo y las coordenadas tridimensionales del objeto. Con estos parámetros es posible determinar el tamaño aparente del objeto frente a la cámara. Sin embargo, este enfo-

que presenta una alta sensibilidad al tipo de cámara y a las distorsiones ópticas introducidas por la lente. Aunque este método fue el más empleado durante muchos años y se conoce como calibración tradicional, su precisión se ve limitada por dichas variables, lo que puede generar errores importantes en las mediciones.

En contraste, la calibración con patrones utiliza una referencia física conocida para relacionar los píxeles con medidas reales. Generalmente se emplean patrones como tableros de ajedrez o arreglos de puntos, aunque también pueden utilizarse otros objetos de dimensiones conocidas. Al conocer con exactitud las dimensiones del patrón, el sistema puede compensar errores ópticos y lograr una mayor precisión dimensional. Este método permite ajustar dinámicamente la relación entre píxeles y unidades métricas, adaptándose a las condiciones reales del sistema de visión.

Es importante destacar que la fuente de iluminación juega un papel crítico en este proceso. Su intensidad y uniformidad pueden alterar la percepción de los bordes del patrón, especialmente si este no es completamente plano o si presenta relieves. Estos efectos pueden provocar errores en la detección de puntos de referencia y, en consecuencia, afectar la calibración. Por ello, la mejor forma de garantizar mediciones confiables es realizar la calibración y la adquisición de imágenes en condiciones constantes, prestando especial atención a la distancia entre el objeto y la lente, así como a la intensidad de la luz utilizada (Duan, Wang, Zhao, y Zhao, 2016).

2.2. Principios de la extrusora de un solo husillo y formación del filamento

La extrusión de polímeros es un proceso termomecánico donde el material es forzado a través de una matriz para generar un perfil continuo. La extrusora de un solo husillo (Figura 1) se divide funcionalmente en tres zonas críticas, según la dinámica del transporte de sólidos y fundido (Osswald y Hernández-Ortiz, 2017):

- **Zona de alimentación:** Los pellets de polímero ingresan desde la tolva. En esta etapa, el diseño del husillo se enfoca en el transporte de sólidos mediante la fricción entre el material, el cilindro (barril) y el canal del husillo.

- **Zona de compresión o transición:** El canal del husillo disminuye su profundidad gradualmente. Esto genera una alta presión que elimina el aire atrapado y compacta el material mientras se funde debido al calor de las resistencias y el calor disipado por el cizallamiento viscoso.
- **Zona de dosificación (Metering):** En esta etapa final, el polímero se encuentra en un estado viscoelástico homogéneo. El husillo actúa como una bomba de presión constante que garantiza que el flujo hacia el dado sea uniforme y estable.

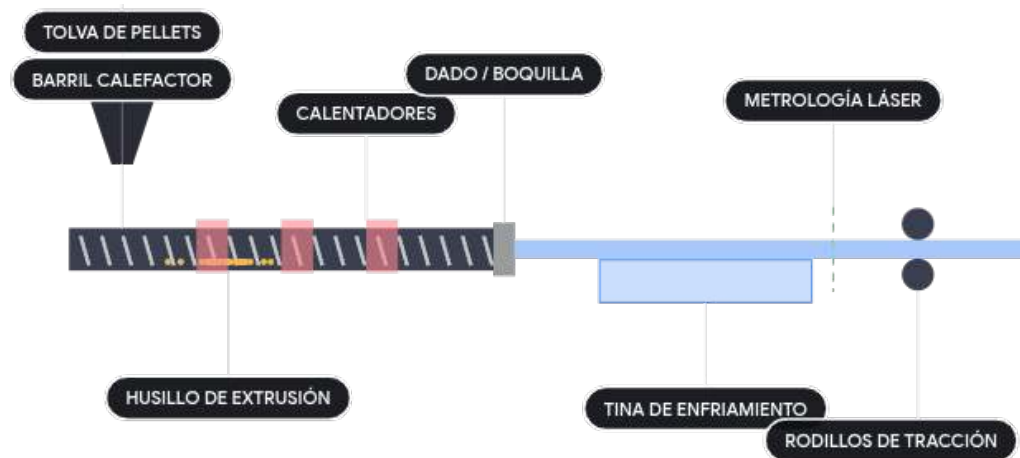


Figura 1: Diagrama de funcionamiento de una extrusora de filamento.

2.2.1. Dinámica de formación y calibración dimensional

Al abandonar el dado, el polímero fundido experimenta el fenómeno de hinchamiento (*die swell*), resultado de la memoria elástica del material al liberarse de los esfuerzos de cizallamiento (Vlachopoulos y Polychronopoulos, 2019). La formación final del diámetro (1.75 mm en este caso) no depende únicamente del orificio del dado, sino de la relación de estiramiento (*drawdown ratio*) impuesta por el sistema de tracción (*puller*).

El filamento se solidifica en una tina de enfriamiento. Si el diferencial térmico entre el núcleo y la superficie es asimétrico, se generan tensiones residuales que derivan en ovalidad. La estabilidad de este proceso es fundamental, pues pequeñas fluctuaciones en las revoluciones por

minuto (RPM) del husillo o en la velocidad del puller se traducen en variaciones volumétricas detectables por el sistema de visión artificial desarrollado (Valerga y cols., 2018).

2.3. Proceso de extrusión y fundamentos reológicos

La fabricación de filamentos termoplásticos para impresión 3D se realiza a través de un proceso de extrusión continuo, el cual transforma la materia prima sólida en un perfil cilíndrico constante. Sin embargo, los polímeros fundidos no se comportan como fluidos newtonianos, sino que presentan un comportamiento viscoelástico complejo que afecta directamente la calidad dimensional del extruido, fenómeno estudiado a fondo por la reología de polímeros (Vlachopoulos y Polychronopoulos, 2019).

Durante su paso por el dado de extrusión, el polímero está sometido a altas tasas de cizallamiento. Debido a su naturaleza pseudoplástica (*shear-thinning*), la viscosidad del material disminuye a medida que aumenta la velocidad de deformación. Al abandonar el dado extrusor, el material experimenta una caída abrupta en los esfuerzos y una relajación de las cadenas poliméricas previamente estiradas.

Este fenómeno de relajación elástica da lugar al hinchamiento del extruido (conocido como *die swell*), donde el diámetro del filamento emergente es mayor que el orificio del dado (Vlachopoulos y Polychronopoulos, 2019). Si el enfriamiento posterior en las tinas de agua no es térmicamente uniforme, o si las tensiones mecánicas del sistema de tracción varían, la contracción viscoelástica se vuelve asimétrica. Esta asimetría reológica y térmica es la causa fundamental de los problemas de ovalidad, estrías y variaciones de diámetro longitudinal que afectan a las piezas fabricadas mediante deposición de material fundido (Valerga y cols., 2018).

2.4. Fundamentos de metrología dimensional en visión artificial

Al funcionar el sistema propuesto como un instrumento de inspección y metrología óptica sin contacto, es imperativo establecer los conceptos metroológicos fundamentales que rigen

la evaluación de su desempeño. En el ámbito del control de calidad automatizado moderno, los parámetros de medición se definen de la siguiente manera (Czimmermann y cols., 2020; Duque-Domingo y cols., 2024):

- **Exactitud de medida:** Es el grado de concordancia entre un valor medido y un valor verdadero de un mensurando. En el contexto de este sistema, define qué tan cerca está el diámetro calculado por el algoritmo de visión artificial del diámetro físico real del filamento plástico.
- **Precisión de medida (Repetibilidad):** Es el grado de concordancia entre las indicaciones obtenidas en mediciones repetidas del mismo objeto, bajo condiciones idénticas de iluminación y procesamiento. Evalúa la dispersión y consistencia de los resultados numéricos de la red y el algoritmo.
- **Resolución espacial:** Es la mínima variación de la magnitud medida que da lugar a una variación perceptible. En este proyecto metrológico, la resolución máxima está dictada por la equivalencia geométrica en milímetros por píxel (mm/px).
- **Trazabilidad metrológica:** Es la propiedad por la cual el resultado de la medición óptica puede relacionarse de manera documentada con una referencia física de mayor exactitud. En este desarrollo, la trazabilidad se establece al calibrar las cámaras contra un patrón cilíndrico rectificado, validado previamente con un micrómetro mecánico.

2.5. Técnicas de medición de calidad en filamentos

2.5.1. Métodos ópticos de medición dimensional

La medición dimensional es el proceso por el cual se tiene el tamaño de un objeto, hablando de métodos ópticos, se pueden usar láseres que miden la distancia de un punto a otro del objeto según la interrupción del láser con el objeto. Un método más avanzado de medición óptica es el uso de cámaras, las cámaras usan la cuenta de los píxeles para poder lograr tener una dimensión, por lo que es importante poder saber dónde empieza y termina el objeto, es donde los filtros entran en efecto.

En el presente trabajo se mencionarán 3 filtros que se usarán para la medición dimensional óptica, siendo estos los sugeridos para tal fin, pero no siendo estos los filtros finales a usar.

Filtro Sobel

El filtro Sobel es un filtro para la identificación de bordes de una imagen, para lo cual utiliza dos kernel diferentes, uno que es sensible para los bordes verticales y otro para los horizontales, este sistema de hacer uso de dos kernel ayuda a poder mitigar aún más el ruido, proporcionando una ponderación en escala de grises.

Los kernel para la detección de los bordes horizontales (S_x) y verticales (S_y) se presentan en la ecuación (5), para aplicarlos se obtiene el gradiente que se pondrá en cada pixel, este se puede ver en la ecuación (3), donde se separa cada gradiente por horizontal ($G_x(i, j)$) y vertical ($G_y(i, j)$), al final se obtiene la magnitud del gradiente completo del píxel ($G(i, j)$) y la dirección de este ($\theta(i, j)$) en la ecuación (7). Con este proceso se resaltan los cambios bruscos en la imagen, identificándolos como si fuera un borde.

$$S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \quad S_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (5)$$

$$G_x(i, j) = \sum_{u=-1}^1 \sum_{v=-1}^1 I(i+u, j+v) \cdot S_x(u, v), \quad G_y(i, j) = \sum_{u=-1}^1 \sum_{v=-1}^1 I(i+u, j+v) \cdot S_y(u, v) \quad (6)$$

$$G(i, j) = \sqrt{G_x(i, j)^2 + G_y(i, j)^2}, \quad \theta(i, j) = \arctan\left(\frac{G_y(i, j)}{G_x(i, j)}\right) \quad (7)$$

2.5.2. Detección de defectos mediante procesamiento de imágenes

Los métodos de detección de defectos mediante imágenes se clasifican dentro de las pruebas no destructivas, caracterizadas por no causar daño adicional a la muestra durante su análisis.

Este enfoque presenta ventajas significativas, ya que el uso de cámaras digitales modernas tiene un bajo costo y un consumo energético reducido. Además, la captura de imágenes es muy rápida, y al combinar una buena iluminación con una lente de campo amplio y un arreglo de espejos, es posible obtener múltiples secciones y vistas del objeto al mismo tiempo.

El proceso de detección de defectos sigue una secuencia clara: obtención de imágenes, procesamiento y acondicionamiento, extracción de características y clasificación. La obtención requiere un sistema de captura bien calibrado que considere las posibles distorsiones de lente y sensor, asegurando así una representación fiel de la realidad. Es fundamental que el sensor tenga la resolución suficiente para captar todos los detalles relevantes y que la iluminación proporcione un nivel adecuado de brillo y contraste.

Durante el procesamiento de la imagen, la captura a color se convierte inicialmente a escala de grises. Posteriormente, se aplican técnicas para mejorar la calidad visual y facilitar el análisis, tales como el filtrado de mediana (*Median Blur*) para reducir el ruido sin difuminar los bordes, y la ecualización adaptativa de histograma (CLAHE) para mejorar el contraste local. La extracción de características implica detectar elementos relevantes como los límites espaciales del objeto; para ello, operadores basados en gradientes como el filtro Sobel son ampliamente utilizados. En particular, la aplicación de Sobel combinada con operaciones morfológicas (como el cierre) permite resaltar e identificar los cambios abruptos que delimitan los contornos longitudinales del filamento.

Finalmente, en la etapa de clasificación, se aplican técnicas de aprendizaje profundo (*Deep Learning*). Las Redes Neuronales Convolucionales (CNN), mediante arquitecturas optimizadas como *EfficientNet*, son capaces de procesar las regiones de interés extraídas para identificar patrones complejos. Estas herramientas, una vez entrenadas, permiten distinguir automáticamente entre filamentos en estado normal y aquellos que presentan defectos críticos como burbujas o contaminación superficial (Czimmermann y cols., 2020).

2.5.3. Importancia de la iluminación en la medición óptica

La iluminación es un paso crítico para la medición óptica, ya que una correcta iluminación puede ser la diferencia entre una imagen útil y una que es imposible obtener información. La finalidad de una correcta iluminación es incrementar el contraste en las características deseadas, reducir el contraste de todo lo demás y aumentar la robustez de la medición; para

lograr estos criterios hay que tomar en cuenta el tipo de iluminación, la geometría, filtros o patrón de la iluminación.

Tipos de iluminación

El tipo de iluminación proporciona una gama completamente diferente de información, ya que en este aspecto se consideran tanto la intensidad como la o las longitudes de onda y la forma en que se emite la luz. Tradicionalmente, las fuentes fluorescentes y la halógena de cuarzo han sido ampliamente utilizadas por ofrecer una luz brillante, confiable y con una buena relación costo-eficiencia. Sin embargo, en los últimos años, el uso de diodos emisores de luz (LED) ha comenzado a desplazarlas gracias a su capacidad para ofrecer resultados equivalentes con un menor consumo energético, un costo reducido y una vida útil significativamente mayor. Cuando se requiere un brillo particularmente alto, la luz de haluro metálico es una de las opciones más empleadas.

