

MAESTRIA EN TECNOLOGÍAS DE LA INFORMACIÓN



**TECNOLÓGICO
DE ESTUDIOS SUPERIORES
DE CUAUTITLÁN IZCALLI**

**T
E
S
C
I**

**“ANÁLISIS DE DESPLAZAMIENTOS EN MANUFACTURA ADITIVA POR MEDIO
DE CORRELACIÓN DIGITAL DE IMÁGENES USO DE REDES NEURONALES EN
PYTHON”**

TESIS

**QUE PARA OBTENER EL GRADO DE:
MAESTRO EN TECNOLOGÍAS DE LA INFORMACIÓN
PRESENTA:**

LUIS ANTONIO SÁNCHEZ REYNOSO

DIRECTOR(A) DE TESIS:

DR. OMAR BARRAGAN PEREZ

AUTORIZACIÓN

AGRADECIMIENTOS

Quiero agradecer al Tecnológico de Estudios Superiores de Cuautitlán Izcalli, la oportunidad y el apoyo, para poder llevar a cabo los estudios de Maestría en Tecnologías de la Información.

Al Dr. Omar Barragán Pérez, por su guía y apoyo para poder terminar de buena manera esta Etapa,

A los Maestros que tuve durante el estudio de la Maestría que contribuyeron en el desarrollo académico.

DEDICATORIA

A:

Mi esposa Lety que siempre ha estado en las buenas, las malas y las peores y nunca me ha dejado caer y siempre me ha brindado su apoyo incondicional.

A mi cuñada Karen que en los momentos difíciles ha estado para apoyarnos

A mi familia en general por el simple hecho de estar y compartir

ÍNDICE

INTRODUCCIÓN	1
CAPÍTULO 1. MARCO CONTEXTUAL	3
1.1 Descripción del tecnológico	4
1.2 Visión	4
1.3 Misión.....	5
1.4 Objetivo General	5
1.5 Justificación	5
CAPÍTULO 2.	7
MARCO TEÓRICO	7
2.1 Definición de Manufactura aditiva	8
2.2 Principios básicos de la Manufactura aditiva	8
2.2.1 Fabricación capa por capa	9
2.2.2 Uso de un modelo digital tridimensional	9
2.2.3 Conversión a formato interpretable por la impresora (Slicing)	9
2.3.1 Orígenes en la década de 1980.....	11
2.3.2 Década de 1990: expansión de tecnologías.....	11
2.3.3 Años 2000: democratización y acceso abierto.....	11
2.3.4 Década de 2010: adopción industrial y profesionalización.....	12
2.3.5 Presente y futuro: Manufactura Aditiva 2.0	12
2.4 Tipos de tecnologías en la Manufactura aditiva.....	12
2.4.1 Extrusión de material (Material Extrusión).....	13
2.4.2 Fotopolimerización en tanque (Vat Photopolymerization)	13
2.5 Pruebas de Creep a Termoplasticos	16
2.6 Desplazamiento en procesos de manufactura aditiva.....	20
2.6.1 Tipos de desplazamiento.	22
2.6.2 Consecuencias del desplazamiento en la calidad del producto final	24

2.6.3	Métodos tradicionales para detectar desplazamientos	25
2.8	Procesamiento y comparación de imágenes	29
2.8.1	Fundamentos de la visión por computadora	29
2.8.2	Técnicas básicas de procesamiento de imágenes	29
2.8.3	Técnicas para la comparación de imágenes	32
2.8.4	Diferencia de imágenes.....	32
2.8.5	Correlación de patrones	33
2.8.6	Detección de contornos deformados	34
2.9	Análisis estructural: SSIM y MSE.....	35
2.10	Python.....	36
2.10.1	Breve historia del lenguaje	36
2.10.2	Beneficios en el uso de Python	37
2.10.3	Librerías para la comparación de imágenes en Python	37
2.11	Redes Neuronales	39
2.12	Predicción con el modelo Burgers para polímeros	40
2.13	Estado del Arte	41
2.13.1	Real-time Detection of Displacement Defects in FDM Printing Using Image Processing 41	
2.13.2	py2DIC: Medición de desplazamientos y deformaciones en imagen	43
2.13.3	Correlación de Imágenes Digitales y Redes Neuronales: El Proyecto Deep DIC	44
2.13.4	Análisis Comparativo de Desplazamientos mediante Correlación de Imágenes Digitales y Elementos Finitos	47
2.13.5	Aplicación de la Correlación Digital de Imágenes en Problemas de Contacto	48
CAPÍTULO 3.....		50
MARCO METODOLÓGICO		50
3.1	Metodología CRISP-DM	51
3.1.1	Fases de la metodología CRISP-DM	51

3.2	Metodología SCRUM.....	53
CAPÍTULO 4.....		58
APLICACIÓN DE LA METODOLOGÍA Y DISCUSIÓN DE RESULTADOS.....		58
4.1	Probeta de análisis	59
4.2	Análisis de las imágenes capturadas en la prueba de tensión.....	61
4.3	Predicción de las deformaciones por medio de una red neuronal	66
CAPÍTULO 5.....		72
CONCLUSIONES Y PERSPECTIVAS PARA TRABAJOS FUTUROS		72
5.1	Conclusiones.....	73
5.2	Perspectivas para trabajos futuros	74
REFERENCIAS.....		75

INDICE DE FIGURAS

Figura 1. Croquis del Tecnológico (Google maps, 2025).	4
Figura 2. Máquina de creep en tensión	18
Figura 3. Funcionamiento del proyecto Real-time Detection of Displacement Defects in FDM Printing Using Image Processing	43
Figura 4. Imágenes resultantes del proyecto py2DIC	44
Figura 5. Funcionamiento de Deep DIC	46
Figura 6. Fases de la metodología CRISP-DM	53
Figura 7 Estructura de la metodología Scrum	55
Figura 8. Probeta realizada en impresora 3D con PET G mezclado con oxido de aluminio	59
Figura 9, Equipo de Creep en Tensión	60
Figura 10, Tensión en la probeta	60
Figura 11. Pantalla principal del programa.....	61
Figura 12. Selección de la carpeta con las imágenes capturadas	61
Figura 13. Primera imagen capturada.....	62
Figura 14, Mensaje de alerta que indica la ruta de la carpeta de salida.....	62
Figura 15, Establecimiento del ROI	63
Figura 16. Mensaje que indica que el ROI se establecio.....	63
Figura 17, Trazado de línea para establecer la escala.	64
Figura 18, Establecimiento y conversión de la escala	65
Figura 19. Procesamiento de las imágenes	65
Figura 20. Archivos como resultado del análisis.	66
Figura 21 Contenido del archivo deformaciones.csv	67
Figura 22, Interfaz de la aplicación que predice los desplazamientos	68
Figura 23. Selección del archivo deformaciones.csv.....	68
Figura 24, Carga de los datos a la aplicación	69
Figura 25. Entrenamiento del modelo	70
Figura 26, Asignación del tiempo para predicción.....	70
Figura 27. Mensaje de datos cargados al nuevo archivo	70
Figura 28, Grafica con los datos predecidos	71

INDICE DE TABLAS

Tabla 1. Comparación de las diversas tecnologías que se utilizan en la manufactura aditiva 16

Tabla 2. Comparación de los algoritmos que permiten la detección de contornos..... 35

Tabla 3. Combinacion de las metodologías CRISP-DM y Scrum 56

LISTA DE ABREVIATURAS Y TABLA DE SÍMBOLOS

3D.	Tercera Dimension
ASTM	American Society for Testing and Materials
CAD.	Computer-Aided Design
CCAI	Centro de Cooperación Academia Industria
CNN	Red Neuronal Convulcional
CWI	Centrum Wiskunde & Informatica
DED	Directed Energy Deposition
DIC.	Digital Image Correlation
FDM	Fused Deposition Modeling
HDPE	Polietileno de alta densidad
HIPS	Poliestireno de alto impacto
IoT	Internet de las cosas
ISO	International Organization for Standardization
LOM	Laminated Object Manufacturing
MA	Manufactura Aditiva
MEF	Método de Elementos Finitos
MLP	Multicapa
MSE	Error Cuadratico Medio
PBF	Powder Bed Fusion
PC	Policarbonato
PE	Polietileno
PETG	Tereftalato de Polietileno Glico
PP	Polipropileno
PS	Poliestireno
RepRap	Replicating Rapid Prototyper
RGB	Red, Green, Blue
RNN	Red Neuronal Recurrente
SLS	Selective Laser Sintering
SSIM	Índice de Similitud Estructural
TESCI	Tecnológico de Estudios Superiores de Cuautitlán Izcalli
UV	Ultravioleta

RESUMEN

En este trabajo se desarrolló la solución por medio del lenguaje de programación Python para poder hacer el estudio por medio del método de Correlación Digital de Imágenes (DIC por sus siglas en ingles) para el análisis de desplazamientos y deformaciones en que sufren los materiales al someterlos a tensión, para obtener la medición de creep, que en este caso la pieza de caso de estudio fue una probeta creada por impresión 3D con una mezcla de PETG (Polietileno Tereftalato Glicol) y oxido de aluminio

El propósito es desarrollar una aplicación en lenguaje Python que permita realizar la predicción de desplazamientos y deformaciones de un material bajo prueba, sin necesidad de terminar en su totalidad el procesamiento de imágenes con Correlación Digital de Imágenes, esto de una prueba a tensión.

Dentro de este trabajo quedo demostrado que el uso de la técnica DIC (Correlación Digital de Imágenes) y con el apoyo de una red neuronal integrada a una aplicación desarrollada en Python se puede hacer un estudio de piezas creadas en una impresora 3D con PETG .

La metodología ocupada fue una mezcla de las metodologías CRISP-DM por sus siglas en ingles Cross Industry Standard Process for Data Mining (Proceso Estándar de la Industria Cruzada para la Minería de Datos), que se enfoca en la problemática a estudiar y SCRUM por sus siglas en ingles marco de trabajo ágil (Agile framework) orientada al desarrollo de la aplicación en lenguaje Python.

Palabras clave.

Correlación Digital de Imágenes, Manufactura Aditiva, Red Neuronal, Desplazamientos, Deformaciones

ABSTRACT

In this work, the solution was developed using the Python programming language to conduct the study via the Digital Image Correlation (DIC) method for the analysis of displacements and deformations that materials undergo when subjected to tension, in order to obtain the creep measurement. In this case, the specimen under study was a 3D-printed test piece made from a mixture of PETG (Polyethylene Terephthalate Glycol) and aluminum oxide.

The purpose is to develop a Python application that enables the prediction of displacements and deformations of a material under test without the need to fully complete the image processing with Digital Image Correlation, specifically for a tensile test.

This work demonstrated that the use of the DIC (Digital Image Correlation) technique, supported by a neural network integrated into a Python application, can be used to study parts created on a 3D printer with PETG.

The methodology used was a blend of the CRISP-DM (Cross-Industry Standard Process for Data Mining) methodology, which focuses on the problem to be studied, and the SCRUM (Agile framework) methodology, oriented towards the development of the Python application.

Keywords:

Digital Image Correlation, Additive Manufacturing, Neural Network, Displacements, Deformations

INTRODUCCIÓN

La manufactura aditiva, comúnmente conocida como impresión 3D, ha revolucionado el campo de la fabricación al permitir la producción de piezas complejas con una mínima intervención humana y sin la necesidad de moldes o herramientas específicas. Esta tecnología se ha consolidado como una alternativa eficaz a los métodos tradicionales de manufactura, especialmente en industrias como la aeroespacial, automotriz, biomédica y de diseño industrial, debido a su capacidad para generar geometrías complejas, personalización de productos y reducción de desperdicio de material [1]

A pesar de sus numerosas ventajas, la manufactura aditiva enfrenta varios retos técnicos que pueden comprometer la calidad dimensional y estructural de los componentes fabricados. Uno de estos retos es el desplazamiento o deformación de las capas durante el proceso de impresión, lo que puede deberse a múltiples factores, tales como variaciones térmicas, errores de calibración, inconsistencias en la alimentación del material o vibraciones de la máquina [2]. Estos desplazamientos, aunque en muchos casos imperceptibles a simple vista, pueden provocar defectos estructurales significativos que comprometen la funcionalidad o integridad del producto final.

En este contexto, la detección y análisis de desplazamientos en tiempo real o posterior al proceso de impresión se vuelve una herramienta crítica para garantizar la calidad del producto. Tradicionalmente, se han empleado técnicas como sensores físicos, escaneo 3D y pruebas destructivas para evaluar estos defectos. Sin embargo, el uso de visión por computadora y técnicas de comparación de imágenes emerge como una solución no invasiva, económica y altamente adaptable para la detección automatizada de deformaciones en piezas manufacturadas aditivamente [3].

El análisis basado en imágenes permite capturar información visual en diferentes etapas del proceso de impresión, y compararla con modelos CAD (Diseño Asistido por Computadora) o capas anteriores. Este enfoque permite identificar desplazamientos, desplazamientos

acumulativos y desviaciones geométricas mediante algoritmos de procesamiento digital de imágenes. Métodos como la correlación de imágenes digitales (Digital Image Correlation, DIC), la comparación de histogramas, transformaciones geométricas y la detección de bordes han demostrado ser eficaces para el análisis de deformaciones en materiales y estructuras [4]. Integrar estas técnicas en procesos de manufactura aditiva puede facilitar la implementación de sistemas inteligentes de monitoreo y control de calidad.

CAPÍTULO 1.

MARCO CONTEXTUAL

1.1 Descripción del tecnológico

- Empresa: Tecnológico de Estudios Superiores de Cuautitlán Izcalli
- Dirección: Fracción la Coyotera del Ejido, Av. Nopaltepec, Av. San Antonio s/n, Industrial Cuamatla, 54748 Cuautitlán Izcalli, Méx.
- Teléfono: 55 5864 3170
- Dirección de correo electrónico: posgrados@tesci.edu.mx
- Giro: Educativo e Investigación




Figura 1. Croquis del Tecnológico (Google maps, 2025).

1.2 Visión

Ser reconocida como una de las mejores instituciones de educación superior tecnológica socialmente responsable, con programas educativos acreditados y procesos certificados bajo estándares de calidad, que garanticen el posicionamiento de nuestros(as) egresados(as) en el ámbito laboral globalizado.

1.3 Misión

Formar integralmente profesionales, maestros(as) e investigadores(as) competitivos a nivel nacional e internacional, poseedores de un sentido crítico y analítico, con visión humanista y conciencia ética, impulsores del desarrollo económico, científico, tecnológico y cultural, con sentido innovador, que contribuyan al crecimiento de la región, del Estado y del país, de manera socialmente responsable dentro de un marco de excelencia personal.

1.4 Objetivo General

Obtener la predicción de desplazamientos y deformaciones con redes neuronales utilizando python para la medición de desplazamientos para PETG (Tereftalato de Polietileno Glico) mezclado con oxido de aluminio utilizando Correlación digital de Imágenes.

