



**Modelamiento de la interdependencia de parámetros de proceso con las propiedades mecánicas  
de órtesis pasivas para articulación metacarpiana obtenidas vía FDM**

Toscano Castillo, Juan Diego

Departamento de Ciencias de la Energía y Mecánica

Carrera de Ingeniería Mecánica

Trabajo de titulación, previo a la obtención del título de Ingeniero Mecánico

Ing. Castellanos Villa, Santiago David PhD.

1 de septiembre del 2021

## Urkund Analysis Result

**Analysed Document:** Tesis Toscano.pdf (D111898431)  
**Submitted:** 9/1/2021 3:55:00 AM  
**Submitted By:** vaerazo@utn.edu.ec  
**Significance:** 2 %



### Sources included in the report:

<https://es.wikipedia.org/wiki/%C3%93rtesis>  
<https://revistas.udem.edu.co/index.php/ingenierias/article/download/2819/3150/>  
<https://www.redalyc.org/journal/944/94459796005/html/>

### Instances where selected sources appear:

8



**DEPARTAMENTO DE CIENCIAS DE LA ENERGÍA Y MECÁNICA  
CARRERA DE INGENIERÍA MECÁNICA**

**CERTIFICACIÓN**

Certifico que el trabajo de titulación, **“Modelamiento de la interdependencia de parámetros de proceso con las propiedades mecánicas de órtesis pasivas para articulación metacarpiana obtenidas vía FDM”** fue realizado por el señor **Toscano Castillo, Juan Diego** el cual ha sido revisado y analizado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 1 de septiembre de 2021

Firma:



.....  
**Ing. Castellanos Villa, Santiago David. PhD**  
C. C1716962608



**DEPARTAMENTO DE CIENCIAS DE LA ENERGÍA Y MECÁNICA  
CARRERA DE INGENIERÍA MECÁNICA**

**RESPONSABILIDAD DE AUTORÍA**

Yo, **Toscano Castillo, Juan Diego**, con cédula de identidad N° 1723296149, declaro que el contenido, ideas y criterios del trabajo de titulación: **“Modelamiento de la interdependencia de parámetros de proceso con las propiedades mecánicas de órtesis pasivas para articulación metacarpiana obtenidas vía FDM”**, es de mi autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 1 de septiembre de 2020

Firmas:

.....  
**Toscano Castillo Juan Diego**

CI:1723296149



**DEPARTAMENTO DE CIENCIAS DE LA ENERGÍA Y MECÁNICA  
CARRERA DE INGENIERÍA MECÁNICA**

**AUTORIZACIÓN DE PUBLICACIÓN**

Yo, **Toscano Castillo Juan Diego** , con cedula de ciudadanía n° 1723296149, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **"Modelamiento de la interdependencia de parámetros de proceso con las propiedades mecánicas de órtesis pasivas para articulación metacarpiana obtenidas vía FDM"** en el Repositorio Institucional, cuyo contenido, ideas y criterios son miresponsabilidad.

**Sangolquí, 1 de septiembre de 2021**

Firmas:



.....  
**Toscano Castillo Juan Diego**  
Ci: 1723296149

## **Dedicatoria**

Dedico el presente trabajo de titulación a mi abuela Olga Mackliff y a mi madre Jacqueline Castillo quienes me apoyaron emocional y económicamente durante mi carrera universitaria.

Este título es completamente suyo.

**Juan Diego Toscano**

## **Agradecimiento**

Inicialmente deseo expresar mi agradecimiento al Ing. Luis Javier Segura, por brindarme su guía, tiempo y confianza durante la realización de los estudios que integran este proyecto. De igual manera, agradezco al tutor de este trabajo de titulación, Dr. Santiago Castellanos, por su vital colaboración para la culminación y presentación del mismo.

Gracias a mi madre, Jacqueline Castillo por su soporte incondicional, sacrificios, paciencia y enseñanzas, mismas que han sido fundamentales a lo largo de mi vida. Agradezco a mis abuelos, Olga Mackliff y Juan Castillo, dos ángeles que mientras me acompañaron, me proporcionaron soporte moral, emocional y económico.

También, agradezco a mi padre Bolivar Toscano, por su apoyo, cariño y respeto. A mis tíos Diego Castillo y Francisco Castillo, por darme posada en su casa y por ayudarme con los proyectos prácticos durante mi carrera de pregrado. A mi tía Elena, y al resto de mi familia.

Finalmente, quisiera agradecer a Dios por haber puesto en mi vida a personas maravillosas: maestros, familia y amigos que me han sido los pilares fundamentales a lo largo de mi vida.

**Juan Diego Toscano**

## Índice de Contenidos

Dedicatoria . . . . .	6
Agradecimiento . . . . .	7
Índice de Contenidos . . . . .	8
Índice de Tablas . . . . .	11
Índice de Figuras . . . . .	11
Resumen . . . . .	13
Abstract . . . . .	14
Capítulo I Introducción . . . . .	15
Título del Proyecto . . . . .	15
Unidad Académica Responsable . . . . .	15
Responsable del Proyecto . . . . .	15
Línea de Investigación . . . . .	15
Colaboradores Científicos . . . . .	16
Director del Proyecto . . . . .	16
Colaboradores Externos . . . . .	16
Localización Geográfica . . . . .	16
Área de Influencia . . . . .	16
Antecedentes . . . . .	17
Proyectos Relacionados o Complementarios . . . . .	20
Proyectos relacionados con la evolución de las órtesis y sus aplicaciones . . . . .	21
Proyectos relacionados con la evolución de la manufactura aditiva y de análisis de propiedades de proceso . . . . .	21