Para aplicaciones que demandan luz parpadeante e intensa, el xenón ha sido una fuente destacada por su capacidad de emitir destellos rápidos, aunque incluso en este campo los LED están ganando terreno debido a su capacidad para igualar la intensidad, ofrecer mayor velocidad de parpadeo y permitir un control más preciso. En muchos casos, una sola fuente de iluminación no resulta suficiente para revelar todos los detalles necesarios; por ello, es común emplear dos tipos distintos de iluminación de forma complementaria, aprovechando las fortalezas de cada una para resaltar diferentes características de la muestra.

Geometría de iluminación

Al hablar de la geometría nos referimos a la disposición física de las fuentes de luz en relación con la muestra y el sensor de la cámara. Este aspecto es crucial para lograr una distribución uniforme de la luz y evitar sombras o reflejos que puedan opacar las características relevantes en la imagen. La forma en que se configura esta geometría influye directamente en la calidad y utilidad de la imagen capturada.

Existen varios tipos de iluminación según esta geometría. La iluminación coaxial se produce cuando la fuente de luz se alinea con el eje óptico del sensor, lo que permite una distribución uniforme de la luz y minimiza la aparición de sombras. No obstante, este tipo de iluminación

puede provocar reflejos molestos cuando se trabaja con materiales muy reflectivos. Por otro lado, la iluminación oblicua se genera al dirigir la luz desde un costado del eje formado entre el sensor y la muestra, lo que facilita la visualización de texturas y contornos en la superficie, siendo especialmente útil para identificar defectos superficiales o trabajar con materiales brillantes.

Además, la iluminación mediante difusores y reflectores permite suavizar la luz, eliminando zonas de sobre o subexposición y proporcionando una iluminación homogénea. Finalmente, la retroiluminación es ideal para resaltar los contornos de la muestra y, en el caso de materiales semitransparentes o transparentes, permite visualizar también su interior.

Filtros y patrones de iluminación

Los filtros y los patrones permiten agregar una forma más de control a la iluminación para resaltar aún más algunas características, esto gracias a que los filtros permiten cambiar o eliminar componentes espectrales de la fuente de iluminación, y al poder ser estos intercambiables se pueden mover para ver algún detalle específico en cualquier momento, pudiendo ser este cambio totalmente automático. Para los patrones nos puede ayudar a hacer más visibles algunas características, algunos ejemplos son rayas o puntos que nos permiten ver la geometría de la superficie a revisar o a compensar posibles distorsiones en la lente de la cámara (Martín, Sales, y Manager, 2013).

2.5.4. Norma ISO 5425:2023

Debido a la necesidad de la repetibilidad y confianza en la extrusión de material, el filamento usado se ha vuelto un factor crítico. Debido a esto, se ha publicado la norma ISO 5425:2023, en la cual se establecen los requisitos técnicos y metodologías necesarias para estandarizar la producción y evaluación de filamentos de PLA, destacando, que sus tolerancias dimensionales son aplicables directamente a otros materiales.

Dentro de la norma se especifica que el diámetro del filamento debe mantenerse dentro de tolerancias estrictas dependiendo de su clasificación (1). Para filamentos de 1.75 mm considerados como productos premium, la tolerancia máxima permitida es de ± 0.03 mm, lo que establece un límite inferior admisible de 1.72 mm y un límite superior de 1.78 mm. Para

filamentos clasificados únicamente como calificados, la tolerancia se mantiene igual. Adicionalmente, la ovalidad, que es la diferencia entre los diámetros mayor y menor en una sección transversal, no debe superar los 0.05 mm en filamentos de 1.75 mm.

Tabla 1: Tolerancias dimensionales aceptadas por la norma ISO 5425:2023

Diámetro Nominal (DN)	Tolerancia		Ovalidad Máxima
	Producto Premium	Producto Calificado	
1.75 mm	± 0.03 mm	± 0.05 mm	≤ 0.05 mm
otra media	± 1.7 % DN	± 1.1 % DN	$\leq \pm 2.6$ % DN

En cuanto a propiedades mecánicas, se establece una carga de tracción mínima de 125 N para filamentos de 1,75 mm, lo cual garantiza un nivel básico de integridad estructural durante el proceso de impresión. Asimismo, se exige una elongación mínima en la rotura del 10 % para filamentos de 1,75 mm, como parámetro de flexibilidad y resistencia a la fractura durante el bobinado y alimentación.

Otro aspecto fundamental abordado por la norma es el contenido de humedad, el cual no debe superar el 0,5 %. La presencia excesiva de humedad puede causar problemas severos en la impresión como burbujeo, deformaciones o pérdida de adherencia entre capas. También se exige una apariencia uniforme del filamento: libre de burbujas, rayaduras o impurezas visibles, ya que estos defectos pueden derivar en fallos mecánicos o estéticos en las piezas finales.

Además de los criterios de calidad física y mecánica, la norma exige un etiquetado claro y completo que incluya información sobre el tipo de material, color, país de origen, temperatura recomendada de impresión, masa neta y código de identificación, con el fin de facilitar su trazabilidad y uso correcto.

Finalmente, la ISO 5425:2023 propone métodos estandarizados para la evaluación de estas propiedades, incluyendo mediciones de diámetro y ovalidad mediante micrómetros o sistemas láser, ensayos de tracción, y determinación de humedad mediante técnicas gravimétricas. También se introducen consideraciones ambientales importantes, como la procedencia de la materia prima, huella de carbono, reciclabilidad del producto y principios de economía circular (International Organization for Standardization, 2023).

2.6. Factores que afectan la detección de defectos

2.6.1. Sensor IMX317

El sensor de imagen utilizado en un sistema de visión artificial es un componente crítico para garantizar el correcto desempeño del equipo. En el presente trabajo, se requiere un sensor de alto rendimiento y alta definición, ya que se llevarán a cabo mediciones dimensionales en objetos pequeños, donde los márgenes de tolerancia son reducidos. Por esta razón, se ha propuesto como principal opción el sensor Sony IMX317, dadas sus capacidades técnicas que se ajustan a los requerimientos del sistema.

El Sony IMX317 es un sensor CMOS de tipo 1/2.5" que ofrece una resolución efectiva de 3840 x 2160 píxeles (8.29 megapíxeles), equivalente a video 4K. Esta alta resolución permite capturar imágenes nítidas y detalladas, esenciales para tareas de inspección visual y monitoreo de calidad. Con un tamaño de píxel de 1.62 μm x 1.62 μm , proporciona una sensibilidad considerable, alcanzando aproximadamente 1145 dígitos a F5.6 con una integración de 1/30 s, y un nivel de señal de saturación mínimo de 3050 dígitos, lo que garantiza un rendimiento fiable incluso en condiciones de iluminación cambiantes.

El sensor admite varios modos de lectura, con resoluciones que van desde 1280 x 720 hasta 3840 x 2160 píxeles, y tasas de fotogramas desde 32.81 fps hasta 249.26 fps, dependiendo del modo y de la interfaz seleccionada (CSI-2 o Sub-LVDS). Esta versatilidad lo convierte en una herramienta adaptable a diferentes requisitos de velocidad y resolución según la aplicación concreta.

Además, el IMX317 incorpora características avanzadas como obturador electrónico con tiempo de almacenamiento variable, reducción de corriente oscura, bajo nivel de ruido y alta sensibilidad. También incluye capacidades de alto rango dinámico (HDR) mediante la función Digital Overlap HDR (DOL-HDR), lo que mejora la visibilidad de detalles en escenas con alto contraste.

Gracias a esta combinación de precisión, calidad de imagen y adaptabilidad, el Sony IMX317 representa una opción adecuada para sistemas de monitoreo en tiempo real, donde es fundamental detectar y clasificar irregularidades con alta fiabilidad en entornos industriales exigentes (Sony Corporation, 2018).

2.6.2. Influencia del color y transparencia

En el presente trabajo, uno de los principales desafíos en relación al color y transparencia de los filamentos a medir es la dificultad que causan estas propiedades al momento de hacer las mediciones. Estas variaciones de color y transparencia podrían provocar errores en los algoritmos de clasificación al momento de su entrenamiento.

Problemas asociados a filamento transparentes

En particular, los filamentos transparentes presentan una complicación única por los fenómenos ópticos que presentan cuando la luz interactúa con ellos. Uno de estos fenómenos ópticos es el brillo especular que puede ocurrir con el uso de retroiluminación, este tipo de brillo causa que el centro del filamento sea mucho más brillante que el resto, este aumento desmedido del brillo podría provocar que se puedan ocultar las burbujas o impurezas que se puedan encontrar dentro del filamento haciendo complicado reconocer estas características del filamento. Una forma de mitigar este problema es el considerar el ángulo de incidencia de la luz y el tipo de iluminación, buscando que la iluminación no esté perfectamente alineada con la cámara y que se use iluminación difusa.

Influencia del color en la detección

Otro aspecto a tomar en cuenta es el color, diferentes colores interactuarán de forma diferente con la luz, los colores más oscuros la absorberán, esto provocaría que el algoritmo de detección de impurezas detecte todo el filamento como una o bien le sea imposible desempeñar su labor, en caso de los de colores de baja saturación o claros pasaría como en el caso anterior de los transparentes, pudiendo con pequeñas variaciones en los pigmentos dar falsos positivos de impurezas y burbujas.

Este problema se debe abordar principalmente por software, usando normalización del histograma o usar espacios de color más robustos contra estos cambios. Otra opción sería usar filtros especiales en la iluminación o la cámara. Para cambios constantes de color se podrían hacer constantes calibraciones para mantener al día al sistema o usar algoritmos adaptativos (Chiang, Yang, Liu, y Lin, 2023).

2.6.3. Impacto del ruido en la detección de defectos

El ruido en una imagen es un problema que está presente en todos los sistemas de visión artificial, este normalmente causa que la imagen pierda la definición de sus características, o perderlas por completo, por lo que es importante mitigarlo.

Supresión de ruido y mejora de contraste

En el procesamiento de imágenes industriales, la eliminación de ruido no debe comprometer la nitidez de las características métricas. Por ello, se descartan filtros de difuminado general (como el Gaussiano) en favor del filtrado de mediana (Median Blur). Este filtro no lineal es altamente efectivo para eliminar el ruido impulsional preservando la integridad de los bordes del objeto (Gonzalez y Woods, 2018), lo cual es crítico para la medición dimensional del filamento.

Adicionalmente, los filamentos plásticos (especialmente los translúcidos o brillantes) generan reflejos especulares que saturan el sensor. Para mitigar esto, se implementa la Ecuilización Adaptativa de Histograma Limitada por Contraste (CLAHE). Esta técnica divide la imagen en regiones y ecualiza el contraste localmente, evitando la sobreexposición y mejorando drásticamente la visibilidad de imperfecciones internas previas a la evaluación por algoritmos de inteligencia artificial (Bae, Yoon, y Cho, 2025).

Necesidad del filtrado

En ocasiones no es necesario filtrar el ruido, pues este no afecta en los procesos posteriores, un ejemplo de eso es el uso del filtro Sobel que, por el uso de un gradiente, puede contrarrestar casi totalmente el ruido cuando no es muy notorio y deja los bordes más prominentes intactos, por lo que es importante siempre valorar la cantidad de ruido presente y si es necesario aplicar un filtro, ya que podríamos perder detalles si aplicamos mal el filtro; por lo que podemos decir que el ruido no siempre es un problema y dependerá más del caso específico que se tenga (Tang, Chen, Sun, y Lin, 2023).

2.7. Sensibilidad del sistema a condiciones ambientales

En general, todos los sistemas de visión tienen problemas por los cambios ambientales que se presentan, especialmente cuando estos cambios implican aumento o descenso drástico de brillo o algún material que impide la vista. Estos cambios provocan que se pueda perder la precisión o incluso impedir por completo la medición, por lo que es importante poder mantener estos problemas bajo control.

La forma de poder contrarrestar estos inconvenientes pasa por soluciones que ajusten el brillo, de la fuente de iluminación, por ejemplo, en una fuente retroiluminada el poder ajustar la salida de luz de esta podría suprimir algunos efectos, reduciendo su brillo para no saturar al sensor cuando le llega más luz de la esperada o aumentándolo si hay algún material que se interponga en la visión del sensor. Otro acercamiento por hardware es el encerrar todo el equipo en una cámara que esté aislada de lo que pase en el exterior, pese a que esta es una aproximación más sensata y simple en condiciones de laboratorio, es poco probable que sea el enfoque usado en este trabajo.

En la parte de software pasa por la normalización de histograma o el uso de sistemas adaptativos, los cuales podrían responder a estos cambios de forma más rápida compensando estos cambios. Un enfoque con mejor probabilidad de éxito serían sistemas híbridos que integren ajustes por hardware y software incluyendo sensores ambientales (Caraiman y cols., 2017).

2.8. Defectos: burbujas e impurezas

Las impurezas y las burbujas en el filamento de impresión 3D son dos de los defectos más comunes y críticos, pues afectan tanto el proceso de extrusión como las propiedades finales de las piezas impresas.

En primer lugar, las impurezas pueden tener orígenes muy diversos: restos de polvo o fibras de ambiente, fragmentos de otros polímeros adheridos al husillo de extrusión, aditivos mal mezclados o incluso pequeñas partículas de metal procedentes del proceso de fabricación del filamento. Al entrar al hot end, estas partículas no fundidas funcionan como obstáculos en el flujo plástico, provocando una extrusión irregular. En la práctica esto se traduce en surcos visibles o “puntos duros” en la superficie de la pieza, así como en un aumento de

la presión interna que puede dañar el engranaje de alimentación o la boquilla. Cuando la partícula alcanza un tamaño cercano al diámetro de la boquilla, es casi seguro que causará un atasco parcial o total, forzando la máquina a parar o a retracción excesiva, lo que a su vez deja conos, hilos sueltos y fallos estéticos. Incluso si no obstruyen por completo, las impurezas actúan como defectos nucleantes: un pequeño granizo que inicia grietas cuando la pieza está bajo carga o vibración.