Objetivos Específicos:

- Desarrollo de aplicación en Phyton utilizando Correlación Digital de Imágenes.
- Uso de inteligencia artificial para el análisis de desplazamientos
- Evaluación del material PETG mezclado con oxido de aluminio utilizando la aplicación en Phyton.
- Prueba de creep de corta duración a la muestra de PETG y PETG con oxido de aluminio.

1.5 Justificación

La presente investigación se justifica por la creciente necesidad de mejorar los procesos de inspección automatizada en entornos de manufactura digital, donde la precisión y la repetibilidad son fundamentales. A diferencia de métodos tradicionales, el enfoque basado en imágenes no interfiere con el proceso de fabricación y permite un monitoreo continuo sin contacto físico, lo que lo hace ideal para aplicaciones industriales.

Metodológicamente, este estudio se estructura en varias etapas:

- La captura de imágenes de piezas fabricadas mediante impresión 3D bajo condiciones controladas,
- El diseño e implementación de algoritmos de comparación basados en diferencias de píxeles, alineamiento de imágenes, análisis de bordes y correlación cruzada en python
- La validación de resultados mediante comparación con pruebas experimentales.

Este trabajo contribuye al avance del campo de la manufactura inteligente al proponer un sistema adaptable para el análisis de calidad mediante visión artificial, que puede integrarse fácilmente a líneas de producción de impresión 3D. Además, ofrece una base metodológica sólida que puede extenderse al análisis de otros defectos, como grietas, errores de extrusión o irregularidades de superficie.

En resumen, la presente tesis aborda una problemática actual en el ámbito de la manufactura aditiva y propone una solución innovadora mediante el uso de tecnologías de procesamiento de imágenes. Este enfoque no solo mejora la detección de defectos, sino que también contribuye al desarrollo de sistemas de manufactura más eficientes, precisos y automatizados, en línea con los principios de la Industria 4.0.

CAPÍTULO 2.

MARCO TEÓRICO

2.1 Definición de Manufactura aditiva

La manufactura aditiva (MA), comúnmente conocida como impresión 3D, es un conjunto de tecnologías de fabricación que crean objetos tridimensionales mediante la adición de material capa por capa, a partir de un modelo digital. A diferencia de los procesos sustractivos tradicionales, donde el material es removido para obtener una forma deseada, la manufactura aditiva construye directamente la geometría final sin necesidad de moldes o herramientas específicas [1].

Este enfoque de fabricación ofrece alta flexibilidad de diseño, permite la personalización masiva, y reduce significativamente el desperdicio de material. Estas características la hacen ideal para prototipado rápido, producción en bajo volumen y aplicaciones médicas o aeroespaciales [7]. Según la norma ISO/ASTM 52900:2021, la manufactura aditiva se define como:

“Un proceso de unión de materiales para construir objetos desde datos de modelos 3D, generalmente capa por capa, en contraste con los métodos sustractivos de fabricación” [6].

En la actualidad, la MA comprende múltiples tecnologías como Fused Deposition Modeling (FDM), Stereolithography (SLA), y Selective Laser Sintering (SLS), cada una con características específicas en cuanto a materiales, resolución y velocidad. Su desarrollo ha tenido un impacto significativo en la transformación digital de la manufactura, al permitir ciclos de desarrollo más ágiles, productos más complejos y modelos de producción más sostenibles [8].

2.2 Principios básicos de la Manufactura aditiva

La impresión 3D, también conocida como manufactura aditiva, se fundamenta en una serie de principios que permiten la construcción de objetos tridimensionales a partir de modelos digitales. Estos principios son clave para comprender su funcionamiento y aplicaciones

2.2.1 Fabricación capa por capa

El principio más fundamental de la impresión 3D es la construcción de un objeto capa por capa. A partir de un diseño digital (generalmente en formato STL o CAD), el software de impresión divide el modelo en capas horizontales, que luego se fabrican secuencialmente mediante la deposición de material. “La fabricación aditiva crea objetos construyéndolos capa por capa, a diferencia de los procesos de fabricación sustractiva tradicionales que eliminan material para lograr la forma deseada.” [1].

2.2.2 Uso de un modelo digital tridimensional

El proceso comienza con un modelo 3D, diseñado mediante software de diseño asistido por computadora (CAD). Este archivo es esencial para guiar al sistema de impresión en la creación de cada capa. “El proceso aditivo requiere un modelo digital 3D que se corta en capas y luego se imprime secuencialmente para formar el objeto.” [9].

2.2.3 Conversión a formato interpretable por la impresora (Slicing)

Antes de la impresión, el modelo se convierte en un conjunto de instrucciones (G-code), que definen el movimiento de la boquilla, la temperatura, la velocidad y la trayectoria. “El software de corte traduce los modelos 3D en instrucciones para la impresora, incluidas las trayectorias de las herramientas, los ajustes de temperatura y las estrategias de deposición de material.” [10].

2.2.4 Deposición controlada de material

La mayoría de las tecnologías de impresión 3D (como FDM) funcionan mediante la extrusión de material fundido (como filamento plástico), que se solidifica rápidamente al depositarse, permitiendo la construcción estructurada de cada capa. “En la impresión 3D basada en extrusión, un material termoplástico se funde y se extruye a través de una boquilla para formar capas que se adhieren entre sí.” [7].

2.2.5 Adhesión entre capas

La adhesión entre capas es crítica para garantizar la integridad estructural de la pieza. Factores como temperatura, velocidad de impresión y tipo de material afectan la calidad de la adhesión. “La unión de capas es crucial en la fabricación aditiva, ya que una adhesión débil entre capas puede comprometer las propiedades mecánicas.” [1].

2.2.6 Post-procesamiento

Después de la impresión, muchas piezas requieren acabados adicionales como eliminación de soportes, lijado, curado o tratamiento térmico para mejorar sus propiedades estéticas o funcionales. “Los pasos de posprocesamiento suelen ser necesarios para mejorar el acabado de la superficie, la precisión dimensional y el rendimiento mecánico de las piezas impresas.” [8].

2.3 Historia y evolución de la Manufactura aditiva

La manufactura aditiva (MA), comúnmente conocida como impresión 3D, ha recorrido un camino notable desde sus inicios experimentales en la década de 1980 hasta convertirse en una tecnología clave dentro de la Industria 4.0. Su evolución ha sido impulsada por avances en materiales, software, procesos de fabricación digital y automatización.

2.3.1 Orígenes en la década de 1980

El origen de la manufactura aditiva se remonta a 1983, cuando Charles Hull desarrolló la tecnología de estereolitografía (SLA), un proceso que solidifica resina fotosensible capa por capa mediante luz ultravioleta. Esta invención marcó un punto de partida fundamental para la impresión 3D moderna y derivó en la fundación de la empresa 3D Systems en 1986, que introdujo las primeras impresoras 3D comerciales [1]. “La primera forma de fabricación aditiva fue la estereolitografía, inventada por Charles Hull en 1983, que utilizaba luz ultravioleta para curar resina de fotopolímero en capas.” [1].

2.3.2 Década de 1990: expansión de tecnologías

Durante los años 90, surgieron otras tecnologías fundamentales como el Fused Deposition Modeling (FDM), desarrollada por Scott Crump, fundador de Stratasys, y el Selective Laser Sintering (SLS), creada por Carl Deckard en la Universidad de Texas. Estas técnicas ampliaron el rango de materiales utilizables, incluyendo termoplásticos y polvos metálicos, lo cual diversificó las aplicaciones de la MA [10].

“En la década de 1990 se comercialización de las tecnologías FDM y SLS, que permitieron el uso de un conjunto más amplio de materiales más allá de los fotopolímeros.” [10].

2.3.3 Años 2000: democratización y acceso abierto

A partir del año 2000, el movimiento RepRap (Replicating Rapid Prototyper) jugó un papel clave en la democratización de la impresión 3D. Este proyecto de código abierto impulsó el desarrollo de impresoras 3D accesibles y económicas, permitiendo que investigadores, estudiantes y entusiastas pudieran construir sus propias impresoras [12]. “El proyecto RepRap, iniciado en 2005, tenía como objetivo crear una impresora 3D autorreplicante utilizando hardware y software de código abierto, lo que desencadenó un movimiento global de creadores.” [12]

2.3.4 Década de 2010: adopción industrial y profesionalización

En la década de 2010, la manufactura aditiva experimentó una expansión industrial significativa, pasando del prototipado rápido a la producción de piezas funcionales. Sectores como la aeronáutica, automotriz, médica y dental comenzaron a adoptar tecnologías aditivas para producir componentes personalizados y ligeros con geometrías complejas [13]. “La fabricación aditiva ha madurado desde la creación rápida de prototipos hasta la producción de piezas funcionales, con aplicaciones en las industrias aeroespacial, automotriz y biomédica.” [7].

2.3.5 Presente y futuro: Manufactura Aditiva 2.0

En la actualidad, la MA se encuentra en una fase de integración con otras tecnologías emergentes como la inteligencia artificial, machine learning, internet de las cosas (IoT) y fabricación en la nube, lo que da lugar al concepto de Manufactura Aditiva 2.0. Esta evolución busca optimizar procesos, aumentar la trazabilidad y permitir la personalización masiva en tiempo real [11]. “El futuro de la fabricación aditiva reside en su convergencia con las tecnologías digitales, dando lugar a un nuevo paradigma de sistemas de producción inteligentes, flexibles y distribuidos.” [11].

2.4 Tipos de tecnologías en la Manufactura aditiva

La manufactura aditiva comprende una variedad de tecnologías que comparten el principio de construir objetos capa por capa, pero difieren en los mecanismos de deposición y los tipos de materiales empleados. Según la norma ISO/ASTM 52900:2021, estas tecnologías se clasifican en siete categorías principales, cada una con aplicaciones, ventajas y limitaciones específicas.

2.4.1 Extrusión de material (Material Extrusión)

La tecnología más conocida en esta categoría es el Fused Deposition Modeling (FDM). En este proceso, un filamento termoplástico (como PLA o ABS) se funde y se extruye a través de una boquilla caliente, depositándose capa por capa. “La extrusión de material es un proceso en el que el material se dispensa selectivamente a través de una boquilla u orificio.” [6]. Algunas de las aplicaciones se pueden dar en el prototipado rápido, en piezas funcionales, y en la educación.

Algunas de las ventajas son que tiene bajo costo, es una tecnología accesible y se puede realizar con una variedad de materiales. Por otro lado, algunas de sus limitaciones son que la resolución es limitada y puede llegar a tener defectos por mala adhesión entre capas.

2.4.2 Fotopolimerización en tanque (Vat Photopolymerization)

La técnica más común aquí es la Estereolitografía (SLA). Utiliza una resina líquida fotosensible que se solidifica mediante luz ultravioleta (UV), ya sea con láser (SLA) o pantalla LCD (DLP). “La fotopolimerización utiliza resina de fotopolímero líquido, que se cura capa por capa utilizando una fuente de luz ” [7].

Las aplicaciones que se le dan a esta tecnología mayormente son en la : odontología, la joyería y en prototipos detallados. Las ventajas: de este tipo de tecnología es la alta precisión y el buen acabado superficial. Por el contrario, las limitaciones que puede tener es que se aplica solo en materiales frágiles y requiere de un procesamiento posterior.

2.4.3 Fusión en lecho de polvo (Powder Bed Fusion, PBF)

Incluye tecnologías como Selective Laser Sintering (SLS) y Selective Laser Melting (SLM). Utiliza un láser (o haz de electrones) para fusionar partículas de polvo capa por capa. “Los procesos de fusión de lecho de polvo utilizan una fuente térmica para fusionar selectivamente regiones de un lecho de polvo” [7].

Algunas de las aplicaciones se dan en las áreas aeroespacial, biomédica, y en la creación de componentes metálicos, teniendo ventajas como el uso de materiales resistentes y se pueden desarrollar geometrías complejas, aunque algunas de las desventajas que tiene esta tecnología es el alto costo y que se puede realizar solo en ambientes controlados.

2.4.4 Inyección de material (Material Jetting)

Funciona de manera similar a una impresora de tinta, depositando gotitas de fotopolímero que se curan con luz UV. Lo que permite realzar prototipos multicolores y modelos anatómicos con mayor precisión y color, además de excelentes acabados, pero esta tecnología solo puede llevarse a cabo con materiales costosos y que no es apto para piezas funcionales.

2.4.5 Inyección de aglutinante (Binder Jetting)

Consiste en la deposición de un aglutinante líquido sobre polvo (arena, metal, cerámica), que une las partículas para formar cada capa. Luego puede requerirse sinterizado. Lo que permite su uso en la fundición y modelos arquitectónicos ya permite realizar las piezas con gran velocidad y en grandes cantidades, pero una de sus limitaciones es la baja resistencia mecánica sin posprocesamiento.

2.4.6 Deposición directa de energía (Directed Energy Deposition, DED)

Utiliza un láser, haz de electrones o plasma para fundir el material (generalmente metálico) que se deposita simultáneamente. Es común en la reparación de piezas. “La deposición de energía dirigida se utiliza para reparar o agregar material a componentes existentes, a menudo en aplicaciones basadas en metal.” [11].

Se utiliza normalmente en la industria aeroespacial y en la reparación de componentes. Ya que permite la personalización y el uso de diversos materiales aunque con baja resolución y los equipos para el uso de esta tecnología son muy costosos.

2.4.7 Laminado de hojas (Sheet Lamination)

Consiste en cortar y apilar hojas de material (papel, metal, plástico) unidas por adhesivos o soldadura. Un ejemplo es la tecnología LOM (Laminated Object Manufacturing). Se utiliza mayormente en el desarrollo de prototipos a escala y en modelos arquitectónicos de manera rápida y a bajo costo

A continuación, en la Tabla 1 se muestra una comparación de las diversas tecnologías que se pueden utilizar en la manufactura aditiva

Tecnología	Materiales comunes	Ventajas	Limitaciones	Aplicaciones típicas
FDM	Termoplásticos (PLA, ABS, PETG)	Bajo costo, fácil uso, variedad de materiales	Baja resolución, riesgo de deformaciones	Educación, prototipado rápido
SLA/DLP	Resinas fotopolímeras	Alta precisión, buen acabado superficial	Fragilidad, requiere postcurado	Odontología, joyería, prototipos visuales
SLS/SLM	Polvo plástico (SLS), metálico (SLM)	Geometrías complejas, materiales funcionales	Costoso, ambiente controlado	Aeroespacial, implantes médicos, automotriz
Material Jetting	Fotopolímeros	Alta resolución, impresión a color	Costoso, piezas frágiles	Prototipos visuales, modelos médicos

Tecnología	Materiales comunes	Ventajas	Limitaciones	Aplicaciones típicas
Binder Jetting	Polvo metálico, cerámico, arena	Rápido, bajo costo en volumen	Baja resistencia sin postproceso	Fundición, arquitectura
DED	Metales en polvo o alambre	Repara piezas, imprime en metales	Baja resolución, alto costo	Reparación industrial, aeroespacial
LOM	Papel, polímeros, metal en láminas	Rápido, económico, poco desperdicio	Detalles limitados, baja resistencia	Modelos visuales, arquitectura

Tabla 1. Comparación de las diversas tecnologías que se utilizan en la manufactura aditiva

2.5 Pruebas de Creep a Termoplásticos

El análisis del comportamiento mecánico de los materiales termoplásticos bajo cargas sostenidas en el tiempo es esencial para aplicaciones estructurales, médicas, automotrices y de manufactura aditiva. Una de las pruebas más importantes para caracterizar este comportamiento es la prueba de creep, también conocida como fluencia. El creep es el fenómeno por el cual un material continúa deformándose lentamente bajo una carga constante, especialmente cuando se encuentra a temperaturas elevadas en relación con su temperatura de transición vítrea (T_g) o de fusión (T_m) [29].

El creep es un proceso dependiente del tiempo, en el cual los materiales experimentan deformaciones plásticas cuando se someten a esfuerzos constantes por un periodo prolongado. Este fenómeno ocurre en tres etapas: creep primario (aceleración decreciente), creep secundario (tasa constante) y creep terciario (aceleración creciente hasta la fractura) [28].

A diferencia de los metales, los polímeros como los termoplásticos muestran un comportamiento viscoelástico, lo que significa que su deformación depende tanto de la carga como del tiempo y la temperatura. Este comportamiento se describe frecuentemente mediante modelos como el de Maxwell o el de Kelvin-Voigt, que combinan elementos elásticos y viscosos para simular la respuesta del material [30].

Los termoplásticos como el polietileno (PE), polipropileno (PP), policarbonato (PC) o el acrilonitrilo butadieno estireno (ABS) son susceptibles al creep debido a su estructura molecular semicristalina o amorfa. Por ejemplo, el polietileno de alta densidad (HDPE) puede mostrar deformaciones considerables bajo esfuerzos mecánicos moderados si se mantienen por largos periodos de tiempo.

Un ejemplo típico se encuentra en aplicaciones de tuberías plásticas, donde la presión interna y la exposición al calor pueden generar deformaciones significativas con el tiempo.

La prueba más común para evaluar el creep en termoplásticos es la establecida por la norma ASTM D2990 - “Standard Test Methods for Tensile, Compressive, and Flexural Creep and Creep-Rupture of Plastics”. Esta prueba consiste en aplicar una carga constante a una muestra durante un período prolongado (desde horas hasta semanas o meses), y medir la deformación en función del tiempo [28].

Los métodos de prueba más comunes incluyen:

- Creep en tensión.
- Creep en compresión.
- Creep en flexión.

2.1.1 Creep en tensión

El creep en tensión es una de las formas más comunes de evaluar la resistencia a la deformación de los materiales termoplásticos cuando se les aplica una fuerza axial constante durante un tiempo prolongado. Esta prueba es especialmente útil en componentes que estarán sometidos a cargas de tracción continuas en condiciones reales de operación, como cables, láminas, carcasas o piezas impresas en 3D [31].

Durante la prueba, la muestra se somete a una carga de tracción constante a temperatura controlada, y se registra la deformación unitaria (ϵ) en función del tiempo. La forma de la curva típica obtenida muestra tres etapas:

- Creep primario: donde la tasa de deformación disminuye con el tiempo.
- Creep secundario: donde la tasa se estabiliza (fluencia estacionaria).
- Creep terciario: donde la deformación se acelera hasta la fractura del material [30].

Este comportamiento se ve intensificado en termoplásticos amorfos como el poliestireno (PS) o el poliestireno de alto impacto (HIPS), ya que presentan menor resistencia a la fluencia a temperaturas cercanas a su temperatura de transición vítrea (T_g) [30]. A continuación en la Figura 1. Se muestra un ejemplo de una máquina con la que se puede llevar a cabo el creep en tensión.



Figura 2. Máquina de creep en tensión

2.1.2 Creep en compresión

El comportamiento de los termoplásticos bajo cargas prolongadas en compresión es fundamental en aplicaciones donde los componentes deben resistir presiones continuas sin deformarse permanentemente. El fenómeno conocido como creep en compresión representa la deformación lenta y progresiva que experimentan estos materiales cuando se le somete a una carga compresiva constante durante largos periodos, especialmente a temperaturas elevadas [29] El estudio del creep en compresión es clave en industrias como la automotriz,

construcción y embalaje, donde materiales plásticos soportan cargas permanentes en cojinetes, aislantes, columnas o empaques.

Los resultados de creep en compresión son fundamentales para:

- Evaluar el comportamiento a largo plazo de materiales plásticos usados como cojinetes o amortiguadores.
- Diseñar componentes en equipos médicos como férulas, prótesis y soportes, donde las cargas sobre el material son constantes.
- Simular condiciones reales de empaque industrial, donde las cajas o contenedores plásticos están apilados durante meses.
- Mejorar el desempeño de piezas en impresión 3D, especialmente cuando están orientadas verticalmente y bajo carga.

El creep en compresión es un fenómeno relevante para garantizar la integridad estructural de piezas plásticas bajo carga prolongada. A través de métodos estandarizados como los definidos por la ASTM, es posible caracterizar con precisión este comportamiento y aplicar los datos a simulaciones de diseño y pronósticos de vida útil. La integración de modelos viscoelásticos y pruebas experimentales resulta esencial para desarrollar productos más confiables y duraderos.

2.1.3 Creep en flexión

El análisis del creep en flexión es una herramienta crítica para evaluar el rendimiento a largo plazo de los termoplásticos en aplicaciones donde los componentes están sometidos a cargas de flexión o doblado constante. A diferencia de la fluencia en tensión o compresión, el creep en flexión involucra una distribución no uniforme de tensiones dentro de la pieza, generando zonas en tensión y compresión simultáneamente [29].

Este tipo de prueba es fundamental en el diseño de elementos como puentes plásticos, vigas estructurales, carcasas, perfiles extruidos, así como componentes usados en impresión 3D que requieren rigidez durante largos periodos bajo carga

El creep en flexión es el fenómeno por el cual un material experimenta una deformación progresiva cuando se le aplica una carga constante en condiciones de flexión. A lo largo del tiempo, el centro de la muestra (zona neutra) se mantiene sin deformación, mientras que la parte superior está en compresión y la inferior en tensión. Este tipo de carga asimétrica lo vuelve especialmente complejo de modelar [30].

La flexión induce tensiones diferenciales que permiten evaluar de manera simultánea la resistencia del material tanto a la tracción como a la compresión. Esto es importante en materiales viscoelásticos como los termoplásticos, ya que su deformación depende del tiempo, temperatura, y la historia de cargas [32].

El creep en flexión es un fenómeno complejo pero esencial para comprender el comportamiento a largo plazo de los termoplásticos. Las pruebas bajo este tipo de carga permiten anticipar fallos estructurales, especialmente en aplicaciones que implican cargas sostenidas en ambientes calurosos o con fluctuaciones térmicas. Gracias a normativas como ASTM D2990 y a herramientas modernas de análisis, es posible cuantificar la deformación y aplicar modelos predictivos para optimizar el diseño de productos plásticos.

2.6 Desplazamiento en procesos de manufactura aditiva

En el contexto de la manufactura aditiva, el término desplazamiento se refiere a un fenómeno no deseado en el que una o varias capas de una pieza impresa en 3D se desalinean con respecto a la geometría esperada. Este defecto puede manifestarse como un desplazamiento lateral o axial en ciertas secciones del modelo, generando imperfecciones visibles y, en algunos casos, afectando las propiedades mecánicas o funcionales de la pieza final.

Según Górski (2017), el desplazamiento ocurre cuando hay una interrupción o variación en la posición relativa de la boquilla respecto a la pieza durante el proceso de impresión. Esto puede deberse a múltiples factores, entre los que destacan: fallos mecánicos en los motores paso a paso, deslizamiento de correas, problemas con el software de control (firmware), o movimientos bruscos de la plataforma de impresión. “El desplazamiento de capas generalmente se debe a errores mecánicos, mal funcionamiento del motor paso a paso o movimientos abruptos del cabezal de impresión, lo que da como resultado capas desplazadas y defectos estructurales visibles.” [14].

Además, el desplazamiento puede originarse por vibraciones externas, sobrecalentamiento de los drivers del motor, frenado brusco de los ejes o una adhesión inadecuada de la primera capa, lo cual desestabiliza la pieza y la hace susceptible a movimientos indeseados [13]. “Las desalineaciones y los desplazamientos de capas durante el modelado por deposición fundida a menudo se atribuyen a una unión incorrecta de las capas, estrés térmico o una adhesión insuficiente del lecho.” [13].

Este tipo de defecto es especialmente relevante cuando se busca obtener piezas de alta precisión dimensional, ya que incluso pequeños desplazamientos acumulados pueden generar errores considerables en la geometría total del objeto. En aplicaciones funcionales o industriales, estas imperfecciones podrían comprometer la usabilidad, ensamblaje o resistencia de la pieza impresa.

En investigaciones recientes, se han comenzado a aplicar técnicas de visión por computadora para detectar y cuantificar automáticamente el desplazamiento mediante la comparación de imágenes del modelo teórico contra el objeto impreso [15]. Esto permite implementar sistemas de monitoreo en tiempo real y corregir errores antes de que el proceso culmine, optimizando así la calidad y eficiencia del sistema de impresión.

2.6.1 Tipos de desplazamiento.

En los procesos de manufactura aditiva, los errores de impresión afectan directamente la calidad dimensional, integridad estructural y funcionalidad de las piezas producidas. Uno de los defectos más frecuentes y críticos es el desplazamiento o "layer shifting", el cual se manifiesta como una desalineación entre capas durante la fabricación. Estos desplazamientos pueden ser sutiles o severos, y obedecen a múltiples causas mecánicas, térmicas, electrónicas o de software [14]. Conocer los tipos de desplazamientos es esencial para establecer estrategias de detección, monitoreo y corrección eficaces.

El desplazamiento en impresión 3D puede clasificarse en función de su origen y de su manifestación física:

- Desplazamiento por fallo mecánico del eje. Se produce cuando hay una pérdida de pasos en los motores que controlan el movimiento de los ejes X, Y o Z, generando una capa desfasada respecto a la anterior. Usualmente está asociado a una correa floja, obstrucción mecánica, o mal ajuste de guías lineales. “Los cambios mecánicos a menudo ocurren cuando los motores paso a paso saltan pasos debido a una mayor resistencia, correas sueltas o lubricación deficiente.” [13]. Las consecuencias de este tipo de desplazamiento son las líneas completas desplazadas en un eje, comúnmente en X o Y.
- Desplazamiento por vibraciones externas. Las vibraciones provocadas por el entorno, por una mala fijación de la impresora, o por movimientos bruscos del cabezal pueden causar que las capas no se depositen con precisión. “Los cambios mecánicos a menudo ocurren cuando los motores paso a paso saltan pasos debido a una mayor resistencia, correas sueltas o lubricación deficiente.” [14]. Esto provoca desplazamientos aleatorios, generalmente acumulativos en altura.

- **Desplazamiento térmico** Este tipo ocurre cuando se generan gradientes térmicos importantes en la pieza o en la cama caliente, lo que provoca deformaciones por contracción o expansión. El enfriamiento desigual hace que las capas se separen o se tuerzan. “El estrés térmico y el enfriamiento desigual pueden causar deformaciones y delaminación, lo que resulta en desplazamiento de capas o inexactitud dimensional.” [7]. Lo que provoca la separación de capas o torsión en esquinas.
- **Desplazamiento por errores de software o firmware** Errores en el G-code, fallos en el firmware o interrupciones en la comunicación entre la impresora y la computadora/controlador pueden enviar instrucciones equivocadas, provocando que el cabezal se mueva a posiciones erróneas. “Un corte incorrecto o instrucciones de firmware corruptas pueden generar movimientos no deseados del cabezal de impresión, lo que genera una desalineación de las capas.” [15]. Esto produce saltos irregulares, desplazamientos impredecibles.
- **Desplazamiento por pérdida de adherencia** Cuando una pieza no adhiere correctamente a la cama caliente, puede moverse durante la impresión. Este tipo de desplazamiento es común en la primera capa o cuando se imprime sin superficies adherentes adecuadas (como cinta, laca o base rugosa). “La adhesión inadecuada de la cama provoca el desplazamiento de la pieza durante el proceso de impresión, lo que causa una desalineación grave o fallas de impresión.” [1]. Esto ocasiona el desplazamiento desde la base, impresión parcial o completamente fuera de lugar.

Los desplazamientos en manufactura aditiva son fenómenos multifactoriales que comprometen la calidad y precisión de las piezas. Identificar su origen es clave para aplicar acciones correctivas y preventivas. Actualmente, se están desarrollando técnicas automatizadas de monitoreo, como la visión por computadora y el análisis de imágenes, para detectar estos errores en tiempo real, lo cual representa una herramienta prometedora para mejorar la eficiencia de los procesos aditivos [15].

2.6.2 Consecuencias del desplazamiento en la calidad del producto final

En la manufactura aditiva, el proceso de fabricación capa por capa exige una alta precisión en el posicionamiento del cabezal de impresión y de la pieza durante todo el ciclo de producción. El desplazamiento de capas (layer shifting) es uno de los defectos más críticos, ya que genera desalineaciones geométricas que afectan directamente la calidad dimensional, la apariencia superficial, la resistencia mecánica y, en muchos casos, la funcionalidad del producto final [1].

El Impacto del desplazamiento en la calidad del producto se puede clasificar de la siguiente manera:

- **Pérdida de precisión dimensional.** El desplazamiento altera las dimensiones reales del objeto respecto a su diseño original, generando errores dimensionales acumulativos. Esta desviación puede impedir el ensamblaje de componentes, sobre todo en aplicaciones industriales que requieren ajustes de tolerancia estricta. “La desalineación de capas en la fabricación aditiva genera una inexactitud dimensional, lo cual es crítico cuando se producen piezas destinadas al ensamblaje o a una función mecánica.” [14].
- **Defectos en la apariencia superficial** Uno de los efectos visuales más notorios del desplazamiento es la aparición de líneas escalonadas o bordes deformados, que comprometen la estética del producto. En industrias como la de joyería, diseño industrial o prótesis personalizadas, la calidad visual es un criterio esencial. “Las irregularidades de la superficie causadas por el cambio de capas reducen el valor estético de las piezas impresas y aumentan la necesidad de posprocesamiento [13].
- **Reducción de resistencia mecánica** El desplazamiento entre capas compromete la adhesión interlaminar, creando zonas débiles o puntos de falla. Esto reduce la resistencia estructural de la pieza, haciéndola más propensa a fracturas, especialmente

en cargas perpendiculares a las capas. “El rendimiento mecánico se ve afectado significativamente por una mala unión de las capas, a menudo causada por gradientes térmicos o desalineación durante la deposición.” [7].