Por su parte, las burbujas se originan cuando el filamento contiene humedad o gases disueltos. Durante el secado inadecuado o el almacenamiento en ambientes húmedos, las moléculas de agua penetran en el polímero; al llegar al hot end, esa agua se vaporiza violentamente y forma pequeñas cavidades de gas. Al expandirse dentro del flujo fundido, estas cavidades se convierten en micro explosiones que interrumpen momentáneamente el suministro continuo de material, generando pequeñas “pompas” o agujeros internos en la pieza. En lugar de un conducto de plástico homogéneo, el extrusor descarga un chorro intermitente de burbujas y plásticos, lo que provoca una superficie granulada y quebradiza. Esas burbujas internas también son puntos débiles: bajo esfuerzos mecánicos, concentran tensiones en su perímetro y actúan como iniciadores de grietas, reduciendo drásticamente la resistencia a la tracción y la durabilidad de la pieza.

Además, la combinación de impurezas y burbujas multiplica los problemas. Una burbuja que explota junto a una partícula contaminante puede generar un fragmento de material mal fundido que incrusta aún más aire y polvo en la pieza. Este efecto en cascada convierte defectos puntuales en fallos generalizados, complicando el postprocesado y la postergación de la calidad hasta la fase final de impresión.

Dado el alto impacto de estos defectos, la identificación y el control tanto de impurezas como de burbujas resultan imprescindibles. En un entorno industrial de alta velocidad, donde cada segundo de paro cuesta dinero, detectar y descartar filamentos defectuosos antes de su uso en la impresora puede ahorrar horas de tiempo de máquina y kilogramos de material perdido. En el plano del usuario doméstico o de laboratorio, evita frustraciones y permite concentrarse en la creatividad y la funcionalidad, en lugar de lidiar con impresiones fallidas. Por ello, un sistema de inspección previo que combine detección óptica de partículas y medición de translucidez para revelar cavidades internas se convierte no solo en un lujo, sino en una necesidad para garantizar la fiabilidad y repetibilidad de la impresión 3D (Baechle-Clayton, Loos, Taheri, y Taheri, 2022; Ng, Koay, Chan, Choo, y Ong, 2020).

Capítulo 3

Metodología

Este capítulo detalla la aplicación de los fundamentos teóricos previamente expuestos, describiendo el diseño, construcción e implementación del sistema de inspección visual para filamentos de impresión 3D.

3.1. Diseño mecánico y hardware de procesamiento

La estructura que soporta la cámara y los espejos fue diseñada utilizando el software CAD online Onshape. Los modelos tridimensionales se desarrollaron con un enfoque modular, lo que permite modificar posiciones y ángulos mediante el ajuste de tornillería. La manufactura de las piezas se realizó mediante impresión 3D utilizando PETG con un alto porcentaje de relleno, garantizando la rigidez estructural necesaria para las geometrías delgadas del diseño.

Para el ensamble se emplearon tornillos fosfatados M5 y M6. Una vez lograda la alineación óptica óptima, la estructura se fijó de manera permanente utilizando cianoacrilato y un acelerante a base de una solución sobresaturada de bicarbonato de sodio, con el fin de evitar cualquier movimiento o desajuste provocado por vibraciones. Estratégicamente, se dejaron cuatro tornillos sin fijar, lo que permite extraer el módulo de los espejos para realizar tareas de mantenimiento, limpieza de la óptica y ajustes finos.

En cuanto a la unidad de procesamiento, el software fue diseñado con una arquitectura multiplataforma. Sin embargo, para la validación de este prototipo, el sistema se ejecutó bajo el

sistema operativo Linux Mint en un equipo informático con un procesador Intel Core i7 de cuarta generación y 8 GB de memoria RAM. Cabe destacar que el procesamiento matemático y la inferencia de la red neuronal se ejecutan íntegramente en la CPU. Se prescindió de la aceleración por hardware mediante tarjeta gráfica (debido a incompatibilidades de soporte con la GPU AMD integrada) con el objetivo de demostrar la alta eficiencia y el bajo costo computacional de los algoritmos desarrollados. La comunicación y transmisión de video desde la cámara se realiza mediante una interfaz USB estándar.

3.2. Diseño del sistema de adquisición óptica

La base del funcionamiento del sistema radica en la captura de imágenes del filamento con una resolución y nitidez óptimas. Dado que la medición dimensional se fundamenta en la distancia en píxeles entre los bordes detectados, se seleccionó el sensor Sony IMX317 por su capacidad de captura en resolución 4K y su alta sensibilidad lumínica. La captura macrofotográfica de un objeto de dimensiones milimétricas, situado a escasa distancia de la lente, presenta retos significativos de enfoque. Para solucionar esto, se ajustó el iris de la cámara para limitar la entrada de luz, incrementando así la profundidad de campo y asegurando que los bordes del filamento se mantengan nítidos.

Para lograr una reconstrucción dimensional precisa y detectar defectos que podrían quedar ocultos, se diseñó un arreglo catóptrico que permite obtener tres vistas simultáneas (frontales y laterales a 120°) utilizando un solo sensor. La arquitectura se basa en una distancia de 35 mm entre la lente del sensor y el centro del filamento. Los espejos laterales se posicionaron con un ángulo de inclinación de 45° respecto al eje óptico principal, permitiendo que las reflexiones se proyecten de forma paralela en el sensor, optimizando así el uso del área efectiva del sensor 4K (Figura 2).




Figura 2: A) Vista lateral mostrando la posición de la cámara, el filamento, los espejos y las luces. B) Vista frontal desde la perspectiva del sensor. (Autoría propia)

3.3. Sistema de iluminación y calibración métrica

Se implementó un arreglo de iluminación indirecta utilizando grupos de diodos emisores de luz (LED) de GaN (Nitruro de Galio) de 5 mm. Estos componentes proporcionan una iluminancia de 19,680 lux (medida en el plano de incidencia del filamento) con una temperatura de color de 6,500 K (blanco frío), garantizando un contraste óptimo para la detección de bordes y texturas superficiales. El circuito consta de cuatro LEDs conectados en serie con una resistencia de limitación de 333Ω , alimentados por una fuente ajustable de 12 V a 15 V. Esta configuración permite una iluminación "modulada" mediante el control del voltaje de entrada, evitando la saturación del sensor IMX317 en filamentos altamente reflectivos y permitiendo ajustar la penetración lumínica en materiales translúcidos.



Figura 3: Vista frontal sin espejos del sistema de adquisición de imágenes del diagrama de luces, cámara y el filamento. (Autoría propia)

Para garantizar la precisión metrológica del sistema informático, se llevó a cabo un proceso de calibración utilizando un patrón físico de dimensiones conocidas. Se empleó un rayo de bicicleta de acero de 2.32 mm de diámetro, verificado previamente con un micrómetro Mitutoyo (margen de error de 0.005 pulgadas). Para emular las propiedades ópticas ideales, la superficie del patrón fue pulida a nivel de espejo y posteriormente recubierta con pintura

blanca mate, permitiendo que el algoritmo de visión artificial extraiga la constante de conversión milímetros por píxel con alta fidelidad. En la Figura 4 se puede observar en la parte A la captura del patrón de calibración visto desde la cámara a través del arreglo de espejos, y en la parte B, la validación dimensional de dicho patrón mediante el micrómetro.




Figura 4: A) Vista macro del patrón de calibración en la cámara con los espejos. B) Medición del patrón de calibración con micrómetro.(Autoría propia)

3.4. Arquitectura de Software e Interfaz HMI

Para garantizar la operabilidad del sistema en un entorno industrial o de laboratorio, se desarrolló una Interfaz Hombre-Máquina (HMI) robusta utilizando el lenguaje Python y la biblioteca customtkinter. Esta interfaz (Figura 5) centraliza el monitoreo y la configuración del equipo, permitiendo al operador visualizar el estado del material en tiempo real mediante un panel de metrología que reporta el diámetro promedio, la ovalidad y los niveles de contracción térmica.

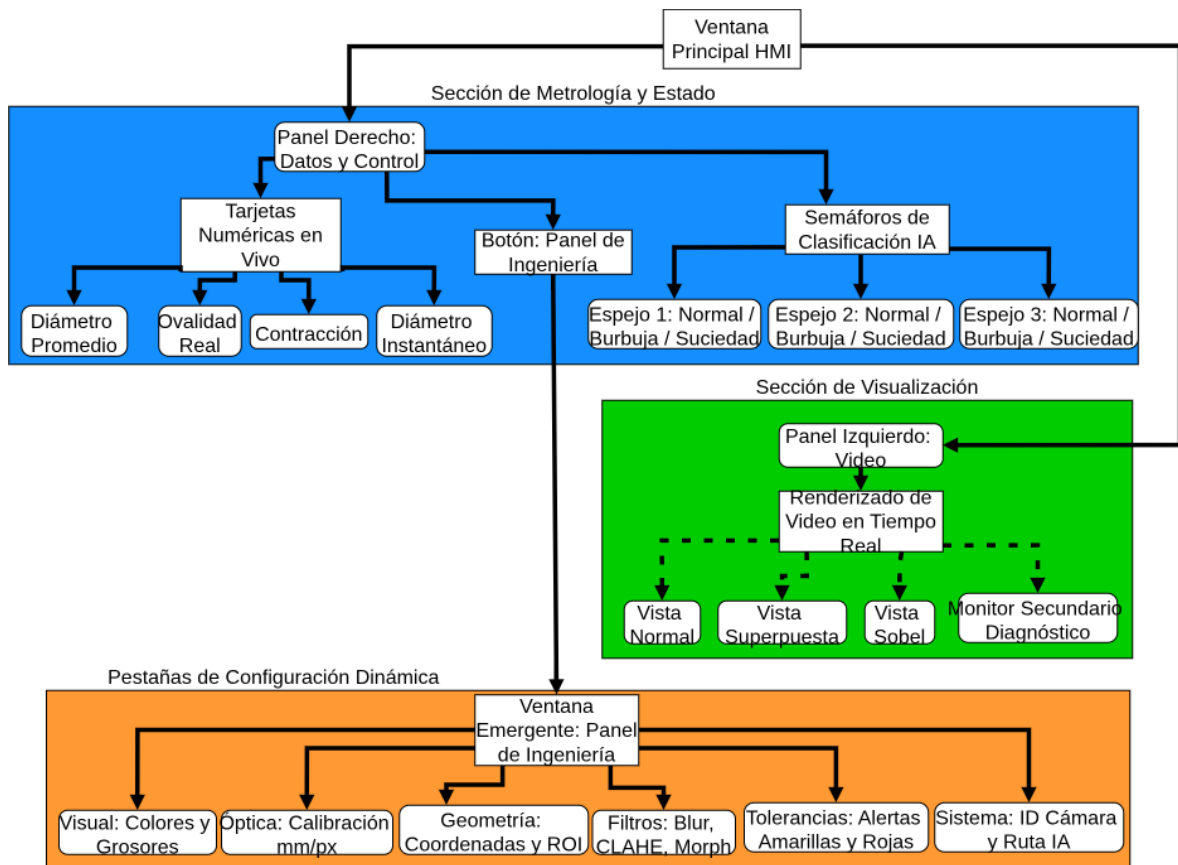


Figura 5: Diagrama del funcionamiento de la interfaz HMI.(Autoría propia)