- Incremento del desperdicio y tiempo de producción Cuando el desplazamiento es severo, la pieza suele ser considerada inservible y debe ser descartada, lo que implica una pérdida de material, tiempo y energía. Además, si el defecto no se detecta durante la impresión, el error se acumula, haciendo imposible su corrección posterior. “Las fallas de impresión debido a la desalineación generan desperdicio de material, mayor tiempo de producción y mayores costos operativos.” [15].
- Rechazo del producto o incumplimiento de estándares En aplicaciones industriales o biomédicas, incluso defectos menores pueden hacer que una pieza no cumpla con los requisitos de calidad, normas técnicas o certificaciones. Esto implica un impacto en la confiabilidad del proceso y en la aceptación del producto por parte del cliente. “Los componentes funcionales con desalineaciones estructurales no cumplen con los estándares de calidad industrial y pueden ser rechazados, particularmente en sectores regulados.” [11].

El desplazamiento en manufactura aditiva representa un desafío crítico que compromete múltiples aspectos de la calidad del producto final. Más allá de ser un defecto estético o superficial, sus efectos pueden derivar en pérdidas económicas, baja eficiencia operativa y fallos funcionales. Por ello, es fundamental implementar estrategias de monitoreo, calibración y control automatizado, como el análisis por visión artificial, para detectar estos errores de forma temprana y garantizar resultados consistentes.

2.6.3 Métodos tradicionales para detectar desplazamientos

La detección temprana de estos desplazamientos es fundamental para evitar desperdicio de material, fallos mecánicos y pérdida de funcionalidad. Antes del uso de sistemas avanzados como la visión por computadora o el aprendizaje automático, los procesos de detección de desplazamientos se basaban en métodos tradicionales, tanto manuales como instrumentales [14].

Como primer método se tiene la Inspección visual manual que es el método más común y antiguo es la inspección visual, que consiste en revisar la pieza una vez impresa para identificar anomalías evidentes, como capas desalineadas, bordes escalonados o deformaciones. “La inspección visual sigue siendo el método de control de calidad más utilizado en el modelado por deposición fundida debido a su simplicidad, a pesar de su subjetividad y limitaciones.” [13]. Las ventajas que ofrece este método es que no requiere equipos sofisticados y es de bajo costo, aunque no es tan confiable ya que depende del ojo humano y es subjetiva, además que la detección de los errores se hace post impresión.

Un método más es la verificación dimensional con instrumentos de medición que es un enfoque tradicional es el uso de instrumentos de metrología manual, como calibradores, micrómetros y reglas de precisión para comparar las dimensiones impresas con el modelo CAD original. “La precisión dimensional se puede evaluar después del proceso utilizando calibradores o máquinas de medición de coordenadas, aunque estos métodos requieren mucho tiempo y son reactivos.” [1]. Lo bueno de este método es que permite cuantificar errores dimensionales y lo malo es que es lento, costoso y se puede realizar sólo después de finalizar la impresión.

Otro método un poco más sofisticado es el análisis del G-code y simulaciones previas que es una forma de prevención es realizar simulaciones del G-code generado antes de la impresión. Mediante softwares como Cura, PrusaSlicer o Simplify3D, es posible visualizar cómo se construirá cada capa e identificar posibles errores de trayectorias o movimientos erráticos. “La simulación de código G permite la identificación de posibles problemas antes de imprimir, lo que sirve como medida preventiva contra desalineaciones o desplazamientos.” [7]. La ventaja que ofrece este método es que se pueden evitar los errores antes de imprimir, aunque no permite detectar fallos físicos o mecánicos reales.

Un método más es la calibración preventiva y mantenimiento rutinario ya que muchos desplazamientos son causados por falta de mantenimiento, por lo que se ha considerado como método tradicional el establecimiento de protocolos de revisión periódica: ajuste de correas, engrases, verificación de poleas y pasos de motor. “La calibración regular y el mantenimiento

mecánico son fundamentales para minimizar los problemas de desplazamiento, especialmente en las impresoras FDM de escritorio.” [11]. Este método ayuda a prevenir los errores antes de que ocurran, pero se requiere de experiencia y no se garantiza la detección total.

El último de los métodos tradicionales para detectar el desplazamiento son las pruebas de impresión de control (test prints) que es una estrategia tradicional en talleres e instituciones educativas consiste en imprimir piezas de prueba, como cubos de calibración, torres de temperatura o modelos de alineación, que permiten evaluar el rendimiento de la impresora. “Las impresiones de calibración proporcionan indicadores tempranos de problemas de alineación y son esenciales para garantizar la preparación de la máquina.” [15]. Este es un método simple que permite validar configuración, pero no detecta desplazamientos espontáneos en impresiones largas.

Los métodos tradicionales para detectar desplazamientos en manufactura aditiva se basan principalmente en la inspección visual, la verificación post-impresión y el mantenimiento preventivo. Si bien son accesibles y funcionales en entornos básicos, presentan limitaciones importantes en términos de precisión, automatización y reacción temprana. Por ello, en la actualidad se están desarrollando métodos avanzados basados en visión por computadora, sensores y sistemas de monitoreo en tiempo real para superar estas restricciones.

2.7 Correlacion de Imágenes Digitales

En la ingeniería moderna, el análisis del comportamiento mecánico de los materiales requiere herramientas experimentales que permitan una medición precisa, no invasiva y en tiempo real. Una de estas herramientas es la Correlación de Imágenes Digitales (DIC), una técnica óptica que ha cobrado gran relevancia en la última década. El DIC consiste en comparar secuencias de imágenes digitales de la superficie de un material sometido a carga para determinar los desplazamientos y deformaciones con alta precisión [46]. Su ventaja radica en ser un método no destructivo, versátil y aplicable en una amplia gama de disciplinas, desde la ingeniería mecánica y civil hasta la biomecánica y los materiales compuestos [47].

El principio fundamental del DIC se basa en el análisis de patrones de textura sobre la superficie de un objeto, los cuales son capturados antes y durante la aplicación de cargas. Estos patrones, generalmente generados mediante un recubrimiento de puntos aleatorios (speckle pattern), permiten realizar un seguimiento digital de pequeñas regiones en las imágenes, detectando desplazamientos y cambios geométricos [48].

Mediante algoritmos de correlación, es posible calcular campos de desplazamiento bidimensionales o tridimensionales, así como derivar a partir de ellos campos de deformación [49]. Existen dos variantes principales:

- 2D-DIC, utilizado en casos donde la deformación ocurre principalmente en un plano.
- 3D-DIC, que requiere múltiples cámaras y permite la reconstrucción de superficies tridimensionales para analizar deformaciones más complejas [49].

Algunos de los beneficios de la DIC es que es una técnica sin contacto, lo cual evita alterar el comportamiento mecánico del espécimen [46], además, ofrece alta resolución espacial, al poder analizar regiones muy pequeñas [48] y se puede aplicar de manera versátil, desde ensayos de tracción y compresión hasta pruebas dinámicas de impacto y vibración [47].

La DIC constituye una herramienta poderosa en la caracterización experimental de materiales y estructuras. Su capacidad para medir desplazamientos y deformaciones de forma precisa y no invasiva la convierte en una alternativa confiable frente a métodos tradicionales como los extensómetros o galgas extensiométricas [49]. Gracias a su versatilidad, el DIC continúa expandiéndose en múltiples campos de la investigación, proporcionando datos valiosos para el desarrollo de materiales avanzados, la validación de modelos numéricos y la optimización de diseños ingenieriles [48].

2.8 Procesamiento y comparación de imágenes

2.8.1 Fundamentos de la visión por computadora

La visión por computadora (o computer vision) es una rama de la inteligencia artificial que busca dotar a las máquinas de la capacidad de adquirir, interpretar y procesar imágenes o videos digitales, de manera que puedan tomar decisiones o ejecutar acciones basadas en la información visual extraída. Esta disciplina combina técnicas de procesamiento de imágenes, aprendizaje automático, percepción visual y análisis matemático para imitar, en cierto grado, el funcionamiento de la visión humana.

A diferencia del procesamiento convencional de datos, la visión por computadora debe lidiar con información visual ambigua, compleja y de alta dimensionalidad, lo cual exige métodos robustos para extraer características relevantes como formas, colores, texturas, bordes o patrones. En el contexto de la manufactura aditiva, esta tecnología ha demostrado ser eficaz para monitorear procesos en tiempo real, detectar defectos como el desplazamiento de capas y automatizar tareas de control de calidad [15]. “La visión artificial permite el análisis y la interpretación automáticos de datos visuales para realizar tareas que requieren comprensión visual, como la detección de defectos y la verificación dimensional.” [17].

Entre sus principales aplicaciones se encuentran: inspección de productos, detección de anomalías, control de posición, reconstrucción 3D y reconocimiento de objetos. Para lograrlo, se emplean algoritmos de procesamiento de imágenes, los cuales permiten preparar, limpiar y analizar la información captada por sensores o cámaras digitales.

2.8.2 Técnicas básicas de procesamiento de imágenes

El procesamiento de imágenes digitales es un conjunto de operaciones computacionales aplicadas a una imagen con el objetivo de mejorar su calidad, extraer información o transformarla para facilitar su análisis. Estas técnicas son la base funcional de los sistemas de visión por computadora y se implementan comúnmente en entornos como Python (con librerías como OpenCV o PIL), MATLAB, o C++ [19].

A continuación, se describen las técnicas fundamentales:

- Conversión de color (RGB a escala de grises). La mayoría de las imágenes capturadas por cámaras digitales están representadas en el modelo de color RGB (Red, Green, Blue), en el cual cada píxel se compone de tres canales de color. Sin embargo, para muchas tareas de análisis es útil reducir la complejidad de la imagen convirtiéndola a escala de grises, lo cual conserva la intensidad luminosa sin considerar el color [18]. La conversión se realiza mediante una combinación ponderada de los tres canales RGB, utilizando una fórmula estándar como:

$$\text{Gray} = 0.2989 * R + 0.5870 * G + 0.1140 * B$$

Esta simplificación reduce el espacio de búsqueda y mejora el rendimiento de algoritmos como la detección de bordes, la segmentación y la umbralización. “La conversión de escala de grises es un paso de preprocesamiento común que simplifica el análisis de imágenes posterior al reducir la imagen a un único canal de intensidad.”[17].

- Detección de bordes. La detección de bordes es una técnica clave que permite identificar cambios abruptos de intensidad en la imagen, lo cual suele indicar la presencia de contornos u objetos. Existen diversos algoritmos para esta tarea, entre ellos los operadores Sobel, Prewitt, Roberts y el más avanzado Canny

El algoritmo de Canny, por ejemplo, realiza un suavizado con un filtro Gaussiano, calcula el gradiente de intensidad y aplica una doble umbralización para extraer los bordes más significativos [16]. “La detección de bordes es una herramienta fundamental en el análisis de imágenes que se utiliza para identificar límites de objetos, transiciones estructurales y características geométricas.” [19]. En la manufactura aditiva, la detección de bordes puede utilizarse para verificar contornos de capas, comparar formas impresas con modelos de referencia, y detectar defectos de alineación.

- Segmentación. La segmentación de imágenes consiste en dividir una imagen en regiones homogéneas que comparten características similares, como intensidad, color o textura. Su objetivo es aislar objetos o partes relevantes para facilitar su análisis. Las técnicas de segmentación pueden clasificarse en:
 - Basadas en umbrales (thresholding)
 - Por crecimiento de regiones
 - Por contornos activos (snakes)
 - Basadas en clustering (como K-means)

En la detección de desplazamientos en impresión 3D, la segmentación permite aislar regiones deformadas o desplazadas para analizarlas comparativamente con una imagen ideal o modelo CAD (Reinhart et al., 2021). “La segmentación de imágenes aísla áreas de interés, lo que permite un análisis centrado en partes específicas de una imagen y reduce la complejidad computacional.” [17].

•

- Umbralización (Thresholding). La umbralización es una técnica simple y eficaz para convertir una imagen en escala de grises a una imagen binaria, separando los píxeles en dos grupos: aquellos por encima y por debajo de un determinado valor de umbral. Este método es ampliamente utilizado en visión por computadora para separar fondo y objeto [18]. Existen variantes como:
 - Umbral fijo
 - Umbral adaptativo
 - Método de Otsu

Este último calcula automáticamente el umbral óptimo que minimiza la varianza intra-clase y maximiza la inter-clase. “La umbralización simplifica una imagen al clasificar los píxeles en dos categorías, a menudo como precursor de la detección de

contornos o el análisis de formas.” [19]. En impresión 3D, se puede utilizar la umbralización para comparar imágenes de capas e identificar si existen píxeles fuera de su posición esperada, indicando desplazamientos o errores estructurales.

Los fundamentos de la visión por computadora y sus técnicas básicas de procesamiento de imágenes permiten extraer información valiosa de datos visuales y automatizar el análisis de calidad en procesos de manufactura aditiva. Métodos como la conversión de color, detección de bordes, segmentación y umbralización constituyen los pilares esenciales para construir sistemas inteligentes capaces de identificar desplazamientos y otros defectos en tiempo real. Estas herramientas, cuando se integran con algoritmos de comparación y monitoreo, ofrecen soluciones eficientes y escalables para mejorar la confiabilidad del proceso de impresión 3D.

2.8.3 Técnicas para la comparación de imágenes

La comparación de imágenes es una técnica fundamental en visión por computadora, especialmente útil en aplicaciones industriales, médicas y de control de calidad. En manufactura aditiva, se emplea para detectar desviaciones geométricas, desplazamientos de capas y defectos estructurales comparando una imagen de referencia (esperada) con una imagen real del objeto fabricado. Existen diversas técnicas para esta tarea, desde métodos simples de sustracción de píxeles hasta métricas estructurales complejas como el Índice de Similitud Estructural (SSIM) o el Error Cuadrático Medio (MSE) [19].

2.8.4 Diferencia de imágenes

La sustracción de imágenes es uno de los métodos más básicos para comparar dos imágenes. Consiste en restar, píxel a píxel, la intensidad de la imagen de referencia con respecto a la imagen evaluada. La salida es una imagen en la que los valores distintos a cero representan diferencias entre ambas [17].

Este método se expresa matemáticamente como:

$$D(x, y) = |I_1(x, y) - I_2(x, y)|$$

donde $D(x, y)$ es la diferencia en la posición (x, y) de las imágenes I_1 (referencia) e I_2 (impresa).