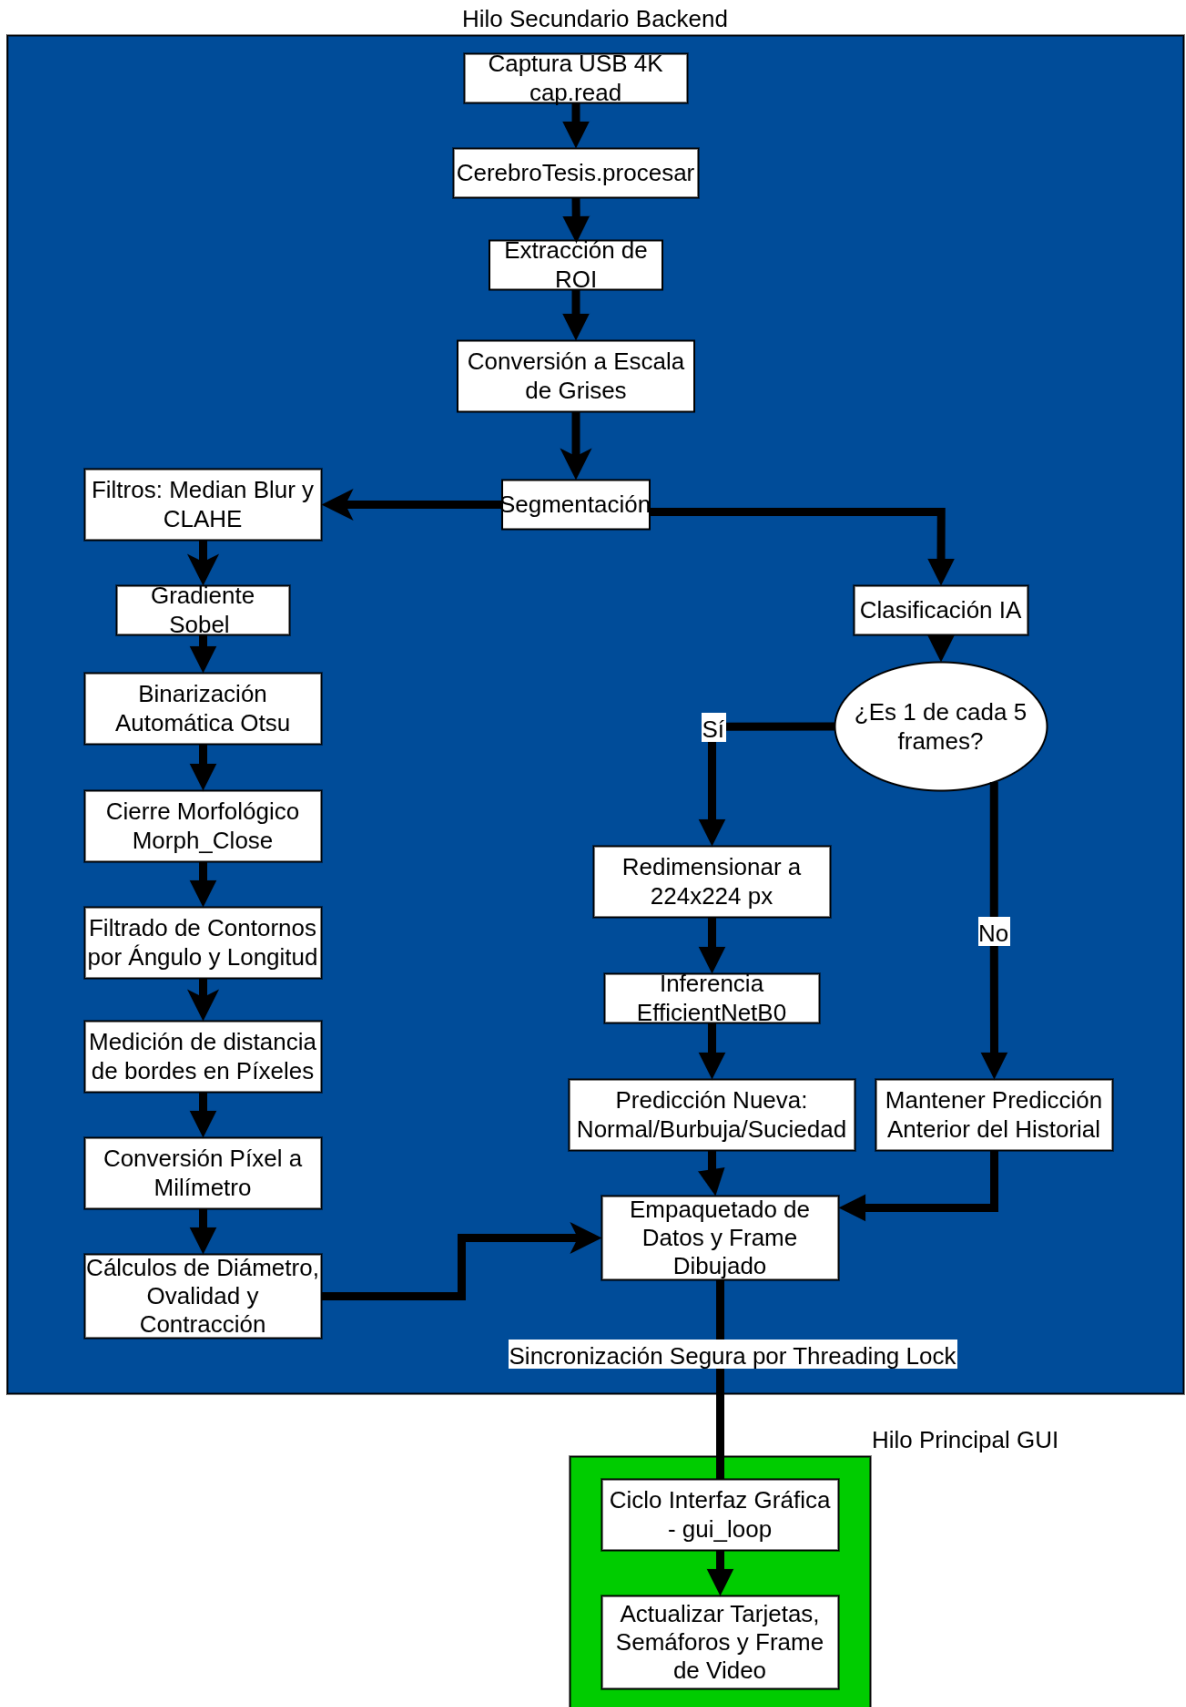
El desafío computacional más significativo en sistemas de visión artificial en tiempo real es evitar el bloqueo de la interfaz gráfica durante el procesamiento pesado de imágenes. Para resolver esto, la arquitectura del software se diseñó bajo un paradigma de concurrencia mediante hilos de procesamiento (multithreading). Un hilo principal se encarga exclusivamente de renderizar la interfaz y actualizar los indicadores visuales (como los semáforos de calidad), mientras que un hilo secundario en segundo plano (el backend o motor de procesamiento) gestiona la captura de video de la cámara 4K, el preprocesamiento con la biblioteca OpenCV y la inferencia del modelo de aprendizaje profundo.

Para detallar el flujo de procesamiento de imágenes ejecutado por el hilo secundario, el algoritmo sigue una secuencia estricta de seis pasos fundamentales por cada fotograma capturado:

1. **Adquisición y partición espacial:** Se recibe el fotograma crudo en resolución 4K y se recorta inmediatamente en tres Regiones de Interés (ROI) estáticas. Esto aísla las refle-

xiones de los tres espejos y descarta la información irrelevante del fondo, reduciendo drásticamente la carga computacional.

2. **Conversión y mejora de contraste:** Cada ROI se convierte a escala de grises. A continuación, se aplica el algoritmo CLAHE (Ecuación Adaptativa de Histograma Limitada por Contraste) para homogeneizar la iluminación local y mitigar los reflejos especulares severos generados por el plástico fundido.
3. **Filtrado de ruido:** Se implementa un filtro de mediana (*Median Blur*) no lineal. Este paso elimina el ruido impulsional del sensor sin comprometer ni difuminar la nitidez de los bordes del material.
4. **Extracción de contornos (Metrología):** Sobre la imagen filtrada y mejorada, se aplica el operador direccional de Sobel combinado con la binarización adaptativa de Otsu. Esto genera un mapa de bordes binario nítido, a partir del cual se calcula la distancia euclidiana transversal (diámetro en píxeles).
5. **Clasificación de anomalías (IA):** De forma concurrente, cada cinco fotogramas, las ROIs preprocesadas se redimensionan al formato de entrada requerido por la red convolucional (224×224 píxeles) y se envían al modelo EfficientNetB0 para su inferencia categórica (Normal, Burbujas o Contaminación).
6. **Fusión de datos y retroalimentación:** Los resultados dimensionales (geometría) y categóricos (defectos internos) se empaquetan en un arreglo de datos y se envían al hilo principal para actualizar en tiempo real los indicadores semafóricos y gráficos de la Interfaz Hombre-Máquina (HMI).



38
Figura 6: Diagrama de funcionamiento interno del sistema.

Adicionalmente, se implementó un "Panel de Ingeniería" dinámico que permite la configuración del sistema sin necesidad de interrumpir el flujo de extrusión o reiniciar el software. A través de este panel, el usuario puede calibrar la constante óptica en milímetros por píxel (mm/px), ajustar las tolerancias geométricas de advertencia y error crítico, modificar los parámetros de filtrado y alternar entre distintos modos de visualización (vista normal, vista superpuesta o vista del mapa de bordes). Esta arquitectura modular y concurrente garantiza un rendimiento fluido, manteniendo la latencia al mínimo y maximizando la eficiencia de la inspección.

3.5. Entrenamiento y validación del modelo de clasificación

El núcleo de la toma de decisiones para la categorización de los defectos recae en la aplicación de redes neuronales convolucionales. Sin embargo, para que el sistema pudiera realizar inferencias precisas y en tiempo real dentro de las limitaciones del hardware, fue necesario someterlo a un riguroso proceso de experimentación, entrenamiento y validación supervisada.

La primera etapa consistió en la generación de un conjunto de datos propio. Utilizando el prototipo físico bajo las condiciones finales de iluminación y calibración óptica, se capturaron 249 fotogramas de filamentos: 83 en estado normal, 83 con burbujas y 83 con contaminantes. Mediante el procesamiento de las Regiones de Interés (ROI) en cada fotograma, se aislaron los recortes individuales correspondientes a las tres vistas de los espejos, obteniendo un total de 747 imágenes crudas. Posteriormente, estas imágenes fueron etiquetadas manualmente y divididas en las tres clases operativas del sistema.

Para garantizar la representatividad del conjunto de datos y someter a la red neuronal a escenarios realistas, fue necesario inducir de manera controlada las imperfecciones en las muestras de filamento utilizadas en el experimento.

El material seleccionado para estas pruebas fue un filamento de policarbonato (PC) transparente. La elección de este polímero se fundamentó no solo en su disponibilidad en el laboratorio como material de purga, sino también en sus propiedades ópticas de alta transmitancia y estabilidad geométrica. Cabe destacar que el lote utilizado contaba con un tiempo de almacenamiento prolongado (dos años) bajo condiciones ambientales no controladas, lo que propició la absorción natural de humedad.

- **Inducción de burbujas:** Las microcavidades internas se generaron aprovechando la humedad ambiental previamente absorbida por la matriz del policarbonato. Se aplicó un choque térmico localizado mediante la llama directa de un soplete, lo que provocó la vaporización súbita y ebullición de la humedad atrapada. Inmediatamente después, el material se sometió a un enfriamiento rápido para solidificar el polímero y conservar la geometría de las microburbujas resultantes. Finalmente, se realizó una limpieza superficial mecánica con un paño para eliminar cualquier residuo de hollín.
- **Inducción de contaminantes:** Con el objetivo de proteger la integridad mecánica del sistema de extrusión real, se optó por simular un escenario de contaminación superficial severa. Para ello, se aplicó calor focalizado a la muestra de filamento hasta alcanzar su punto de reblandecimiento y, posteriormente, se le incrustaron limaduras de hierro procedentes de los residuos de mecanizado del taller universitario. Esta técnica aseguró la adhesión térmica de las partículas sin comprometer el equipo.

En la Figura 7 se observa la disposición del equipo y la óptica durante la fase de captura de datos en el laboratorio. Asimismo, en la Figura 8 se presenta la evidencia macrofotográfica de las muestras físicas utilizadas para construir el conjunto de datos, evidenciando las diferencias morfológicas entre las tres clases.



Figura 7: Montaje experimental para la adquisición del conjunto de datos. Se aprecia la calibración del sistema de iluminación indirecta y el arreglo catóptrico durante el paso del filamento. (Autoría propia)




Figura 8: Muestras físicas utilizadas para el entrenamiento del modelo: A) Filamento con burbujas internas inducidas por humedad, B) Filamento con impurezas incrustadas en la matriz plástica, C) Filamento en estado normal. (Autoría propia)

Para evaluar el desempeño de la inteligencia artificial con información completamente nueva, el conjunto total de 747 imágenes se dividió estratégicamente. Se separaron 150 ROIs (correspondientes a las vistas de 50 fotogramas) para dejarlos intactos y exclusivos para la fase de validación. Los 597 ROIs restantes (extraídos de los otros 199 fotogramas) se destinaron al entrenamiento.

Para evitar el sobreajuste y garantizar la robustez del modelo ante pequeñas variaciones ambientales, a este conjunto de entrenamiento se le aplicaron técnicas de aumento de datos (data augmentation), tales como rotaciones aleatorias, inversiones espaciales y ajustes ligeros de brillo. Este proceso permitió multiplicar la variabilidad de las muestras, expandiendo el conjunto de entrenamiento de 597 ROIs a un total de 6000 imágenes procesadas, sin necesidad de capturas físicas adicionales. En la Figura 9 se muestra el diagrama de todo el proceso de obtención de ROIs y aumento de datos.

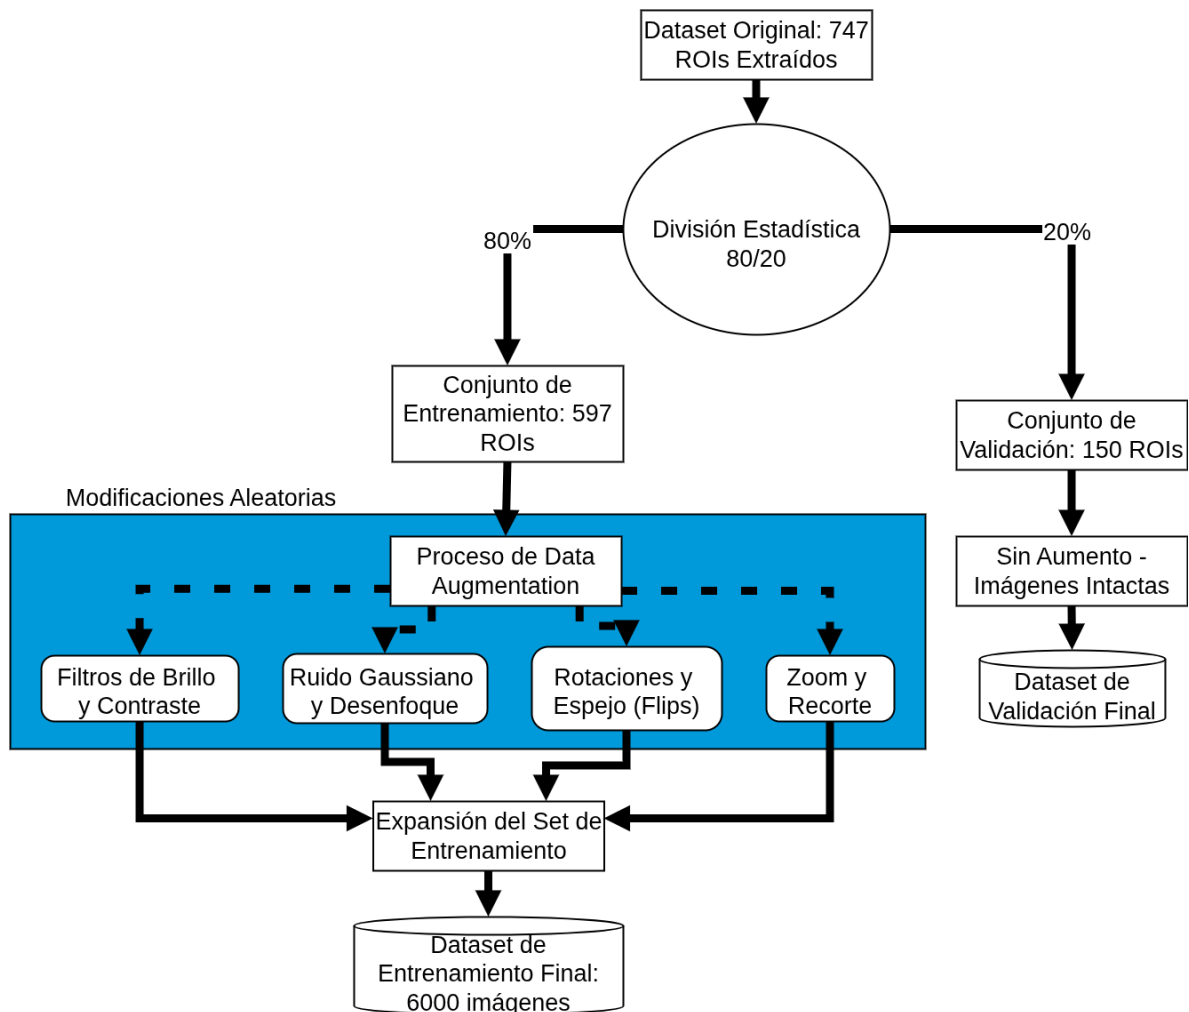


Figura 9: Proceso de obtención de ROIs y aumento de datos

El proceso de entrenamiento se configuró mediante la biblioteca TensorFlow/Keras utilizando la función de pérdida de entropía cruzada categórica, ideal para la clasificación multiclase. Con el objetivo de seleccionar la arquitectura más eficiente, se diseñó un experimento comparativo evaluando tres modelos de estado del arte: ResNet, MobileNet y EfficientNet. Adicionalmente, para cada arquitectura se realizaron pruebas variando el tamaño del lote (batch size) en configuraciones de 4, 8, 16 y 32 imágenes, buscando el equilibrio óptimo que maximizara la precisión y minimizara la pérdida.