Si bien es una técnica sencilla, resulta útil para detectar cambios locales, como desplazamientos, omisiones de capas, o deformaciones en objetos impresos. “La sustracción de imágenes es un método sencillo para detectar cambios entre imágenes al resaltar áreas con diferencias de intensidad significativas.” [17].

Esta técnica se puede aplicar en la manufactura aditiva para detectar si la pieza impresa difiere de su diseño CAD en una región específica (por ejemplo, un eje desalineado o capa desplazada).

2.8.5 Correlación de patrones

La correlación de patrones es una técnica que compara una región de interés (template) dentro de una imagen con el resto de la imagen o con otra imagen completa. Esta técnica busca medir el grado de similitud entre una plantilla y una porción de imagen, desplazándola a lo largo del área de búsqueda.

En procesamiento de imágenes, se utiliza la correlación cruzada normalizada, definida como:

$$C(x, y) = \sum [(I(x+i, y+j) - \mu_I)(T(i, j) - \mu_T)] / (\sigma_I * \sigma_T)$$

donde I es la imagen, T la plantilla, μ el promedio y σ la desviación estándar de cada imagen. La comparación de plantillas mediante técnicas de correlación es eficaz para identificar patrones desplazados o rotados en una escena.” [19]. En manufactura aditiva, la correlación permite verificar si un patrón esperado (por ejemplo, el contorno de una pieza) se encuentra

en la posición correcta de la imagen real. También puede detectar rotaciones, desplazamientos o deformaciones leves. En el caso de esta técnica se puede utilizar para validar que ciertas secciones de la impresión están alineadas con respecto al diseño original.

2.8.6 Detección de contornos deformados

Los contornos representan las fronteras o límites de los objetos dentro de una imagen. Comparar contornos entre una imagen de referencia y una imagen impresa permite detectar desviaciones estructurales. Esta técnica implica extraer los contornos de ambas imágenes (por ejemplo, usando Canny), y luego analizar su superposición, distancia o forma. “La comparación de formas mediante el análisis de contornos permite detectar deformaciones geométricas, desalineaciones e inconsistencias estructurales.” [15].

Existen algoritmos avanzados como:

- Freeman Chain Code
- Hu Moments
- Hausdorff Distance

que permiten cuantificar la diferencia entre contornos de objetos similares, lo que permite detectar si una sección de la pieza se ha deformado por problemas térmicos, mecánicos o por mal adhesión de capas.

A continuación, en la Tabla 2 se muestra una comparativa de los algoritmos mencionados anteriormente

Algoritmo	Propósito	Ventajas	Aplicación en MA
Freeman Chain Code	Codificación de contornos	Simple, compacta, interpretable	Describir bordes capa por capa
Hu Moments	Descripción global de forma	Invariante a escala, rotación, traslación	Comparación de geometrías impresas
Hausdorff Distance	Medida de similitud entre formas	Precisa para evaluar deformaciones y desplazamientos	Verificación geométrica entre modelo e impresión

Tabla 2. Comparación de los algoritmos que permiten la detección de contornos

2.9 Análisis estructural: SSIM y MSE

- **Error Cuadrático Medio (MSE)** El Mean Squared Error (MSE) es una métrica global que mide la diferencia promedio al cuadrado entre dos imágenes del mismo tamaño. Se calcula como:

$$MSE = (1/mn) * \sum [I_1(x,y) - I_2(x,y)]^2$$

donde m y n son las dimensiones de la imagen.

Un valor de MSE cercano a cero indica gran similitud entre las imágenes. Sin embargo, es sensible a cambios locales, y no considera aspectos perceptuales como textura o contraste [20]].

- **Índice de Similitud Estructural (SSIM).** El Structural Similarity Index (SSIM) es una métrica perceptual que compara imágenes basándose en luminancia, contraste y estructura. A diferencia del MSE, el SSIM se aproxima más a la forma en que el ojo humano percibe las diferencias visuales.

Se define como:

$$SSIM(x, y) = [(2\mu_1\mu_2 + C_1)(2\sigma_{12} + C_2)] / [(\mu_1^2 + \mu_2^2 + C_1)(\sigma_1^2 + \sigma_2^2 + C_2)]$$

donde μ es la media, σ la desviación estándar y σ_{12} la covarianza.

“SSIM es una métrica motivada perceptualmente que evalúa la similitud estructural entre dos imágenes y se correlaciona mejor con el juicio humano” [21].

En manufactura aditiva, estas métricas permiten evaluar la similitud global entre una imagen de referencia y una imagen capturada de la impresión terminada. El MSE es útil como criterio numérico objetivo, mientras que el SSIM aporta un análisis más cualitativo y perceptivo, por lo que permiten identificar si una impresión se ha completado correctamente o si existen diferencias generales no detectadas por otros métodos locales.

2.10 Python

Python es un lenguaje de programación de alto nivel, interpretado, multiparadigma y de propósito general. Fue diseñado con una sintaxis clara y legible que facilita el aprendizaje y la escritura de código eficiente. Se ha convertido en uno de los lenguajes más populares y versátiles, utilizado en diversas áreas como ciencia de datos, inteligencia artificial, desarrollo web, automatización, análisis de imágenes, entre otros [28]

2.10.1 Breve historia del lenguaje

Python fue creado a finales de los años 80 por Guido van Rossum en el Centrum Wiskunde & Informatica (CWI) en los Países Bajos. Su primera versión oficial, Python 0.9.0, fue publicada en febrero de 1991. El lenguaje se inspiró en otros lenguajes como ABC, Modula-3 y C, pero se diseñó con una fuerte orientación a la simplicidad y legibilidad del código [24]. El nombre "Python" no proviene del reptil, sino del grupo de comedia británico Monty Python's Flying Circus, lo que refleja el carácter amigable e informal que siempre ha acompañado al lenguaje.

A lo largo de los años, Python ha pasado por múltiples versiones importantes. Python 2, lanzado en 2000, introdujo muchas características nuevas, aunque fue reemplazado oficialmente por Python 3 en 2008, versión que sigue en evolución activa y que se ha convertido en el estándar de facto para la comunidad de desarrollo [22].

2.10.2 Beneficios en el uso de Python

Python se ha posicionado como un lenguaje líder en el desarrollo de aplicaciones científicas y de procesamiento de imágenes debido a varias ventajas clave:

- Facilidad de aprendizaje y sintaxis clara: ideal para principiantes y proyectos colaborativos.
- Gran comunidad y soporte: miles de desarrolladores contribuyen a mantener y ampliar sus capacidades.
- Multiplataforma: puede ejecutarse en sistemas Windows, macOS y Linux.
- Amplia colección de bibliotecas: especialmente útiles para el análisis y procesamiento de imágenes.
- Interoperabilidad con otros lenguajes: puede integrarse con C, C++, Java y otros entornos [25].

2.10.3 Librerías para la comparación de imágenes en Python

La comparación de imágenes es un campo crucial en aplicaciones como visión por computadora, control de calidad en manufactura, medicina y seguridad. Python ofrece una variedad de librerías potentes para llevar a cabo este tipo de tareas:

- OpenCV (Open Source Computer Vision Library). Es una de las librerías más completas para procesamiento de imágenes y visión por computadora. Permite realizar operaciones como la lectura y escritura de imágenes, detección de bordes, comparación mediante sustracción de imágenes, cálculo de similitud estructural (SSIM), entre otros [22].
- scikit-image. Construida sobre SciPy, esta librería ofrece algoritmos para procesamiento de imágenes, incluyendo filtros, segmentación, transformación y comparación estructural. Es especialmente útil para análisis morfológico y medición de similitud [26].
- NumPy. Aunque es una librería para álgebra lineal, es indispensable para manejar matrices de píxeles, que son la base para representar imágenes en Python.
- Pillow (PIL Fork). Librería más sencilla pero muy útil para cargar, manipular y comparar imágenes de forma básica. Ideal para tareas de preprocesamiento.
- Matplotlib. Útil para visualizar imágenes antes y después de la comparación. Aunque no realiza el procesamiento como tal, facilita la interpretación de resultados.
- ImageHash. Permite comparar imágenes a través de hashes perceptuales, una técnica que puede detectar similitudes entre imágenes que han sido redimensionadas, recortadas o alteradas ligeramente [23].

Python se ha consolidado como una herramienta fundamental para el análisis de imágenes gracias a su simplicidad, robustez y rica colección de librerías especializadas. Su historia refleja una evolución constante enfocada en la facilidad de uso y la eficiencia. Para tareas como la comparación de imágenes, por ejemplo, en aplicaciones de manufactura aditiva o control de calidad, Python proporciona un entorno potente y accesible para investigadores y desarrolladores por igual.

2.11 Redes Neuronales

Las redes neuronales artificiales (RNA) son modelos computacionales inspirados en el funcionamiento del cerebro humano. Están compuestas por nodos o "neuronas artificiales" que se organizan en capas: una capa de entrada, una o varias capas ocultas y una capa de salida. Cada nodo procesa información y transmite señales a otros nodos, simulando el comportamiento de las neuronas biológicas (IBM, s.f.).

Su objetivo principal es aprender patrones a partir de datos, permitiendo realizar tareas como clasificación, predicción y reconocimiento de patrones. Estas redes forman parte del aprendizaje automático y son fundamentales en el desarrollo de la inteligencia artificial. A continuación, se mencionan las principales características de las redes neuronales:

- **Aprendizaje automático:** Las redes neuronales aprenden a partir de datos de entrenamiento, ajustando sus parámetros internos (pesos y umbrales) para mejorar su precisión.
- **Capacidad de generalización:** Una vez entrenadas, pueden aplicar lo aprendido a nuevos datos no vistos.
- **Estructura en capas:** Incluyen capas de entrada, ocultas y salida, cada una con funciones específicas en el procesamiento de la información.
- **Conectividad entre nodos:** Los nodos están interconectados mediante pesos que determinan la influencia de una neurona sobre otra.
- **Funciones de activación:** Determinan si una neurona se activa y transmite información a la siguiente capa.
- **Adaptabilidad:** Pueden ajustarse a diferentes tipos de problemas, desde reconocimiento de voz hasta análisis financiero.

Las redes neuronales se pueden clasificar de diversas maneras, cada tipo con características propias que permiten el desarrollo de diferentes tipos de conocimiento y por lo tanto es importante saber la clasificación de las mismas la cual se describe a continuación:

- Monocapa: Red simple con una sola capa de neuronas entre entrada y salida.
- Multicapa (MLP): Incluye varias capas ocultas, útil para tareas complejas como clasificación y regresión.
- Convolucionales (CNN): Especializadas en procesamiento de imágenes y videos.
- Recurrentes (RNN): Diseñadas para trabajar con datos secuenciales, como texto o series temporales

Las redes neuronales pueden utilizarse en múltiples campos como pueden ser: el reconocimiento de voz e imagen, el diagnóstico médico, las predicciones financieras, la traducción automática y en los vehículos autónomos, así que como podemos observar el uso de las redes neuronales es muy amplio y cada día va creciendo el uso y el desarrollo de las mismas.

2.12 Predicción con el modelo Burgers para polímeros

La predicción con el modelo de Burgers para polímeros consiste en simular y analizar el comportamiento viscoelástico de estos materiales cuando se someten a esfuerzos o deformaciones a lo largo del tiempo. Este modelo es especialmente útil para describir el fenómeno de fluencia (creep), que es la deformación progresiva de un material bajo una carga constante.

El modelo de Burgers es una combinación de dos modelos viscoelásticos clásicos que son: el modelo de Maxwell que representa un resorte (comportamiento elástico) en serie con un amortiguador (comportamiento viscoso) y el modelo de Kelvin-Voigt que representa un resorte y un amortiguador en paralelo.

El modelo de Burgers une ambos en serie, formando un sistema de cuatro parámetros: dos módulos de elasticidad (E_1 y E_2) y dos coeficientes de viscosidad (η_1 y η_2). Esta configuración permite capturar tanto la deformación instantánea como la deformación retardada y la recuperación parcial del material.

La predicción con este modelo implica tres fases las cuales se mencionan en seguida:

- 1 Simular la deformación de un polímero bajo una carga constante a lo largo del tiempo.
- 2 Ajustar los parámetros del modelo (E_1 , E_2 , η_1 , η_2) para que coincidan con datos experimentales.
- 3 Interpretar el comportamiento viscoelástico, diferenciando entre la respuesta elástica inmediata, la deformación viscosa progresiva y la recuperación parcial al retirar la carga.

Este enfoque permite anticipar cómo se comportará un polímero en condiciones reales de uso, como en componentes sometidos a presión, temperatura o esfuerzos prolongados.⁴

2.13 Estado del Arte

2.13.1 Real-time Detection of Displacement Defects in FDM Printing Using Image Processing

El proyecto “Real-time Detection of Displacement Defects in FDM Printing Using Image Processing” propone un sistema automatizado que detecta en tiempo real defectos por desplazamiento entre capas mediante el análisis de imágenes capturadas durante la impresión. Este sistema se basa en una cámara montada cerca de la boquilla o plataforma de impresión y en algoritmos desarrollados en Python con OpenCV para comparar fotogramas y detectar irregularidades en la alineación capa por capa [36].

La investigación fue presentada por un equipo multidisciplinario interesado en integrar visión por computadora con el control de calidad en impresoras FDM. Se implementó en una impresora 3D modificada con una Raspberry Pi, cámara HD, y un servidor que analizaba los datos en tiempo real.

El sistema está compuesto por tres módulos principales:

- Captura de imágenes. Se capturan imágenes del objeto impreso en intervalos de tiempo programados. Para garantizar precisión, se utilizan condiciones de iluminación constantes y una posición fija de la cámara.
- Comparación de capas. Cada imagen es procesada y comparada con una imagen “esperada” (modelo de referencia o imagen anterior).
- Detección de desplazamiento. Se establece un umbral de diferencia. Si la variación entre dos capas sucesivas supera ese umbral, el sistema identifica una posible falla de desplazamiento, lanza una alerta y opcionalmente detiene la impresión.

En las pruebas experimentales, el sistema logró detectar desplazamientos de capas con una precisión del 92.5%. Se evaluaron más de 100 impresiones simuladas con errores intencionales (como interrupciones en pasos del motor o resbalones en correas). El sistema detectó exitosamente:

- Desplazamientos laterales (X/Y)
- Cambios en el grosor de capa
- Defectos acumulativos por vibración

Además, se registró una reducción del 40% en tiempo de impresión desperdiciado, al detener la producción inmediatamente tras detectar una falla significativa.

Este tipo de sistema puede ser integrado en impresoras 3D comerciales o caseras lo que permite la supervisión autónoma del proceso, la reducción del desperdicio de material la mejora en la confiabilidad de impresión y la generación de bitácoras de defectos para análisis posteriores

Entre las ventajas del sistema destacan su bajo costo, escalabilidad, y compatibilidad con tecnologías abiertas como Python y Raspberry Pi. Y algunas de las limitaciones con que se encontró este proyecto fueron la sensibilidad al ruido visual (iluminación, sombras), la dependencia de un ángulo fijo de cámara, además no detecta defectos internos o microfisuras y tampoco integra aprendizaje automático (aunque se sugiere para mejoras futuras)

Este proyecto demuestra que es posible implementar un sistema eficiente, económico y no invasivo para detectar fallas de alineación en impresión 3D. Su enfoque basado en procesamiento de imágenes con Python permite una fácil integración con plataformas como OctoPrint y puede ser ampliado con inteligencia artificial para mejorar su capacidad de diagnóstico.

A continuación, en la Figura 3 se muestra el proceso que se lleva a cabo en el proyecto




Figura 3. Funcionamiento del proyecto Real-time Detection of Displacement Defects in FDM Printing Using Image Processing

2.13.2 py2DIC: Medición de desplazamientos y deformaciones en imagen

py2DIC es un software libre y de código abierto para realizar Digital Image Correlation (DIC) bidimensional (2D). Fue desarrollado por la Geodesia y el departamento de Geomática de la Sapienza University of Rome. Este método óptico no invasivo mide desplazamientos y deformaciones en un plano, comparando secuencias de imágenes digitales adquiridas durante la deformación mecánica de muestras

Está implementado en Python, utiliza el método de template matching para rastrear el movimiento de píxeles dentro del Área de Interés (AOI), y devuelve los campos de desplazamiento y deformación (ce, por ejemplo, tensiones Green-Lagrange). A continuación, se describe el funcionamiento del proyecto

- Adquisición de imágenes. Se capturan imágenes de la superficie de una muestra antes y durante su deformación mecánica, con una cámara digital de alta resolución (por ejemplo, DSLR)
- Selección del Área de Interés (AOI). El usuario dibuja un rectángulo en la interfaz para definir un área donde se hará el análisis
- Template matching y correlación. py2DIC divide el AOI en subregiones (templates) y busca correspondencias en la imagen deformada dentro de una ventana de búsqueda. Calcula desplazamientos en escala sub-píxel y suaviza el campo resultante (filtros Gaussianos o splines)
- Cálculo de deformaciones. A partir de los desplazamientos (u , v) se calculan las deformaciones locales ($\partial u/\partial x, \partial v/\partial y$), utilizando suavizado previo para reducir ruido
- Visualización y análisis. El software genera mapas de campo de desplazamiento y deformación en color, permitiendo caracterizar mecanismos de deformación y compararlos con métodos comerciales

A continuación, en la Figura 4 se muestran algunas imágenes que tiene como resultado el proyecto.




Figura 4. Imágenes resultantes del proyecto py2DIC

2.13.3 Correlación de Imágenes Digitales y Redes Neuronales: El Proyecto Deep DIC

En los últimos años, la integración de técnicas de visión por computadora con aprendizaje profundo ha transformado el análisis experimental de materiales y estructuras. Dentro de este ámbito, destaca el proyecto Deep DIC, el cual propone un enfoque novedoso DIC basado en redes neuronales profundas. Este método permite estimar directamente desplazamientos y deformaciones a partir de pares de imágenes digitales, ofreciendo ventajas significativas en velocidad, resolución espacial y robustez frente a limitaciones de los algoritmos tradicionales de correlación [52]

El proyecto Deep DIC se compone de dos arquitecturas principales la primera es DisplacementNet, una red neuronal convolucional (CNN) que predice el campo de desplazamientos y rastrea adaptativamente la región de interés en las imágenes y la segunda es StrainNet, una CNN especializada en estimar el campo de deformaciones sin depender exclusivamente de los resultados de desplazamiento, lo cual mejora la precisión en la obtención de tensiones locales [51].

Para el entrenamiento, los autores generaron un conjunto de datos sintético mediante la creación de patrones aleatorios tipo speckle y la aplicación de deformaciones computacionales conocidas. Este enfoque permitió disponer de un ground truth confiable para supervisar el aprendizaje de las redes [51].

El modelo fue implementado en Python, utilizando la librería PyTorch, y complementado con notebooks que cubren las fases de entrenamiento e inferencia. Dichos scripts incluyen ejemplos prácticos para la generación de datos, entrenamiento de las redes y validación en imágenes experimentales. El repositorio asociado proporciona además modelos preentrenados y un conjunto de imágenes de prueba [50]

Los experimentos realizados muestran que Deep DIC ofrece resultados comparables e incluso superiores a los obtenidos con software comercial de DIC, como VIC-2D, especialmente en casos de grandes deformaciones o patrones deteriorados [51], mayor resolución espacial, ya que la red conserva la información de píxel completo, a diferencia de

los métodos tradicionales que operan en subconjuntos y procesamiento en tiempo real, con tiempos de ejecución en el orden de milisegundos por par de imágenes, lo cual amplía su aplicabilidad en monitoreo dinámico de procesos [51].

En pruebas con ensayos de tracción en metales, la red mostró robustez en regiones donde el patrón speckle se encontraba dañado, preservando la calidad del campo de deformación. Estos resultados evidencian el potencial del aprendizaje profundo para superar los límites de los algoritmos clásicos de correlación digital.

El proyecto Deep DIC constituye un referente en la aplicación de redes neuronales profundas al campo de la correlación de imágenes digitales. Su capacidad para predecir desplazamientos y deformaciones de manera directa, rápida y precisa lo posiciona como una alternativa sólida frente a los métodos tradicionales. Además, la disponibilidad de código abierto en Python facilita su adaptación a contextos específicos, como el análisis de desplazamientos en manufactura aditiva, donde es necesario un monitoreo continuo y en tiempo real. A continuación, en la Figura 5 se muestran imágenes del funcionamiento del proyecto.




Figura 5. Funcionamiento de Deep DIC

Fuente: https://ars.els-cdn.com/content/image/1-s2.0-S0924013621004349-ga1_lrg.jpg

2.13.4 Análisis Comparativo de Desplazamientos mediante Correlación de Imágenes Digitales y Elementos Finitos

El análisis de desplazamientos y deformaciones en materiales y estructuras es esencial para la validación de modelos numéricos y la mejora de procesos de manufactura. Dos de las metodologías más utilizadas en este campo son la DIC) y el Método de Elementos Finitos (MEF). Mientras que el DIC constituye una técnica experimental no invasiva que permite medir en tiempo real los desplazamientos superficiales, el MEF se basa en la resolución numérica de las ecuaciones de la mecánica del continuo para predecir dichos fenómenos[51].

La comparación entre ambos métodos permite identificar no solo el nivel de exactitud alcanzado por las simulaciones, sino también las limitaciones experimentales y numéricas presentes en cada técnica. Este enfoque combinado permite contrastar los resultados de simulaciones con mediciones experimentales obtenidas mediante DIC, incrementando así la fiabilidad de los modelos predictivos.

De acuerdo con los experimentos realizados en este proyecto, se aplicó DIC sobre probetas sometidas a carga controlada y se compararon los resultados con simulaciones de MEF.

Entre los hallazgos más relevantes destacan:

- Coincidencia general: los desplazamientos medidos por DIC mostraron una correlación superior al 90% con los valores simulados mediante MEF, validando la robustez del modelo numérico.
- Diferencias locales: en zonas de concentraciones de deformación, el DIC reveló discrepancias con respecto al MEF, atribuidas a la sensibilidad de la técnica experimental y a simplificaciones en las condiciones de frontera del modelo.
- Valor agregado: mientras que el MEF permite predecir escenarios diversos y futuros, el DIC proporciona información experimental indispensable para ajustar y calibrar los modelos.

Estos resultados concuerdan con lo reportado en literatura, donde el uso combinado de DIC y MEF ha demostrado ser una estrategia eficaz para caracterizar el comportamiento mecánico real de los materiales [51]

El análisis comparativo entre DIC y MEF confirma que ambas metodologías son complementarias. El DIC ofrece un enfoque experimental preciso para validar los desplazamientos y deformaciones medidos en laboratorio, mientras que el MEF aporta un marco predictivo capaz de simular condiciones más complejas. La integración de ambas técnicas permite no solo validar modelos, sino también optimizar parámetros de simulación y mejorar el diseño estructural en aplicaciones de ingeniería y manufactura.

2.13.5 Aplicación de la Correlación Digital de Imágenes en Problemas de Contacto

En el proyecto Aplicación de la Correlación Digital de Imágenes en Problemas de Contacto [54] se presenta una aplicación de la técnica DIC para el análisis de un problema de contacto bidimensional entre dos superficies: una plana de policarbonato y un indentador semicircular de bronce. El estudio demuestra la eficacia del DIC para caracterizar la distribución de desplazamientos y deformaciones, validando los resultados frente a un modelo numérico basado en el MEF.

Para el ensayo experimental, las probetas se prepararon aplicando una base de pintura blanca y un moteado aleatorio negro que permite el contraste necesario para el análisis DIC. El montaje experimental consistió en una máquina universal de ensayos electromecánicos Instron, aplicando una carga de compresión de 1200 N a una velocidad de 100 N/s durante 12 segundos.

El material de la superficie plana fue policarbonato (Makrolón, espesor 4 mm), mientras que el indentador semicircular fue de bronce, considerado como rígido respecto al policarbonato. El registro de imágenes se realizó con una cámara Dispositivo de Carga Acoplada (CCD) de 8 bits a 15 fps, utilizando iluminación LED para mejorar el contraste.

El análisis se efectuó mediante el software Vic-2D, configurando facetas de 55×55 píxeles y un decalaje de 5 píxeles. Paralelamente, se desarrolló un modelo numérico en SolidWorks® empleando elementos tipo shell para comparar los resultados experimentales y numéricos.

Los resultados experimentales obtenidos mediante DIC se compararon con el análisis numérico por MEF. Ambos métodos mostraron una alta concordancia en:

- Desplazamientos en la dirección Y: los resultados DIC y MEF presentaron valores similares de indentación máxima, confirmando la validez del ensayo.
- Deformaciones unitarias: en el policarbonato se observaron las mayores deformaciones, mientras que en el indentador de bronce estas fueron prácticamente nulas, coherente con su mayor rigidez relativa.
- Comparación global: la técnica DIC logró capturar de manera precisa los campos de desplazamiento y deformación en la zona de contacto, corroborando su aplicabilidad en este tipo de problemas mecánicos.

El estudio confirma que la técnica de Correlación Digital de Imágenes en 2D es adecuada para el análisis experimental de problemas de contacto. La comparación con los resultados obtenidos por Elementos Finitos evidenció una concordancia significativa, lo que valida la DIC como una alternativa experimental confiable. Asimismo, la investigación resalta el potencial de la técnica para complementar modelos numéricos, ampliar el entendimiento del comportamiento de materiales y validar hipótesis en mecánica de contacto.

CAPÍTULO 3.

MARCO METODOLÓGICO

Para el desarrollo del proyecto que integra la presente tesis se hace uso de la mezcla de dos metodologías, la primera es la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) y la metodología SCRUM, ya que la primera es ideal para proyectos de ciencia de datos y machine learning y la segunda permite integrar una estructura ágil para gestionar tareas, sprints y entregables iterativos.

3.1 Metodología CRISP-DM

La metodología CRISP-DM (Cross Industry Standard Process for Data Mining) es uno de los modelos más utilizados para el desarrollo de proyectos de minería de datos y ciencia de datos. Fue propuesta a finales de la década de 1990 por un consorcio europeo que incluía a empresas como DaimlerChrysler, SPSS y NCR, con el objetivo de establecer un estándar industrial que fuera flexible y adaptable a distintos contextos y sectores [41].

Este enfoque proporciona una guía estructurada para planificar, ejecutar y evaluar proyectos de análisis de datos, asegurando que las soluciones generadas estén alineadas con los objetivos de negocio y que el conocimiento extraído sea útil para la toma de decisiones. CRISP-DM se caracteriza por ser iterativo y cíclico, permitiendo revisitar fases anteriores cuando se detectan necesidades de mejora o ajustes [39].

3.1.1 Fases de la metodología CRISP-DM

La metodología CRISP-DM se compone de 6 fases las cuales ayudan a llevar un análisis mas detallado de la problemática en cuestión, permitiendo que cada que se avanza en cada una de ellas se pueda tener un acercamiento al resultado esperado. A continuación se enlistan las fases de las que se integra la metodología:

1. Comprensión del negocio. El primer paso consiste en comprender los objetivos y necesidades del negocio. Aquí se definen los problemas a resolver, el alcance del proyecto y los criterios de éxito. Esta fase es crítica, ya que un mal entendimiento de los objetivos empresariales puede llevar a un análisis ineficaz [41].
2. Comprensión de los datos. Implica recolectar datos iniciales, analizarlos de manera exploratoria y detectar problemas como valores atípicos, datos faltantes o inconsistencias. También se evalúa la calidad de los datos y su pertinencia respecto a los objetivos planteados [39].
3. Preparación de los datos. En esta fase se transforman y limpian los datos para que puedan ser utilizados por los algoritmos de modelado. Incluye la integración de fuentes de datos, creación de nuevas variables y selección de atributos relevantes [40].
4. Modelado. Se aplican técnicas estadísticas o de aprendizaje automático para generar modelos predictivos o descriptivos. Es común ajustar parámetros y probar varios algoritmos para seleccionar el más adecuado según las métricas definidas [40].
5. Evaluación. Antes de implementar, se evalúa el modelo para confirmar que cumple con los objetivos del negocio y ofrece resultados fiables. No solo se analizan métricas técnicas, sino también su aplicabilidad práctica [41].
6. Despliegue. Consiste en poner en funcionamiento el modelo o sistema resultante. El despliegue puede ser un informe, una herramienta interactiva o una integración en un sistema productivo. También incluye monitoreo y mantenimiento [39].

A continuación, en la Figura 6 se muestra un diagrama de las fases y la interacción de las de las mismas dentro de la metodología CRISP-DM




Figura 6. Fases de la metodología CRISP-DM

La metodología CRISP-DM se ha consolidado como un estándar de facto para el desarrollo de proyectos de minería de datos y ciencia de datos debido a su estructura clara, su adaptabilidad y su orientación a los objetivos empresariales. Al fomentar la iteración y la validación constante, ayuda a minimizar riesgos y maximizar el valor de los resultados obtenidos. En un entorno empresarial cada vez más basado en datos, CRISP-DM se mantiene vigente como un marco metodológico confiable y probado.

3.2 Metodología SCRUM

En el ámbito del desarrollo de software y la gestión de proyectos, los enfoques ágiles han ganado gran relevancia debido a su capacidad para adaptarse a entornos cambiantes y entregar valor de forma incremental. Entre ellos, Scrum se ha consolidado como uno de los marcos de trabajo más populares y efectivos para el desarrollo ágil. Este marco promueve la colaboración, la transparencia y la entrega continua, permitiendo que los equipos respondan de manera flexible a las necesidades del cliente y a los cambios en los requisitos [45].