Cada configuración fue entrenada durante un máximo de 100 épocas, monitoreando continuamente las métricas de precisión (accuracy) y pérdida (loss) en el conjunto de datos. Finalmente, los pesos sinápticos de cada modelo fueron exportados y empaquetados en un archivo

compilado.

Para la selección final del modelo óptimo, se comparó la precisión y la pérdida de cada una de las arquitecturas. Adicionalmente, se aplicó una prueba de estrés utilizando un conjunto de datos de validación sometido a un aumento de datos mucho más agresivo e inusual. Esta prueba permitió evaluar la capacidad de generalización y adaptación de cada red ante escenarios ruidosos, eligiendo finalmente el modelo que demostró el mejor desempeño global en ambos procesos. En la Figura 10 se puede ver el proceso completo del entrenamiento y la selección del mejor modelo.

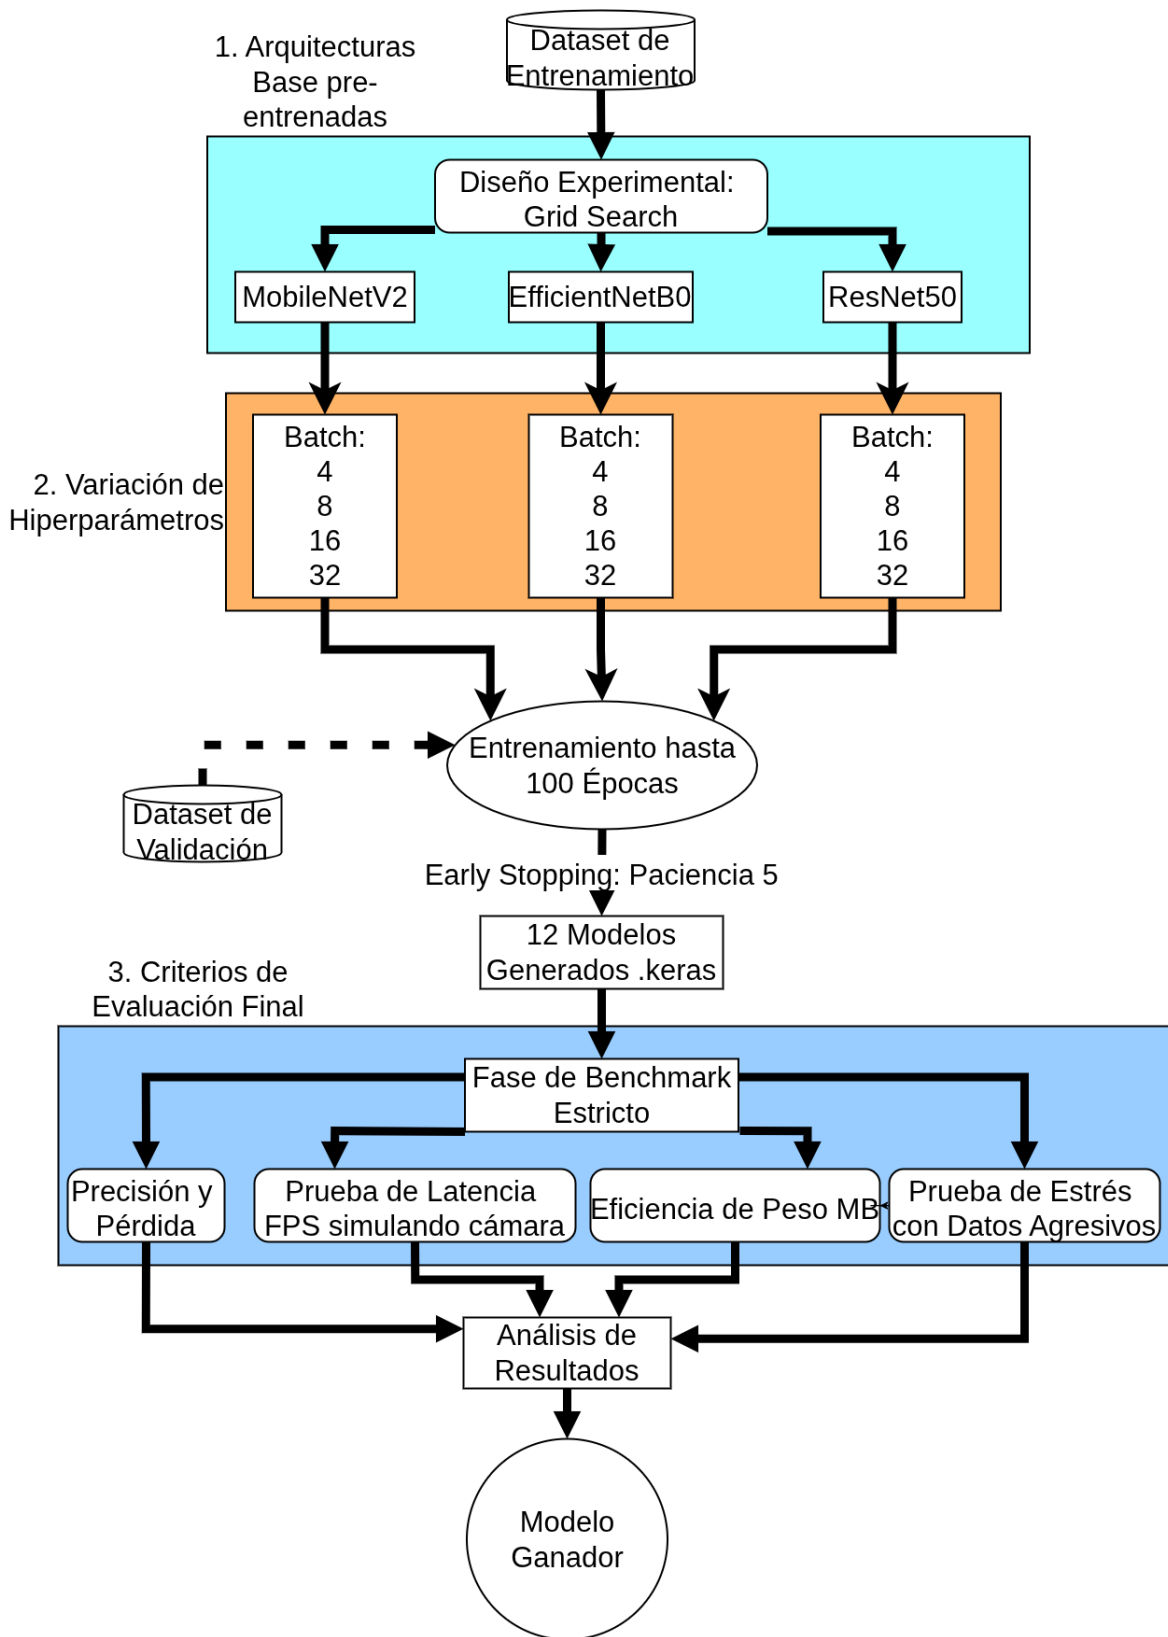


Figura 10: Proceso de entrenamiento y selección del mejor modelo

3.6. Construcción e integración del prototipo físico

La materialización del diseño conceptual se completó de manera satisfactoria. A diferencia de los sistemas industriales completamente cerrados, el prototipo se ensambló deliberadamente con una arquitectura abierta (sin carcasa exterior). Esta decisión de diseño tuvo como objetivo someter a prueba la robustez de los algoritmos de binarización adaptativa frente a la contaminación lumínica y los cambios de iluminación del entorno. Adicionalmente, se empleó adhesivo termofusible de manera abundante, cumpliendo una doble función: actuar como material difusor para suavizar la incidencia de los LEDs y proporcionar un encapsulado elástico que dota a la estructura de resistencia mecánica ante vibraciones o impactos accidentales.

En la Figura 11 se presenta una vista frontal del ensamblaje, equivalente a la distribución esquemática mostrada previamente en el capítulo de Metodología. En esta perspectiva se aprecia la configuración geométrica de los espejos y el canal de paso del filamento. Asimismo, la comparativa entre el equipo apagado (A) y encendido (B) evidencia la alta intensidad de la iluminación indirecta implementada.



Figura 11: Vista frontal del prototipo de inspección. A) Sistema inactivo. B) Sistema de iluminación LED encendido. (Autoría propia)

Por otro lado, la Figura 12 muestra el perfil lateral del equipo, revelando la ubicación del sensor 4K, las conexiones de datos USB y de alimentación, así como los soportes estructurales. Como se puede observar, los brazos impresos en PETG que sostienen la óptica presentan geometrías intencionadamente esbeltas. Esta característica reduce el peso total del conjunto, minimiza la inercia en caso de vibraciones y facilita ajustes mecánicos posteriores o procesos de termomoldeo localizado para calibración fina.




Figura 12: Vista lateral del prototipo mostrando la distribución de la cámara, óptica, iluminación y cableado estructural. (Autoría propia)

Finalmente, el método de fijación seleccionado (cianoacrilato con acelerante de polimerización rápida a base de bicarbonato) resultó ser un acierto crítico durante la fase de desarrollo. Esta técnica permitió congelar instantáneamente la posición de los espejos una vez que se encontró el ángulo óptimo de refracción, evitando la necesidad de imprimir iterativamente múltiples versiones del chasis y reduciendo significativamente los tiempos de ensamblaje y calibración óptica.

3.6.1. Análisis de costos y viabilidad

Para evaluar la competitividad del sistema frente a soluciones comerciales basadas en láser (que pueden superar los \$1,500 USD), se presenta un resumen de los costos de los componentes principales en la Tabla 2.

Tabla 2: Desglose de costos del hardware del prototipo.

Componente	Cantidad	Costo Est. (MXN)
Sensor Sony IMX317 4K	1	\$1,350.00
Espejos de primera superficie	2	\$0.00 (Reciclado)
Estructura PETG (Impresión 3D)	100g	\$50.00
Arreglo LED y electrónica	1	\$85.00
Tornillería y adhesivos	1	\$50.00
Total		\$1,535.00

3.6.2. Criterios de selección de hardware

La selección de los componentes principales del prototipo obedeció a criterios técnicos específicos para satisfacer los requerimientos de la norma ISO 5425:2023:

- **Sensor Sony IMX317:** Se eligió por su resolución nativa 4K. Al dividir el campo visual en tres vistas mediante espejos, una resolución menor (como 1080p) no habría proporcionado suficientes píxeles por cada ROI para alcanzar la resolución espacial de 0.0058 mm/px necesaria para detectar micro-burbujas.
- **Material Estructural (PETG):** Se seleccionó PETG sobre PLA para la fabricación del chasis debido a su mayor resistencia térmica y estabilidad mecánica a largo plazo en entornos de laboratorio, asegurando que el arreglo óptico mantenga su alineación a pesar de las vibraciones de la línea de extrusión.
- **Espejos de primera superficie:** A diferencia de los espejos convencionales, estos reflejan la luz directamente desde la superficie frontal, eliminando el efecto fantasma.^o doble reflexión que introduciría errores de medición en los algoritmos de detección de bordes.
- **Arquitectura en CPU (Intel i7):** Se optó por optimizar el software para ejecución en CPU para demostrar la eficiencia del modelo EfficientNetB0, permitiendo que el sistema sea replicable en estaciones de trabajo industriales estándar sin necesidad de hardware de procesamiento gráfico (GPU) especializado.

Capítulo 4

Resultados y discusión

En el presente capítulo se exponen y analizan los hallazgos derivados de la implementación del sistema propuesto. Los resultados se estructuran en cuatro áreas fundamentales: la validación de su precisión metrológica dimensional, el rendimiento de inferencia del modelo de aprendizaje profundo, y el desempeño global de la Interfaz Hombre-Máquina (HMI) operando en tiempo real.

4.1. Validación de exactitud metrológica y análisis estadístico

Como se describió en la metodología, el proceso de calibración inicial se realizó mediante un patrón físico de acero pulido y recubierto en blanco mate. Para determinar el diámetro real de este patrón con trazabilidad mecánica, se utilizó un micrómetro digital con una exactitud de 0.001 mm. Los resultados de este procedimiento de caracterización se presentan en la Tabla 3.