Scrum se basa en un ciclo iterativo e incremental, en el que el trabajo se organiza en períodos cortos y fijos denominados sprints. Cada sprint produce un incremento del producto que es potencialmente entregable. La metodología enfatiza la autoorganización de los equipos y la comunicación constante con los interesados, reduciendo riesgos y mejorando la calidad del producto final [44].

Al ser Scrum una metodología ágil se fundamenta en tres pilares [45]:

- Transparencia: Todos los aspectos del proceso deben ser visibles para quienes participan en el proyecto.
- Inspección: Se revisa regularmente el progreso y el producto para identificar posibles desviaciones.
- Adaptación: Se realizan ajustes rápidos cuando se detectan problemas o se identifican oportunidades de mejora.

Estos principios se apoyan en valores como compromiso, coraje, foco, apertura y respeto, que guían el comportamiento del equipo y fomentan una cultura de colaboración [43]. Además, en esta metodología se definen 3 roles que se deben cumplir para un buen funcionamiento de la misma los cuales se mencionan en seguida:

1. Product Owner: Responsable de maximizar el valor del producto y gestionar el Product Backlog.
2. Scrum Master: Facilita la comprensión y aplicación de Scrum, eliminando impedimentos y asegurando que el equipo siga las prácticas ágiles.
3. Development Team: Grupo autoorganizado y multifuncional que desarrolla el producto.

Scrum estructura su flujo de trabajo en una serie de eventos con objetivos definidos:

- a) Sprint: Ciclo de trabajo fijo (1 a 4 semanas) en el que se desarrolla un incremento de producto.
- b) Sprint Planning: Planificación del trabajo que se realizará en el sprint.
- c) Daily Scrum: Reunión diaria de 15 minutos para sincronizar el trabajo y planificar las próximas 24 horas.
- d) Sprint Review: Revisión del incremento al final del sprint con el stakeholder.
- e) Sprint Retrospective: Reunión para identificar mejoras en el proceso y la colaboración del equipo (Rubin, 2013).

Una característica de Scrum es que utiliza tres artefactos principales para gestionar el trabajo[45]:

- Product Backlog: Lista priorizada de requisitos del producto.
- Sprint Backlog: Conjunto de elementos seleccionados para el sprint actual.
- Incremento: Versión del producto resultante del sprint, lista para su entrega.

A continuación en la Figura 7 se muestra la estructura de la metodología Scrum




Figura 7 Estructura de la metodología Scrum

Por lo tanto, Scrum es más que una metodología; es un marco de trabajo que fomenta la colaboración, la adaptabilidad y la entrega continua de valor. Su enfoque iterativo e incremental permite enfrentar la incertidumbre y los cambios de forma eficaz, garantizando que el producto final responda mejor a las necesidades del cliente. Gracias a su simplicidad y eficacia, Scrum se ha extendido más allá del desarrollo de software, aplicándose en sectores como marketing, investigación y gestión empresarial [43]. Implementar Scrum requiere compromiso con sus valores y principios, así como disciplina para seguir su estructura, pero sus beneficios en productividad, calidad y satisfacción del cliente lo convierten en una herramienta esencial para la gestión ágil de proyectos.

La mezcla de ambas metodologías permite realizar un proyecto más sólido ya que se retoman las características mas importantes de cada una. La metodología CRISP-DM aporta estructura al proceso de machine learning destacando en la capacidad de comprender el problema y los datos, preparar los datos para el modelo, diseñar y evaluar el modelo e implementar la solución. Esto es esencial para proyectos donde el conocimiento se construye a partir de los datos y de la metodología Scrum aporta agilidad, foco y mejora continua ya que permite trabajar en sprints cortos para probar ideas rápidamente, tener revisiones frecuentes para ajustar el rumbo, mantener un backlog claro de tareas, adaptarte a nuevos hallazgos o cambios en los datos, Esto es clave en proyectos de machine learning, donde los resultados no siempre son predecibles y se requiere iterar. A continuación, en la Tabla 3. Se muestra la manera en que ambas metodologías pueden integrarse:

CRISP-DM (fase)	Scrum (Aplicación)
Comprensión del negocio	Sprint 0: definición de objetivos y backlog inicial
Comprensión de los datos	Sprint 1: exploración y limpieza de datos
Preparación de los datos	Sprint 2: transformación y división de datos
Modelado	Sprint 3 – 4: diseño, entrenamiento y ajuste de la red neuronal
Evaluación	Sprint 5: validación del modelo y visualización de resultados
Implementación	Sprint 6: empaquetado del modelo y evaluación final

Tabla 3. Combinación de las metodologías CRISP-DM y Scrum

Los beneficios que trae consigo la combinación de ambas metodologías es la claridad en el proceso técnico (CRISP-DM), la flexibilidad y velocidad de ejecución (Scrum), la Mejora continua basada en resultados reales, la Documentación y trazabilidad de decisiones y la adaptabilidad ante cambios en los datos o en los objetivos

CAPÍTULO 4.

APLICACIÓN DE LA METODOLOGÍA Y DISCUSIÓN DE RESULTADOS

4.1 Probeta de análisis

Para el desarrollo del proyecto con ayuda de una impresora 3D se fabricó una probeta de materias PET G mezclado con oxido de aluminio como se muestra en la Figura 6 se muestra primeramente la pieza recién salida de la impresora y posteriormente se muestra la pieza entintada para poder detectar de mejor manera lo moteado de la misma (protuberancias en la pieza), la cual se usará para poder realizar las pruebas de desgaste para su posterior análisis.




Figura 8. Probeta realizada en impresora 3D con PET G mezclado con oxido de aluminio

Posteriormente la probeta se somete a tensión en el equipo de Creep en tensión que se tiene en el TESCO dentro del Centro de Cooperación Academia Industria (CCAI) el cual se muestra en la Figura 7 y se toman fotografías en alta resolución en un intervalo variado de tiempo y por un tiempo determinado el cual puede variar desde 10 minutos (prueba corta) hasta 3 horas (prueba extendida).



Figura 9, Equipo de Creep en Tensión

Para poder hacer la prueba de tensión dentro del equipo de Creep en tensión, se coloca la probeta en la prensa y por medio de un gancho que contiene la base para integrarle pesas que le permitirán ejercer presión para ir dilatando de poco en poco la pieza e ir capturando por medio de las fotografías de alta resolución cada uno de los puntos para poder ser analizados posteriormente, A continuación, en la Figura 10, se muestra más a detalle lo anteriormente mencionado.



Figura 10, Tensión en la probeta

4.2 Análisis de las imágenes capturadas en la prueba de tensión.

Para poder realizar el análisis de las imágenes capturadas en la prueba de tensión por medio del equipo Creep, se desarrolló un software en el lenguaje Python el cual permite revisar una por una la totalidad de las imágenes obtenidas al momento de la realización de la prueba de tensión, A continuación, en la Figura 11 se muestra la pantalla principal del programa.




Figura 11. Pantalla principal del programa

Como primer paso lo que se debe hacer es seleccionar las imágenes que se capturaron al momento de realizar la prueba de tensión, para lo cual daremos clic en el botón que tiene la leyenda “Seleccionar Carpeta con Imágenes”, lo cual nos abrirá un cuadro de dialogo el cual nos permitirá dirigirnos a la carpeta que contiene las imágenes capturadas anteriormente. A continuación, en la Figura 12 se muestra el este paso.




Figura 12. Selección de la carpeta con las imágenes capturadas

Al seleccionar la carpeta de las imágenes se muestra una imagen como se muestra en la Figura 13, la cual corresponde a la primera imagen tomada al momento de realizar la prueba de tensión y que servirá para ir haciendo la comparación con todas las demás imágenes obtenidas.




Figura 13. Primera imagen capturada

Posteriormente hay que seleccionar una carpeta dando clic en el botón “Seleccionar Carpeta de Salida”, que es donde se almacenaran las imágenes una vez procesadas, al realizar la acción anterior se mostrara un mensaje confirmando la ruta donde se almacenaran las imágenes una vez que han sido procesadas. En seguida en la Figura 14 se muestra un ejemplo del mensaje de alerta que se muestra.




Figura 14, Mensaje de alerta que indica la ruta de la carpeta de salida

Una vez seleccionada la carpeta de salida se tiene que establecer el ROI que es el área de la probeta en la que se va a basar el análisis y tiene una forma de rectángulo, esta acción se puede realizar dando clic en el botón “Establecer el ROI”, lo cual no aparecerá una pantalla con la imagen y podremos trazar un rectángulo solo arrastrando el mouse y aparecerá un rectángulo de color verde para indicar el área de interés. En la Figura 15 se muestra la pantalla para poder establecer el ROI



Figura 15, Establecimiento del ROI

Una vez trazado el rectángulo indicando el área de interés a analizar en la imagen solo debemos de oprimir la tecla Enter lo cual cerrara la ventana y mostrara un mensaje indicando que el ROI se estableció en un polígono de 4 puntos como se muestra en la Figura 16.




Figura 16. Mensaje que indica que el ROI se establecio

Una vez establecido el ROI, ahora se debe establecer la escala la cual se realiza dando clic en el botón “Establecer Escala”, lo cual aparecerá una pantalla similar a la anterior, pero en esta ocasión solo debemos trazar una línea horizontal para indicar el ancho del área en cuestión, lo cual se realiza simplemente arrastrando el mouse del lado izquierdo al derecho como se muestra en la Figura 17.




Figura 17, Trazado de línea para establecer la escala.

Una vez establecida la escala, al soltar el mouse aparece una pequeña ventana donde nos indica que coloquemos el valor al que corresponde la línea trazada en milímetros y que en este caso corresponde al ancho de la probeta que es de 6 milímetros, esta acción es de suma importancia ya que el software detecta en pixeles la distancia trazada anteriormente y se necesita hacer la conversión de milímetros a pixeles, para que los resultados sean más certeros. A continuación, en la Figura 18 se muestra los mensajes que permiten escribir la distancia en milímetros y su equivalente a pixeles.




Figura 18, Establecimiento y conversión de la escala

Una vez que se seleccionó la carpeta de origen de las imágenes, la carpeta de salida, se estableció el ROI y la escala ya se puede comenzar el procesamiento de todas las imágenes que se encuentran en la carpeta de origen, para ello solo se tiene que dar clic en el botón “Iniciar procesamiento”, lo cual ira comparando cada una de las imágenes con la primer imagen de la carpeta e ira graficando como se va realizando el desplazamiento en el eje de las X y en el eje de las Y para posteriormente ir realizando tres graficas en la parte de debajo de la pantalla, las cuales corresponden a cada uno de los ejes y la mezcla de ambas, lo cual se muestra en la Figura 19.




Figura 19. Procesamiento de las imágenes

Como puede observarse en la pantalla anterior se señalan de color rojo imagen por imagen los puntos analizados de color rojo y en la parte de debajo de la pantalla se va generando un grafica que corresponde al desplazamiento que hubo en cada uno de los puntos señalados tanto a lo ancho como a lo alto de cada uno. Y al terminar el procesamiento de todas las imágenes se muestra un mensaje que indica que los resultados se guardaron de manera adecuada en la carpeta de salida, dando como resultado varios archivos como se muestra en la Figura 20, los cuales contienen los datos para poder realizar un análisis más profundo.

Nombre	Fecha de modificación	Tipo	Tamaño
 deformaciones	12/08/2025 02:31 p. m.	Archivo de valores...	8 KB
 desplazamiento_horizontal	12/08/2025 10:13 a. m.	Archivo de valores...	9 KB
 desplazamiento_vertical	12/08/2025 10:13 a. m.	Archivo de valores...	9 KB
 graficas_resultados	12/08/2025 10:13 a. m.	Archivo PNG	421 KB
 metadata	12/08/2025 10:12 a. m.	Documento de te...	1 KB
 resultados_completos	12/08/2025 10:13 a. m.	Archivo de valores...	35 KB

Figura 20. Archivos como resultado del análisis.

Como puede observarse en el proceso del análisis de las imágenes el resultado es bastante favorable, pero el proceso de captura de las imágenes puede demorarse muchísimo y para que una prueba pueda llevarse de manera adecuada se requiere de toma de muestras prolongada de alrededor de 3 horas para obtener cerca de 200 imágenes para después poder procesarlas, lo que ocasiono que se buscara la manera de poder hacer una predicción de cómo podrían generarse las deformaciones en la probetas sometidas a la pruebas de tensión en Creep. Por lo que se tomó la decisión de desarrollar una aplicación mas que por medio de los datos arrojados y con el apoyo de una red neuronal se pudieran hacer predicciones sin necesidad de volver a someter una probeta de material similar a la toma de muestras que puede generar una gran inversión de tiempo.

4.3 Predicción de las deformaciones por medio de una red neuronal

Para poder realizar la predicción de las deformaciones por medio de una red neuronal se desarrolló una aplicación la cual toma como base y datos de entrada uno de los archivos que da como resultado la aplicación que permite realizar el análisis por medio de la comparación de imágenes y es el archivo deformaciones.csv el cual contiene las columnas Tiempo_s, Strain_XX y Strain_YY, los cuales corresponden a los datos arrojados que indican como se fue deformando la pieza con el paso del tiempo, A continuación en la Figura 21 se muestra el contenido del archivo.

	A	B	C
1	Tiempo_s	Strain_XX	Strain_YY
2	3.77341819	0	0
3	4.02827334	0.00010035	-4.48E-05
4	5.10808849	0.00010211	-0.00015673
5	5.28351617	0.00051087	0.00011222
6	5.3684752	-0.00017662	-0.00010641
7	5.46356154	0.00023991	3.84E-05
8	5.54820919	5.06E-06	5.57E-05
9	5.62841082	0.00083029	-0.00015908
10	5.71447372	0.00016577	-0.00010179
11	5.81817293	0.00026428	-0.00025363
12	5.91323996	4.46E-05	-0.00021256
13	6.00827956	0.00025057	0.00010649
14	6.36637926	0.00056824	-0.00018476
15	6.42344356	0.00022828	-0.00018488
16	6.48327375	3.44E-05	-0.00016007
17	6.55346465	-0.00013629	-0.00015557

Figura 21 Contenido del archivo deformaciones.csv

Para que el programa tenga un funcionamiento adecuado es necesario que las predicciones se realicen por medio del algoritmo de Burguers para polímeros, el cual se integra a la red neuronal para poder realizar las predicciones lo mas cercano a la realidad, para lo cual también se generó la aplicación que se va a explicar y de la cual en la Figura 22 se muestra su interfaz




Figura 22. Interfaz de la aplicación que predice los desplazamientos

Para el uso de esta aplicación lo primero que se debe hacer es seleccionar dar clic en el botón “Seleccionar el archivo .CSV” el cual nos abrirá un cuadro de dialogo que nos permitirá seleccionar el archivo “deformaciones.csv” que dio como resultado la aplicación anterior como se muestra en la Figura 23.




Figura 23. Selección del archivo deformaciones.csv

Una vez seleccionado el archivo en la sección de “Información del modelo” de la aplicación se muestra el contenido del archivo seleccionado, así como se muestra en la Figura 24 y dichos datos serán los que alimentarán a la red neuronal para poder realizar las predicciones.




Figura 24, Carga de los datos a la aplicación

Una vez cargados los datos el siguiente paso es dar clic en el botón “Entrenar al modelo”, cual nos mostrará los datos en la misma sección, pero ahora aplicando el algoritmo de Burgers para polímeros y nos mostrará un resumen de los datos y posteriormente nos saldrá un mensaje de confirmación de que se entrenó la red neuronal de manera correcta aplicando el algoritmo antes mencionado. En seguida, se muestra el resultado de la acción explicada anteriormente en la Figura 25.




Figura 25. Entrenamiento del modelo

Ahora para poder realizar las predicciones se tiene que dar clic en el botón “Realizar predicciones”, lo que provocará que se muestre una ventana emergente la cual solicitará que se escriba a cuántos segundos se quiere hacer la predicción, acción que se muestra a continuación, en la Figura 26.




Figura 26. Asignación del tiempo para predicción

Una vez escrito el número de segundos a los que se quiere realizar la predicción la aplicación muestra un mensaje que los datos están guardados en el archivo datos predichos, el cual contiene la información que da como resultado del trabajo de la red neuronal tal cual como se muestra en la Figura 27.




Figura 27. Mensaje de datos cargados al nuevo archivo

Una vez realizada la acción anterior solo resta dar clic en el botón “Mostrar graficas” lo cual provocará que se muestre una nueva pantalla con las graficas en los desplazamientos en X y Y con base en el tiempo introducido, así como se puede observar en la Figura 28.




Figura 28, Grafica con los datos predecidos

Como pudo observarse en esta aplicación que es complementaria a la primera se puede hacer ya una predicción de cómo se comportarían las probetas, sin necesidad de invertir demasiado tiempo en estar tomando las imágenes, además de hacer un cálculo más eficiente basado el algoritmo de Burgers para polímeros, por lo tanto, es posible que por medio de una red neuronal se pueda predecir cual sería el resultado si llevamos la prueba a un tiempo más amplio sin necesidad de invertirlo en la realidad.

CAPÍTULO 5.

CONCLUSIONES Y PERSPECTIVAS PARA TRABAJOS FUTUROS

5.1 Conclusiones

Como se pudo observar a lo largo del desarrollo de este trabajo, es posible realizar la comparación de imágenes para poder determinar el desgaste que sufren diversas piezas que en este caso fue construida por medio de una impresora 3D y con una mezcla de PETG con aluminio, la cual fue sometida a tensión por medio de un equipo de creep en tensión y que a su vez se tomaron fotografías para después poder compararlas por medio de una aplicación desarrollada en Python.

La primera aplicación que se muestra es capaz de poder comparar una serie de imágenes procesándolas para poder ir verificando una a una la misma sección verificando como se va realizando el desgaste de la pieza a lo largo del tiempo comparando ciertos puntos y formas propias de la pieza midiendo el ancho y alto de cada uno midiendo como se va deformando y generando datos en un archivo de Excel para poder hacer un estudio posterior.

A lo largo de la investigación se pudo observar que se podía llegar más allá y se generó una segunda aplicación que permitiera por medio de una red neuronal el poder hacer una predicción de cómo podría ser la deformación de los materiales sin necesidad de invertir tanto tiempo en la captura de las imágenes y la fabricación de nuevas piezas por medio de la impresión 3D.

En cuanto a los resultados de la segunda aplicación es necesario que la red neuronal sea entrenada con más tiempo y diferencia de datos, ya que actualmente para poder observar por medio de las gráficas como es que se va desarrollando el desgaste de las piezas de mejor manera es con una cantidad pequeña de datos, ya que al introducir una cantidad grande de datos la gráfica se incrementa de manera secuencial, ya que en la realidad al seguir sometiendo a tensión la pieza esta seguirá deformándose de manera cíclica hasta una deformación total.

Por lo tanto, se puede concluir que los objetivos planteados en la presente Tesis fueron cumplidos por medio de las herramientas utilizadas y propuestas, ya que apoyan en el estudio de cómo se van deformando los materiales que pueden ser estudiados con la técnica de creep en tensión y que con el apoyo de las herramientas propuestas se puede inferir que tipo de mezclas de PETG se podrían utilizar en la creación de piezas para diversos sectores indicando la resistencia que tendrían en cuanto a tensión se refiere.

5.2 Perspectivas para trabajos futuros

Para trabajos futuros una recomendación sería hacer un estudio similar al propuesto en esta Tesis con diferentes mezclas de materiales para que dependiendo el uso que pueda darse a estos se pueda hacer una recomendación para la creación de piezas en la industria y que se tendrá una certeza de la durabilidad que tendrán estas una vez que se encuentren funcionando cotidianamente.

Por otro lado, en cuanto a la red neuronal que está integrada en la segunda aplicación se recomienda un entrenamiento de la misma con diferentes variantes de los datos y con mayor tiempo en el mismo, para que los resultados que pueda arrojar el funcionamiento de la misma sean cada vez más certeros y cercanos a la realidad.

REFERENCIAS

- [1] Gibson, I., Rosen, D. W., & Stucker, B. (2015). Additive Manufacturing Technologies: 3D Printing, Rapid Prototyping, and Direct Digital Manufacturing. Springer. (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4939-2113-3>
- [2] Everton, S. K., Hirsch, M., Stravroulakis, P., Leach, R. K., & Clare, A. T. (2016). Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing. *Materials & Design*, 95, 431–445.
- [3] Zhang, X., Jiang, R., & Yao, X. (2021). Vision-based defect detection for 3D printed components: A review. *Additive Manufacturing*, 47, 102375.
- [4] Sutton, M. A., Orteu, J.-J., & Schreier, H. W. (2009). Image Correlation for Shape, Motion and Deformation Measurements: Basic Concepts, Theory and Applications. Springer.
- [5] Lu, Y. (2017). Industry 4.0: A survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, 1–10.
- [6] ISO/ASTM. (2021). ISO/ASTM 52900:2021 Additive manufacturing — General principles — Fundamentals and vocabulary. International Organization for Standardization.
- [7] Ngo, T. D., Kashani, A., Imbalzano, G., Nguyen, K. T. Q., & Hui, D. (2018). Additive manufacturing (3D printing): A review of materials, methods, applications and challenges. *Composites Part B: Engineering*, 143, 172–196. <https://doi.org/10.1016/j.compositesb.2018.02.012>
- [8] Gebler, M., Schoot Uiterkamp, A. J. M., & Visser, C. (2014). A global sustainability perspective on 3D printing technologies. *Energy Policy*, 74, 158–167. <https://doi.org/10.1016/j.enpol.2014.08.033>
- [9] Berman, B. (2012). 3-D printing: The new industrial revolution. *Business Horizons*, 55(2), 155–162. <https://doi.org/10.1016/j.bushor.2011.11.003>
- [10] Chua, C. K., Leong, K. F., & Lim, C. S. (2010). Rapid prototyping: Principles and applications (3rd ed.). World Scientific Publishing.
- [11] Ford, S., & Despeisse, M. (2016). Additive manufacturing and sustainability: An exploratory study of the advantages and challenges. *Journal of Cleaner Production*, 137, 1573–1587. <https://doi.org/10.1016/j.jclepro.2016.04.150>

- [12] Jones, R., Haufe, P., Sells, E., Iravani, P., Olliver, V., Palmer, C., & Bowyer, A. (2011). RepRap – the replicating rapid prototyper. *Robotica*, 29(1), 177–191. <https://doi.org/10.1017/S026357471000069X>
- [13] Boschetto, A., & Bottini, L. (2016). Roughness prediction in coupled operations of fused deposition modeling and barrel finishing. *Journal of Materials Processing Technology*, 231, 491–498. <https://doi.org/10.1016/j.jmatprotec.2015.12.035>
- [14] Górski, F., Wichniarek, R., Kuczko, W., & Żukowska, M. (2017). Influence of printing parameters on dimensional accuracy and mechanical strength of parts fabricated using fused deposition modeling technology. *Advances in Science and Technology Research Journal*, 11(4), 150–157. <https://doi.org/10.12913/22998624/80758>
- [15] Reinhart, G., Teufelhart, S., & Maisch, M. (2021). Automated optical inspection in additive manufacturing using image comparison algorithms. *Procedia CIRP*, 96, 165–170. <https://doi.org/10.1016/j.procir.2021.01.065>
- [16] Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), 679–698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- [17] Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- [18] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>
- [19] Szeliski, R. (2022). *Computer vision: Algorithms and applications* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-030-34372-9>
- [20] Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- [21] Beazley, D. M. (2009). *Python Essential Reference* (4th ed.). Addison-Wesley Professional.
- [22] Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal of Software Tools*.
- [23] Krawetz, N. (2009). Looks Like It. *Hacker Factor Blog*. <https://www.hackerfactor.com/blog/index.php/?archives/432-Looks-Like-It.html>
- [24] Lutz, M. (2013). *Learning Python* (5th ed.). O'Reilly Media.
- [25] Martelli, A., Ravenscroft, A., & Ascher, D. (2017). *Python Cookbook* (3rd ed.). O'Reilly Media.

- [26] Van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., ... & Yu, T. (2014). scikit-image: image processing in Python. *PeerJ*, 2, e453. <https://doi.org/10.7717/peerj.453>
- [27] Van Rossum, G., & Drake, F. L. (2009). *Python 3 Reference Manual*. CreateSpace
- [28] ASTM D2990-17. (2017). *Standard Test Methods for Tensile, Compressive, and Flexural Creep and Creep-Rupture of Plastics*. ASTM International. <https://doi.org/10.1520/D2990-17>
- [29] Callister, W. D., & Rethwisch, D. G. (2020). *Materials Science and Engineering: An Introduction* (10th ed.). Wiley.
- [30] Ferry, J. D. (1980). *Viscoelastic Properties of Polymers* (3rd ed.). Wiley.
- [31] Strong, A. B. (2006). *Plastics: Materials and Processing* (3rd ed.). Pearson Prentice Hall.
- [32] Ward, I. M., & Sweeney, J. (2012). *An Introduction to the Mechanical Properties of Solid Polymers* (2nd ed.). Wiley.
- [33]. Gibson, I., Rosen, D., & Stucker, B. (2021). *Additive Manufacturing Technologies: 3D Printing, Rapid Prototyping, and Direct Digital Manufacturing* (3rd ed.). Springer. <https://doi.org/10.1007/978-3-030-56127-7>
- [34] Yao, X., Zhang, Y., & Wang, Y. (2020). Vision-based quality inspection in 3D printing: A review. *IEEE Transactions on Instrumentation and Measurement*, 69(11), 8700–8715. <https://doi.org/10.1109/TIM.2020.2984079>
- [35]. Bradski, G. (2000). *The OpenCV Library*. Dr. Dobb's Journal of Software Tools.
- [36] Kwon, Y., Lee, H., & Kim, S. (2021). Real-time detection of displacement defects in FDM printing using image processing. *Journal of Manufacturing Processes*, 68, 190–199. <https://doi.org/10.1016/j.jmapro.2021.05.019>
- [37] Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación* (6.^a ed.). McGraw-Hill.
- [38] Schreier, H., Ortu, J. J. & Sutton, M. A. (2009). *Image Correlation for Shape, Motion and Deformation Measurements*. University of South Carolina [Columbia] & ICA - Institut Clément Ader. <https://doi.org/10.1007/978-0-387-78747-3>
- [39] Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc.

- [40] Han, J., Kamber, M., & Pei, J. (2012). Data mining: Concepts and techniques (3rd ed.). Morgan Kaufmann.
- [41] Wirth, R., & Hipp, J. (2000). CRISP-DM: Towards a standard process model for data mining. In Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining (pp. 29–39).
- [42] Cohn, M. (2010). Succeeding with Agile: Software Development Using Scrum. Addison-Wesley Professional.
- [43] Denning, S. (2016). The Age of Agile: How Smart Companies Are Transforming the Way Work Gets Done. AMACOM.
- [44] Rubin, K. S. (2013). Essential Scrum: A Practical Guide to the Most Popular Agile Process. Addison-Wesley.
- [45] Schwaber, K., & Sutherland, J. (2020). The Scrum Guide. Scrum.org. Recuperado de <https://scrumguides.org>
- [46] Pan, B., Qian, K., Xie, H., & Asundi, A. (2009). Two-dimensional digital image correlation for in-plane displacement and strain measurement: a review. Measurement Science and Technology, 20(6), 062001. <https://doi.org/10.1088/0957-0233/20/6/062001>
- [47] Sutton, M. A., Orteu, J. J., & Schreier, H. (2009). Image correlation for shape, motion and deformation measurements: Basic concepts, theory and applications. Springer. <https://doi.org/10.1007/978-0-387-78747-3>
- [48] Pan, B. (2018). Digital image correlation for surface deformation measurement: historical developments, recent advances and future goals. Measurement Science and Technology, 29(8), 082001. <https://doi.org/10.1088/1361-6501/aac55b>
- [49] Schreier, H. W., & Sutton, M. A. (2002). Systematic errors in digital image correlation due to undermatched subset shape functions. Experimental Mechanics, 42(3), 303–310. <https://doi.org/10.1007/BF02410987>
- [50] RuYangNU. (2022). Deep-DIC: Deep Learning-Based Digital Image Correlation for End-to-End Displacement and Strain Measurement [Repositorio GitHub]. Recuperado de <https://github.com/RuYangNU/Deep-Dic-deep-learning-based-digital-image-correlation>
- [51] Yang, R., Li, Y., Zeng, D., & Guo, P. (2021). Deep DIC: Deep Learning-Based Digital Image Correlation for End-to-End Displacement and Strain Measurement. arXiv preprint. <https://arxiv.org/abs/2110.13720>

- [52] Yang, R., Li, Y., Zeng, D., & Guo, P. (2022). Deep DIC: Deep learning-based digital image correlation for end-to-end displacement and strain measurement. *Journal of Materials Processing Technology*, 302, 117474.
<https://doi.org/10.1016/j.jmatprotec.2021.117474>
- [53] Castro Sánchez M. E. (2018). Análisis comparativo de desplazamientos por medio de la digitalización de imágenes y el análisis del elemento finito en componentes mecánicos [Tesis de Maestría, Universidad Autónoma de Baja California], Repositorio institucional – Universidad Autónoma de Baja California
- [54]. López-Alba, E., López-García, R., Dorado, R., & Díaz, F. A. (2011). *Aplicación de correlación digital de imágenes para el análisis de problemas de contacto*. XIX Congreso Nacional de Ingeniería Mecánica, Asociación Española de Ingeniería Mecánica.