Tabla 3: Mediciones obtenidas con micrómetro para determinar el diámetro real del patrón de calibración.

N°	Medición (mm)	N°	Medición (mm)
1	2.050	6	2.036
2	2.041	7	2.035
3	2.035	8	2.053
4	2.049	9	2.040
5	2.034	10	2.036
Promedio poblacional			2.0409

Nota: El promedio de las diez mediciones independientes se estableció como el valor de referencia absoluto para el cálculo de la constante óptica de conversión.

A partir de este valor promedio de 2.0409 mm, el algoritmo de visión artificial calculó las constantes de conversión dimensional para cada una de las tres perspectivas del arreglo catóptrico. Los resultados de esta relación de milímetros por píxel se resumen en la Tabla 4. Los valores obtenidos indican que un solo píxel en el sensor equivale a un máximo de ≈ 0.0058 mm. Esta resolución espacial confirma que el sistema excede los requerimientos de la norma ISO 5425:2023, permitiendo la detección de defectos con dimensiones inferiores a 0.01 mm.

Tabla 4: Valores de la constante óptica de conversión (mm/px) por espejo.

Espejo (Vista)	Relación (mm/px)
1	0.00574
2	0.00419
3	0.00587

Una vez calibradas las constantes, se procedió a validar la exactitud y repetibilidad del equipo en un escenario de inspección real. Para ello, se realizó un análisis estadístico comparativo contrastando las lecturas del instrumento óptico contra mediciones mecánicas manuales. En este experimento se evaluaron tres tipos de especímenes con distintas propiedades ópticas y diámetros: un filamento polimérico y dos patrones de alambre metálico calibrado. El registro de las mediciones recolectadas se detalla en la Tabla 5.

Tabla 5: Registro comparativo de mediciones para evaluación de dispersión y exactitud.

Muestra	Filamento		Alambre Grueso		Alambre Delgado	
	Visión Art.	Micrómetro	Visión Art.	Micrómetro	Visión Art.	Micrómetro
1	1.807	1.834	1.987	1.993	0.789	0.940
2	1.796	1.833	1.993	1.990	0.799	0.905
3	1.801	1.832	1.984	1.987	0.807	0.932
4	1.794	1.834	1.980	1.988	0.625	0.936
5	1.796	1.826	1.977	1.986	0.807	0.903

Nota: Valores expresados en milímetros (mm). La primera columna de cada categoría presenta el cálculo del sistema de visión, mientras que la segunda muestra la medición mecánica de referencia.

A partir de las diferencias absolutas registradas en la Tabla 5, se realizó un análisis de exactitud segmentado por rango operativo. Se determinó que el sistema presenta su máximo desempeño en especímenes con diámetros cercanos al valor nominal de diseño para impresión 3D (1.75 mm). Para el rango operativo comprendido entre 1.75 mm y 2.0 mm (filamento y alambre grueso), el sistema obtuvo un error promedio de exactitud de 0.0194 mm.

Es importante notar que en especímenes fuera del rango de diseño, como el alambre delgado (≈ 0.9 mm), el error promedio ascendió a 0.157 mm debido a los límites de resolución espacial y enfoque de la óptica catóptrica a dicha escala. No obstante, al centrar el análisis en el propósito de la investigación, el error de 0.0194 mm valida la capacidad del equipo, ya que es significativamente menor a la tolerancia de ± 0.03 mm estipulada por la norma ISO 5425:2023 para filamentos de grado premium. Asimismo, las variaciones observadas en las muestras poliméricas evidencian la capacidad del sensor para captar la morfología real y la ovalidad del material sin la compresión mecánica que introduce el micrómetro manual. De este modo, se confirma la utilidad del prototipo como un instrumento de metrología no invasivo con capacidad de certificación industrial. En la Figura 13 se presentan las capturas utilizadas para el contraste de estas mediciones.




Figura 13: A) Medición de diámetro de filamento usando micrómetro. B) Captura de parámetros dimensionales en tiempo real mediante la interfaz del sistema.

4.2. Evaluación y selección del modelo de Inteligencia Artificial

Tras definir la viabilidad metrológica del prototipo, la siguiente etapa consistió en validar el "motor de decisión" del sistema: el modelo de aprendizaje profundo encargado de clasificar los defectos de la superficie del filamento. Como se detalló en la metodología, se realizó un experimento comparativo (Grid Search) entrenando tres arquitecturas de estado del arte (MobileNetV2, ResNet50 y EfficientNetB0) bajo diferentes configuraciones de tamaño de lote (4, 8, 16 y 32), generando un total de 12 modelos candidatos.

4.2.1. Fase de Validación Estándar

Durante la primera fase de evaluación, se analizó el comportamiento de los modelos frente al conjunto de validación original (imágenes no sometidas a aumento de datos). Los resultados demostraron que la arquitectura EfficientNetB0 fue superior en la extracción de características. Específicamente, la configuración con un tamaño de lote de 4 (Batch 4) alcanzó la métrica más alta del experimento con un 98.00% de precisión (Accuracy) y la menor tasa de error (Loss) con un valor de 0.0708, en la Figura 14 se puede ver el desempeño que tuvo en su entrenamiento.




Figura 14: Curvas de aprendizaje (Precisión y Pérdida) del modelo EfficientNetB0 con tamaño de lote 4. (Autoría propia)

En comparación, las mejores configuraciones de ResNet50 (Batch 4 y 8) se estancaron en un 97.33 % de precisión con pérdidas superiores a 0.100. La superioridad de EfficientNet se atribuye a su método de escalado compuesto, el cual optimiza el procesamiento de texturas sutiles, como los bordes de refracción que generan las micro-burbujas en el interior del filamento plástico. En la Figura 15 se puede ver la comparación de los demás modelos frente a EfficientNet lote 4.

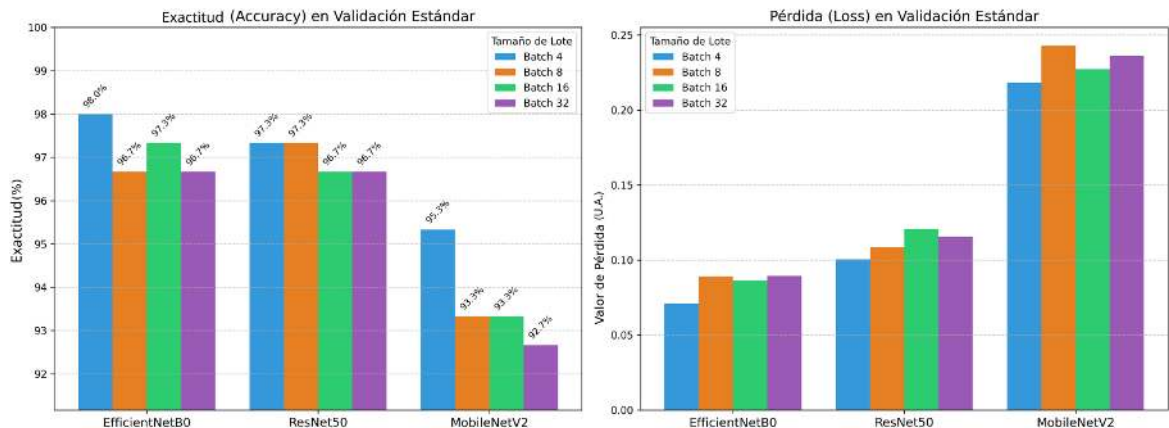


Figura 15: Comparativa de Precisión y Pérdida en la fase de validación estándar para las tres arquitecturas evaluadas con diferentes tamaños de lote. (Autoría propia)

4.2.2. Fase de Benchmark: Latencia y Prueba de Estrés

Para garantizar que el sistema pudiera operar en un entorno industrial real (donde existen vibraciones, reflejos anómalos o polvo), los modelos preseleccionados fueron sometidos a

una segunda fase de evaluación o "prueba de estrés". Esta prueba evaluó su rendimiento utilizando un conjunto de datos con "aumento agresivo", simulando condiciones extremas de ruido gaussiano, desenfoque y alteraciones bruscas de contraste.

Adicionalmente, dado que el sistema integrado está diseñado para ejecutarse íntegramente en una Unidad de Procesamiento Central (CPU) sin aceleración por tarjeta gráfica dedicada, la latencia de inferencia y el consumo de memoria RAM se establecieron como criterios críticos. En la Figura 16 se presenta el análisis comparativo de estas métricas.




Figura 16: Resultados del benchmark masivo de modelos bajo la prueba de estrés con aumento de datos agresivo. Se compara precisión, latencia y peso. (Autoría propia)

El análisis de la prueba de estrés reafirmó la robustez del modelo EfficientNetB0 con Batch 4, el cual no solo mantuvo su desempeño, sino que demostró una excelente capacidad de generalización al alcanzar un 99.33 % de precisión frente a las imágenes distorsionadas.

Más allá de la precisión, la eficiencia computacional fue el factor decisivo. El modelo basado en ResNet50 demostró ser excesivamente pesado para un entorno de ejecución en CPU, con un tamaño de archivo de 90.67 MB y una latencia promedio de ≈ 96.4 ms (10.3 FPS). Por el contrario, EfficientNetB0 registró un peso sumamente ligero de apenas 16.29 MB, logrando tiempos de inferencia de ≈ 77.6 ms por fotograma (12.8 FPS).

Con base en estos resultados —máxima precisión en validación, resistencia superior al ruido y la latencia más baja del experimento— el modelo EfficientNetB0_Batch4 fue seleccionado como el motor de clasificación definitivo para su integración en la Interfaz Hombre-Máquina.

Para cuantificar el impacto de la técnica de aumento de datos (*Data Augmentation*), se evaluó el desempeño del sistema antes y después de su aplicación. El modelo base, entrenado exclusivamente con las 597 imágenes originales (sin transformaciones), alcanzó una precisión de validación máxima de aproximadamente 97.33 % y presentó signos de sobreajuste (*overfitting*) temprano de 0.0903. Al aplicar las transformaciones espaciales y lumínicas (expandiendo el conjunto a 6000 imágenes), el modelo EfficientNetB0 (Batch 4) experimentó una mejora sustancial: incrementó su precisión absoluta al 99.33 % bajo condiciones de estrés y redujo su pérdida (Loss) a 0.0708. Esto demuestra cuantitativamente que el aumento de datos mejoró el rendimiento general del sistema en un 2.0 %, siendo una etapa relevante para garantizar la robustez del algoritmo ante variaciones industriales reales.

Es importante aclarar que, para la clasificación de defectos internos y superficiales, el sistema no emplea un umbral porcentual estático (como un área o volumen mínimo de impurezas o burbujas). En su lugar, el modelo de aprendizaje profundo (EfficientNetB0) opera de manera cualitativa sobre las regiones de interés (ROI): detecta la presencia o ausencia de estas anomalías basándose en la extracción de características complejas (como variaciones abruptas de contraste, refracción de luz en microcavidades y patrones morfológicos irregulares) aprendidas durante su entrenamiento. Por lo tanto, el sistema es capaz de alertar sobre la presencia de un defecto independientemente de la proporción del área total que este ocupe dentro de la vista del filamento.

4.3. Desempeño de la Interfaz Hombre-Máquina (HMI)

La Interfaz Hombre-Máquina (HMI) actúa como el nexo fundamental entre los sistemas de adquisición óptica, el procesamiento neuronal y el operario. Gracias a ella, los datos crudos y las inferencias matemáticas se traducen en indicadores visuales de fácil interpretación. Para un análisis detallado, el desempeño de la interfaz se dividirá en tres apartados: la ventana principal de operación, el panel dinámico de ingeniería y la demostración de detección de fallos en tiempo real.

4.3.1. Ventana principal de monitoreo

La ventana principal constituye la primera vista operativa del programa y centraliza todos los parámetros requeridos para la operación estándar del equipo. Su diseño fue concebido bajo el principio de usabilidad intuitiva, permitiendo una supervisión continua del proceso de extrusión sin requerir manipulación manual bajo condiciones normales.

Como se ilustra en la Figura 17, la interfaz se ha segmentado en cuatro áreas funcionales clave. En la Zona A se despliega la renderización en tiempo real del video capturado por el sensor 4K. Sobre esta transmisión se superponen elementos gráficos de diagnóstico: las líneas azules delimitan las Regiones de Interés (ROI) donde se ejecuta el reconocimiento espacial, mientras que las barras verdes representan el diámetro físico detectado. Adicionalmente, el sistema permite proyectar el mapa de bordes generado por el algoritmo de binarización (líneas amarillas), lo que permite al operador visualizar exactamente qué contornos está reconociendo la máquina.

En la Zona B se ubica el panel de metrología en vivo. Este sector reporta el diámetro promedio (calculado a partir de una media móvil de las últimas 10 mediciones para suavizar el ruido), la ovalidad geométrica, el porcentaje de contracción térmica y el diámetro instantáneo exacto del fotograma actual. Estos valores numéricos cambian de color dinámicamente si los parámetros exceden las tolerancias permitidas.

La Zona C alberga los indicadores semafóricos correspondientes a las inferencias de la red neuronal convolucional. Para evitar ambigüedades, las alertas utilizan un código dual (color y texto). La severidad se clasifica según el impacto físico que el defecto tendría en el hot-

end de una impresora 3D: color verde para un filamento en estado normal, color amarillo como advertencia ante la presencia de micro-burbujas, y color rojo como alerta crítica por contaminación con impurezas.

Por último, en la Zona D se ubican los controles de acceso al Panel de Ingeniería, el cual permite la calibración profunda del sistema y será abordado en la siguiente sección.



Figura 17: Distribución funcional de la ventana principal. A) Renderizado de video en tiempo real. B) Panel de metrología. C) Semáforos de inferencia de IA. D) Acceso a configuración. (Autoría propia)

4.3.2. Panel dinámico de ingeniería

El panel de ingeniería está compuesto por seis pestañas modulares (Figuras 18, 19 y 20). Con excepción de la pestaña de Sistema, todos los parámetros y valores pueden ser modificados dinámicamente en tiempo de ejecución (en caliente). Los ajustes realizados se serializan y almacenan de forma automática en un archivo de configuración en formato JSON. Esta arquitectura de software permite exportar e importar perfiles de configuración y realizar ajustes profundos en el comportamiento de la máquina sin necesidad de alterar o recompilar el código fuente.

La primera pestaña, Visual, está diseñada para gestionar la retroalimentación gráfica del algoritmo de visión. Permite al operario alternar entre visualizar únicamente los bordes segmentados o superponer el mapa de bordes sobre el flujo de video en tiempo real. Adicionalmente, se puede personalizar el grosor y color de las líneas de contorno, o habilitar una ventana secundaria de diagnóstico que muestre exclusivamente los resultados de la binarización mientras la interfaz principal mantiene el video original.

La pestaña Óptica representa uno de los logros técnicos más significativos del sistema: la calibración métrica automatizada. Al colocar un patrón de calibración cilíndrico rectilíneo en la zona de enfoque e ingresar su diámetro conocido, el algoritmo recalcula instantáneamente la constante óptica de conversión (mm/px) y la guarda en la configuración. Esta flexibilidad elimina la dependencia de un patrón calibrado único y costoso, permitiendo reajustar el sistema utilizando cualquier herramienta cilíndrica de precisión disponible en el laboratorio o la industria.

El módulo de Geometría facilita la reubicación digital de las Regiones de Interés (ROI) y de las guías de medición durante la operación. Esta función resulta crítica para compensar desajustes mecánicos o daños ópticos imprevistos sin necesidad de detener la producción. A modo de ejemplo, durante las validaciones experimentales de este proyecto, esta característica permitió desplazar las ventanas de lectura para evadir exitosamente un rasguño superficial ocasionado de manera accidental en uno de los espejos, manteniendo intacta la capacidad operativa y precisión del equipo.

La pestaña de Filtros controla el preprocesamiento de imágenes, permitiendo activar o desactivar filtros de ruido y ajustar los parámetros matemáticos utilizados para la detección de contornos. Esta parametrización directa otorga al sistema la versatilidad necesaria para adaptarse rápidamente a filamentos con diferentes propiedades reflectivas (como transparentes, mate o metálicos) sin requerir modificaciones en el código base.

En el apartado de Tolerancias se establecen los umbrales geométricos de calidad del producto. El sistema permite configurar tolerancias suaves o de advertencia (que activan el color amarillo en los indicadores de la HMI) y tolerancias duras o críticas (que activan el color rojo). Este módulo está diseñado para alinear la inspección con los parámetros estrictos estipulados por la norma ISO 5425:2023, o bien, para adaptarse a tolerancias personalizadas según los requerimientos de un proceso de impresión específico.

Por último, la pestaña Sistema administra las variables de infraestructura que requieren que el equipo detenga su captura para aplicarse. Aquí se configura el identificador (ID) del puerto USB asignado a la cámara, lo que facilita una rápida reconexión en caso de desconfiguración del hardware. Además, permite actualizar la ruta de acceso al modelo de red neuronal convolucional compilado, facilitando la actualización de la inteligencia artificial si se entrenan modelos más precisos en el futuro o para alguna tarea específica.

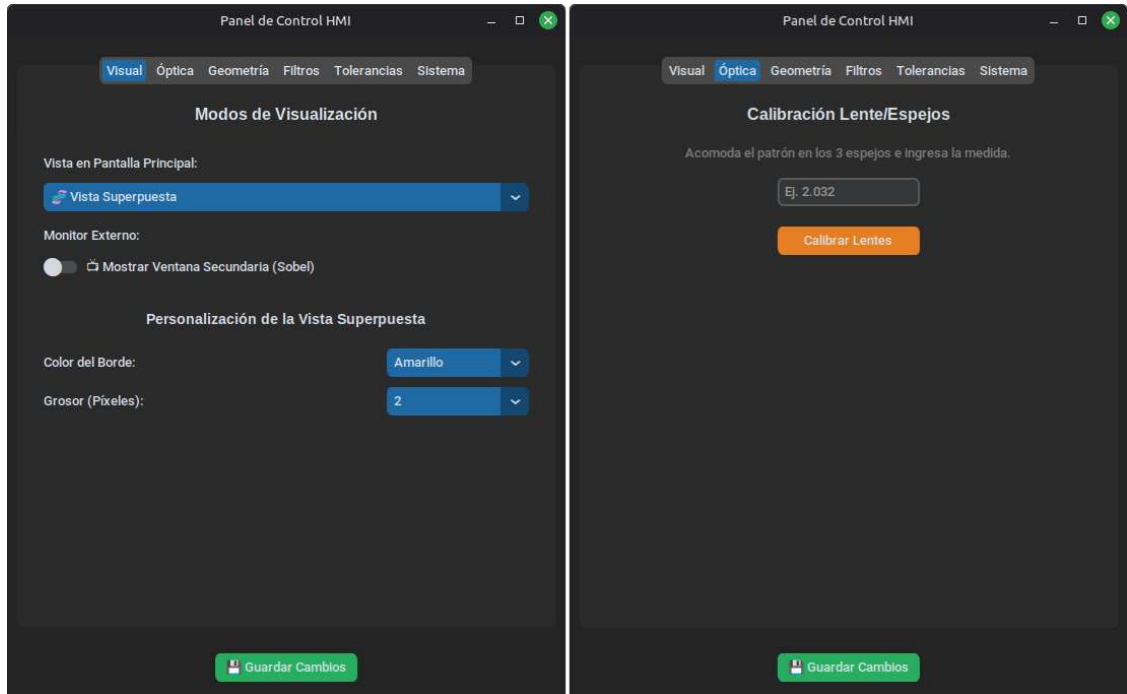


Figura 18: Vista detallada de panel de ingeniería: Módulos de Visualización y Óptica.

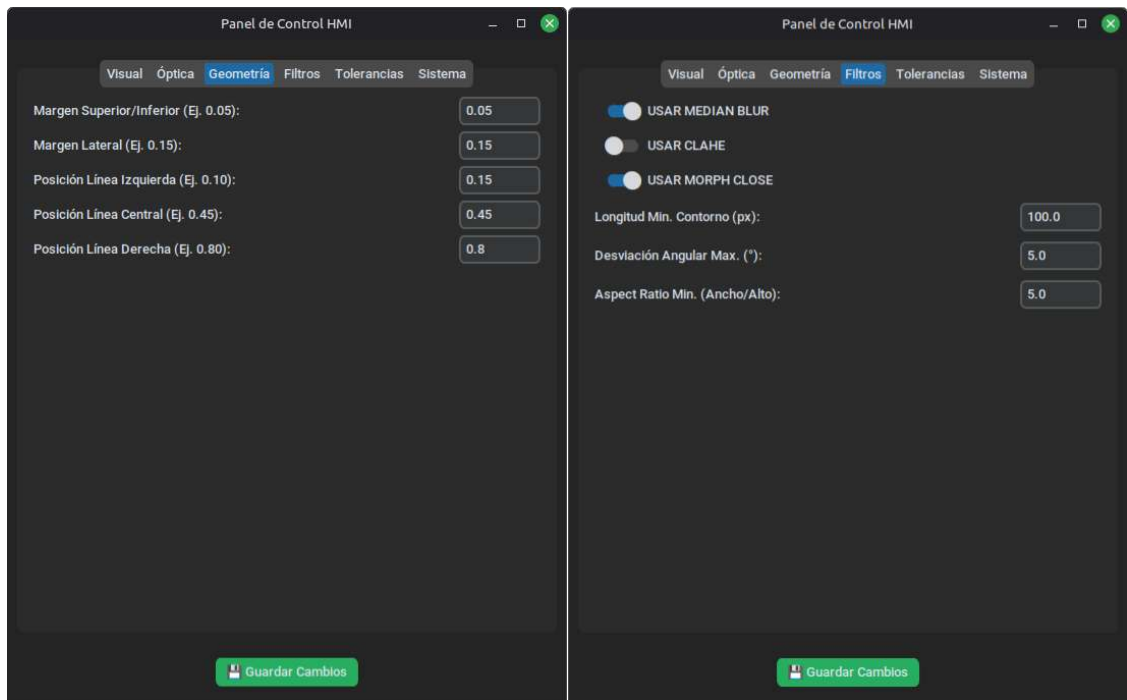


Figura 19: Vista detallada de panel de ingeniería: Configuración de Geometría y Filtros.

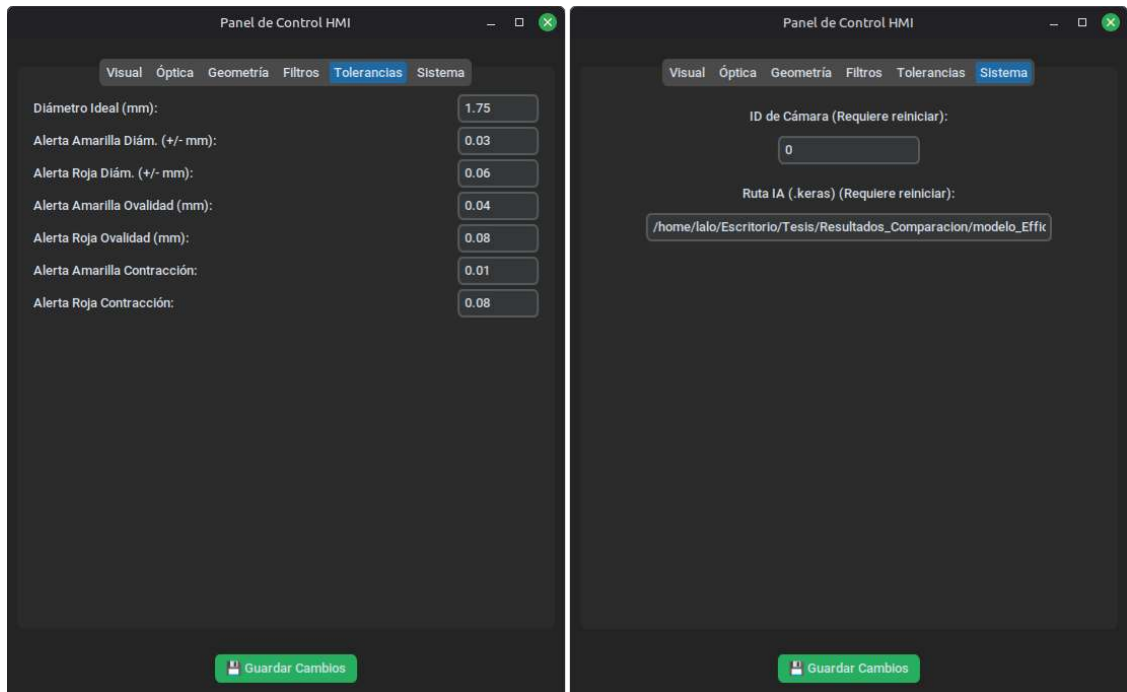


Figura 20: Vista detallada de panel de ingeniería: Ajustes de Tolerancias y Sistema (Ruta IA).

4.3.3. Demostración de detección de anomalías en tiempo real

Para concluir con la validación del sistema integrado, se realizaron pruebas de funcionamiento continuo sometiendo al prototipo a muestras de filamento con distintos tipos de defectos físicos. La Figura 21 presenta una composición de tres escenarios operativos distintos (A) estado normal, B) presencia de burbujas y C) contaminación), demostrando la capacidad de la Interfaz Hombre-Máquina para reportar simultáneamente las mediciones dimensionales y la clasificación de la red neuronal.

En el primer escenario (A) estado normal), el clasificador de inteligencia artificial determina que el material no presenta burbujas ni contaminación. En el panel de metrología de esta misma captura, el diámetro promedio se muestra en color verde al encontrarse dentro de la tolerancia permitida. Sin embargo, el sistema resalta la ovalidad en color rojo (indicando una deformación geométrica crítica) y la contracción térmica en color amarillo (advertencia). Este comportamiento subraya una de las mayores ventajas del equipo propuesto: la capacidad de desacoplar los defectos visuales de los defectos dimensionales, alertando al operario que, aunque el plástico está libre de impurezas, su geometría transversal no cumple con la norma.

En el segundo escenario (B) presencia de burbujas), el modelo convolucional detecta correctamente las microcavidades generadas por humedad durante el proceso de extrusión, activando la alerta correspondiente en la zona del clasificador. Simultáneamente, el panel de metrología refleja un diámetro y una ovalidad fuera de los rangos aceptables (color rojo), acompañados de una advertencia de contracción (color amarillo). Esta lectura es físicamente congruente con la expansión irregular y la pérdida de volumen lineal que sufre el plástico cuando el agua atrapada en su interior se evapora de manera abrupta al salir de la boquilla.

Finalmente, en el tercer escenario (C) contaminación), el sistema identifica exitosamente la presencia de impurezas incrustadas en la matriz del polímero. Al igual que en el caso anterior, los indicadores dimensionales reportan valores críticos en rojo para el diámetro y la ovalidad, evidenciando que la presencia de partículas extrañas altera significativamente la uniformidad del material extruido.

Estos resultados confirman que la arquitectura concurrente del software opera de manera exitosa. El procesamiento matemático de los contornos para la metrología y la inferencia del modelo de aprendizaje profundo se ejecutan en paralelo y sin bloqueos en la interfaz gráfica, brindando un diagnóstico integral, preciso y en tiempo real sobre la viabilidad del filamento

evaluado para su uso en impresión 3D.




Figura 21: Composición de la interfaz evaluando tres escenarios de calidad del filamento: A) estado normal, B) presencia de burbujas y C) contaminación. (Autoría propia)

4.4. Estrategias de control y acciones correctivas

La detección de anomalías en tiempo real mediante el sistema de visión permite una intervención inmediata en los parámetros del proceso de manufactura. En la Tabla 6 se resumen las acciones recomendadas según el tipo de defecto clasificado por la red neuronal Efficient-NetB0.

Tabla 6: Acciones correctivas sugeridas según el defecto detectado.

Defecto Detectado	Causa Raíz Probable	Acción Correctiva Sugerida
Burbujas internas	Exceso de humedad en la materia prima (pellets).	Aumentar la temperatura y el tiempo del sistema de secado; verificar sellado de tolva (Baechle-Clayton y cols., 2022).
Variación de diámetro ($> \pm 0.05$ mm)	Desincronización entre husillo y puller.	Ajustar el lazo PID de velocidad del puller; verificar consistencia térmica en el dado.
Ovalidad excesiva	Enfriamiento asimétrico en la tina.	Ajustar flujo de agua o temperatura del baño; verificar alineación mecánica de los rodillos.
Impurezas / Puntos negros	Degradación térmica o contaminación del material.	Realizar purga del sistema; disminuir temperatura de procesamiento si hay degradación.

Capítulo 5

Conclusiones

A partir de los resultados obtenidos y analizados en esta investigación, se presentan las siguientes conclusiones fundamentales que confirman el cumplimiento de los objetivos y la validación de la hipótesis planteada.

En relación con la hipótesis de este trabajo, se demostró que el sistema es capaz de alcanzar una exactitud superior a 0.01 mm, superando significativamente el umbral de exactitud propuesto inicialmente. Este nivel de resolución, obtenido mediante la calibración del arreglo óptico y el procesamiento digital de imágenes, garantiza la detección de irregularidades dimensionales y la identificación de anomalías internas con dimensiones menores a lo estipulado originalmente, validando así la capacidad diagnóstica del equipo.

El desarrollo e implementación de este sistema de inspección visual demostró la viabilidad técnica de sustituir equipos metrológicos de alto costo por una arquitectura basada en visión artificial y aprendizaje profundo, sin sacrificar la precisión ni la velocidad de respuesta en un entorno de laboratorio. Respecto a los objetivos específicos de diseño, se confirmó que el uso de un arreglo de espejos de primera superficie es una técnica altamente efectiva para la reconstrucción dimensional de objetos cilíndricos extruidos. Al medir el material desde múltiples ángulos de forma simultánea, el sistema logró calcular la ovalidad real del filamento plástico con mayor fidelidad que un micrómetro tradicional, el cual tiende a deformar la muestra por contacto mecánico. Además, se comprobó que el sistema cumple con la resolución necesaria para validar los parámetros de la norma ISO 5425:2023.

La evaluación exhaustiva de los modelos de inteligencia artificial arrojó evidencia concluyente sobre la superioridad de la arquitectura EfficientNetB0 para esta aplicación específica. Al enfrentar la red a un conjunto de datos con aumento agresivo, el modelo demostró una

excelente capacidad de generalización para distinguir entre burbujas internas e impurezas superficiales, alcanzando una precisión del 99.33 %. Asimismo, su bajo peso computacional permitió que la inferencia en tiempo real se ejecutara de manera fluida en un procesador estándar, eliminando la dependencia tecnológica de hardware de aceleración gráfica.

La arquitectura de software desarrollada para la interfaz hombre-máquina validó la importancia del procesamiento concurrente mediante hilos. La capacidad de ajustar los parámetros de metrología, los umbrales de binarización y la constante óptica en tiempo de ejecución dota al sistema de una versatilidad industrial excepcional, permitiendo su adaptación inmediata a diversos materiales y condiciones de iluminación. En conjunto, estos elementos consolidan una solución de inspección integral, precisa y eficiente para la industria de la manufactura aditiva.

Finalmente, debido a la originalidad y desempeño de la HMI se considera que el presente desarrollo posee las características necesarias para su registro como Modelo de Utilidad ante el Instituto Mexicano de la Propiedad Industrial (IMPI), así como el registro de los algoritmos ante el Instituto Nacional del Derecho de Autor (Indautor).

5.1. Trabajo Futuro

A pesar de los resultados satisfactorios obtenidos en este proyecto, la naturaleza escalable de la arquitectura propuesta abre diversas vías para la mejora y expansión del sistema en futuras investigaciones.

Se propone, como principal ruta de desarrollo, la integración del procesamiento de software con una etapa de control de hardware externo. Esta mejora consistiría en enviar señales digitales de alerta desde la interfaz en Python hacia un microcontrolador inalámbrico dedicado, como un módulo de la familia ESP32 o ESP8266. De esta forma, al detectar un segmento de filamento con defectos críticos o un diámetro fuera de tolerancia, el microcontrolador podría accionar un mecanismo físico automatizado para cortar y desechar el tramo defectuoso antes de que sea enrollado en la bobina final.

Adicionalmente, se sugiere expandir el conjunto de datos de entrenamiento para incluir filamentos con propiedades ópticas más complejas, como polímeros translúcidos, filamentos

con partículas de fibra de carbono o materiales termo-sensibles. Entrenar el modelo de aprendizaje profundo bajo estas nuevas condiciones permitiría robustecer aún más el clasificador neuronal y acercar el prototipo a un nivel de estandarización comercial.

Finalmente, como ruta crítica para la consolidación industrial del sistema, se plantea la realización de pruebas de validación dinámica con material en movimiento. Aunque el prototipo demostró una latencia de inferencia inferior a 80 milisegundos operando en CPU, es necesario evaluar el comportamiento del sensor y la óptica operando directamente sobre una línea de extrusión a velocidades estándar. Esta fase prospectiva permitirá medir y compensar posibles fenómenos ópticos como el desenfoque por movimiento (*motion blur*), así como validar la sincronización de la interfaz HMI con el flujo continuo del plástico fundido.

Referencias

- 3devo. (2020). *Filament thickness deviation (inconsistent diameter)*. Descargado de <https://support.3devo.com/filament-thickness-deviation-inconsistent-diameter>
- Aniulis, J., Dudzik, G., y Abramski, K. M. (2024). Automated non-destructive 3d printing filament material properties monitoring based on electric permittivity, longitudinal encoding and diameter multi-axes real-time measurements. *Additive Manufacturing*, 84, 104103. doi: 10.1016/J.ADDMA.2024.104103
- Bae, G., Yoon, S., y Cho, J. (2025). Edge-aware illumination enhancement for fine-grained defect detection on railway surfaces. *Mathematics*, 13(23), 3780. doi: 10.3390/math13233780
- Baechle-Clayton, M., Loos, E., Taheri, M., y Taheri, H. (2022). Failures and flaws in fused deposition modeling (fdm) additively manufactured polymers and composites. *Journal of Composites Science*, 6(7), 202. doi: 10.3390/JCS6070202
- Bradski, G., y Kaehler, A. (2008). *Learning opencv: Computer vision with the opencv library*. Descargado de <https://books.google.com.mx/books?id=seAgiOfu2EIC>
- Caraiman, S., Morar, A., Owczarek, M., Burlacu, A., Rzeszotarski, D., Botezatu, N., y Moldoveanu, A. (2017). Computer vision for the visually impaired: The sound of vision system. En *Proceedings* (pp. 1480–1489). Descargado de <http://www.p.lodz.pl>
- Cardona, C., Curdes, A. H., y Isaacs, A. J. (2016). Effects of filament diameter tolerances in fused filament fabrication. *IU Journal of Undergraduate Research*, 2(1), 44–47. doi: 10.14434/IUJUR.V2I1.20917
- Chiang, C. C., Yang, Y. Y., Liu, W. L., y Lin, Y. C. (2023). Improving automatic identification of medications in transparent packaging by glare removal and color correction.

- IEEE Access*, 11, 118812–118829. doi: 10.1109/ACCESS.2023.3327421
- Czimmermann, T., Ciuti, G., Milazzo, M., Chiurazzi, M., Roccella, S., Oddo, C. M., y Dario, P. (2020). Visual-based defect detection and classification approaches for industrial applications—a survey. *Sensors*, 20(5), 1459. doi: 10.3390/S20051459
- Duan, Z., Wang, N., Zhao, W., y Zhao, W. (2016). Calibration method based on lattice calibration plate in vision measurement system. *Acta Optica Sinica*, 36(5), 0515004. doi: 10.3788/AOS201636.0515004
- Duque-Domingo, J., Gómez-García-Bermejo, J., y Zalama-Casanova, E. (2024). *Visión artificial. componentes de los sistemas de visión y nuevas tendencias en deep learning* (1.ª ed., Vol. 1).
- Gasca, A. F. (2022). *Diseño de patrones combinados de relleno en impresión 3d para la fabricación de elementos automotrices* (Tesis de Master, Universidad Autónoma de Querétaro). Descargado de <https://ri-ng.uaq.mx/handle/123456789/3826>
- Gonzalez, R. C., y Woods, R. E. (2018). *Digital image processing* (4.ª ed.). Pearson.
- Gómez-Allende, D. M. (1994). *Reconocimiento de formas y visión artificial* (1.ª ed.). Addison-Wesley Iberoamericana.
- Han, O. C., y Kutbay, U. (2025). Detection of defects on metal surfaces based on deep learning. *Applied Sciences*, 15(3), 1406. doi: 10.3390/app15031406
- Hernández Rodríguez, J. D., y Valle Medina, J. (2018). *Implementación de una máquina semi automática extrusora de filamento de plástico para impresoras 3d* (Tesis).
- Herrarte López, I., Steven, J., y Villamil, M. (2024). *Prototipo de una máquina extrusora de filamento para impresión 3d a partir del reciclado de botellas pet* (Tesis).
- Hossain, M. S., Shahriar, G. M., Syeed, M. M. M., Uddin, M. F., Hasan, M., Shivam, S., y Advani, S. (2023). Region of interest (roi) selection using vision transformer for automatic analysis using whole slide images. *Scientific Reports*, 13(1), 1–14. doi: 10.1038/s41598-023-38109-6
- Iftekar, S. F., Aabid, A., Amir, A., y Baig, M. (2023). Advancements and limitations in 3d printing materials and technologies: A critical review. *Polymers*, 15(11), 2519. doi: 10.3390/POLYM15112519
- International Organization for Standardization. (2023). *Additive manufacturing — feedstock materials — polylactic acid (PLA) filaments — specifications*. ISO 5425:2023. Descargado de <https://www.iso.org/standard/81238.html> (Norma internacional)
- Klipper. (s.f.). *Features – klipper documentation*. Descargado de <https://www>

- .klipper3d.org/Features.html (Recuperado el 7 de marzo de 2025)
- Kranthi Kumar, K., Chaduvula, K., y Rao Markapudi, B. (2020). A detailed survey on feature extraction techniques in image processing for medical image analysis. *European Journal of Molecular & Clinical Medicine*, 7, 1480–1489.
- Martín, D., Sales, M., y Manager, S. (2013). *A practical guide to machine vision lighting*.
- Ng, T. Y., Koay, S. C., Chan, M. Y., Choo, H. L., y Ong, T. K. (2020). Preparation and characterisation of 3d printer filament from post-used styrofoam. En *Aip conference proceedings* (Vol. 2233). doi: 10.1063/5.0001340/611089
- Osswald, T. A., y Hernández-Ortiz, J. P. (2017). *Polymer processing: Modeling and simulation*. Hanser Publications.
- Petsiuk, A., y Pearce, J. M. (2021). Open source filament diameter sensor for recycling, winding, and additive manufacturing machines. *Journal of Manufacturing Science and Engineering, Transactions of the ASME*, 143(10), 101616. doi: 10.1115/1.4050762
- Prusa Research. (2020). *Velocidad volumétrica máxima — prusa knowledge base*. Descargado de https://help.prusa3d.com/es/article/velocidad-volumetrica-maxima_127176
- Reséndiz Carranza, R. U. (2025). *Análisis y diseño de resortes torsionales de nylon 6, impresos en 3d, para captar energía cinética de una bicicleta* (Tesis de Master, Universidad Autónoma de Querétaro). Descargado de <https://ri-ng.uaq.mx/handle/123456789/11372>
- Revilla Días, R. (2006). *Factores del proceso que influyen sobre la contracción, dimensiones y alabeo en piezas moldeadas por inyección* (Inf. Téc.). CIQA. Descargado de <https://ciqa.repositorioinstitucional.mx/jspui/handle/1025/472>
- Sony Corporation. (2018). *IMX317CQC: Diagonal 7.20 mm (type 1/2.5) cmos image sensor with square pixel for color cameras* (Data Sheet). Sony Semiconductor Solutions Corporation. (Rev. 1.0)
- Su, A., y Al’Aref, S. J. (2018). History of 3d printing. En *3d printing applications in cardiovascular medicine* (pp. 1–10). doi: 10.1016/B978-0-12-803917-5.00001-8
- Sudeep, K. S., y Pal, K. K. (2017). Preprocessing for image classification by convolutional neural networks. En *2016 IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology (rteict)* (pp. 1778–1781). doi: 10.1109/RTEICT.2016.7808140
- Tan, M., y Le, Q. (2019, 09–15 Jun). EfficientNet: Rethinking model scaling for convolutional neural networks. En K. Chaudhuri y R. Salakhutdinov (Eds.), *Proceedings of the*

- 36th international conference on machine learning* (Vol. 97, pp. 6105–6114). PMLR.
Descargado de <https://proceedings.mlr.press/v97/tan19a.html>
- Tang, B., Chen, L., Sun, W., y Lin, Z. K. (2023). Review of surface defect detection of steel products based on machine vision. *IET Image Processing*, 17(2), 303–322. doi: 10.1049/IPR2.12647
- Valerga, A. P., Batista, M., Salguero, J., y Girot, F. (2018). Influence of pla filament conditions on characteristics of fdm parts. *Materials*, 11(8), 1322. doi: 10.3390/MA11081322
- Vlachopoulos, J., y Polychronopoulos, N. D. (2019). *Understanding rheology and technology of polymer extrusion*. Dundas, ON, Canada: Polydynamics Inc.
- Zhong, W., y Dong, X. (2015). Camera calibration method of binocular stereo vision based on opencv. En *Proceedings of spie* (Vol. 9675, pp. 571–576). doi: 10.1117/12.2202186