Proyectos relacionados con las propiedades mecánicas de las piezas obtenidas por	
FDM . . . . .	22
Justificación . . . . .	22
Alcance . . . . .	24
Objetivos . . . . .	25
Objetivo General . . . . .	25
Objetivos Específicos . . . . .	25
Organización del Proyecto . . . . .	26
Capítulo II Marco Teórico . . . . .	28
Manufactura Aditiva . . . . .	28
Modelado por deposición Fundida (FDM) . . . . .	28
Órtesis . . . . .	30
Tipos de Órtesis . . . . .	31
Órtesis no convencionales (NCCB) . . . . .	32
Optmización Topológica . . . . .	33
Machine Learning . . . . .	34
Supervised Learning . . . . .	34
Tipos de Variables . . . . .	34
Datos de Entrenamiento y Datos de Prueba . . . . .	35
Regresión y Clasificación . . . . .	36
Métodos de Regresión de ML . . . . .	36
Transfer Learning (TL) . . . . .	38
Domain Adaptation(DA) y Transfer Learning(TL) . . . . .	38
Métodos DA . . . . .	38
Capítulo III Modelamiento del FDM aplicando técnicas de Machine Learning . . . . .	41
Introducción . . . . .	41

Método . . . . .	43
Diseño, Fabricación, Modelamiento y Caracterización del MCB . . . . .	43
Maquina de FDM . . . . .	45
Sistema de Adquisición de Datos . . . . .	46
Pruebas Mecánicas . . . . .	47
Modelamiento . . . . .	47
Caso de Estudio . . . . .	48
Proceso FDM . . . . .	50
Resultados . . . . .	50
Resumen . . . . .	52
 Capítulo IV Análisis de Deformación de órtesis Metacarpofalangias e Interfalangias vía	
Transfer Learning . . . . .	55
Introducción . . . . .	55
Revisión Bibliográfica . . . . .	57
órtesis . . . . .	57
Deformación de las órtesis . . . . .	58
Domain Adaptation . . . . .	60
Método . . . . .	61
Caracterización del MCB . . . . .	62
Domain Adaptation . . . . .	63
Caso de Estudio . . . . .	63
Proceso FDM . . . . .	64
Resultados . . . . .	64
Resumen . . . . .	66
 Capítulo V Conclusiones y Trabajo Futuro . . . . .	
Conclusiones . . . . .	68

Trabajo Futuro . . . . .	69
Referencias . . . . .	70

### Índice de Tablas

<b>Tabla 1</b>	Diseño de Experimentos para las MCB de Tamaño Reducido . . . . .	49
<b>Tabla 2</b>	Error relativo de los modelos de ML utilizados . . . . .	52
<b>Tabla 3</b>	MAE y Desviación estándar del error en el TD . . . . .	66

### Índice de Figuras

<b>Figura 1</b>	Tipos de órtesis . . . . .	23
<b>Figura 2</b>	Organización del Trabajo de Titulación . . . . .	26
<b>Figura 3</b>	Impresión 3D por FDM . . . . .	29
<b>Figura 4</b>	Parámetros de proceso en FDM . . . . .	30
<b>Figura 5</b>	Esquema de los parámetros de proceso en FMD . . . . .	31
<b>Figura 6</b>	Órtesis obtenida por impresión 3D . . . . .	33
<b>Figura 7</b>	Proceso de obtención de una órtesis para brazo . . . . .	34
<b>Figura 8</b>	Relación entre variables de entrada y salida en machine learning . . . . .	35
<b>Figura 9</b>	Esquema representativo del Método TCA . . . . .	39
<b>Figura 10</b>	Proceso de FDM . . . . .	41
<b>Figura 11</b>	Método para el modelamiento del CS aplicando técnicas de ML . . . . .	44
<b>Figura 12</b>	Diseño, Fabricación, Modelamiento y Caracterización del MCB . . . . .	45
<b>Figura 13</b>	Esquema representativo del circuito utilizado en el Sistema de Adquisición de Datos . . . . .	47

<b>Figura 14</b>	Ensayos de Compresión . . . . .	48
<b>Figura 15</b>	Parámetros de Proceso . . . . .	48
<b>Figura 16</b>	Sistema DAQ . . . . .	50
<b>Figura 17</b>	Muestras Defectuosas MCB . . . . .	51
<b>Figura 18</b>	Ilustración de los resultados de ML . . . . .	53
<b>Figura 19</b>	Distribución de esfuerzos y tiempo de impresión de los MCB . . . . .	55
<b>Figura 20</b>	Tipo de Falla del MCB . . . . .	59
<b>Figura 21</b>	Esquema representativo de los tipos de deformación . . . . .	60
<b>Figura 22</b>	Método para el modelamiento de $\delta$ aplicando técnicas de DA . . . . .	62
<b>Figura 23</b>	Influencia de los predictores en $\delta$ para SD y TD . . . . .	65
<b>Figura 24</b>	Número de Observaciones en TD . . . . .	66

## Resumen

Una órtesis es un dispositivo diseñado para proporcionar inmovilización o apoyo a la zona lesionada del paciente durante el proceso de rehabilitación. Por su fabricación manual, las órtesis tradicionales generan problemas como desperdicio de material, poca ventilación, peso excesivo entre otras. Estos problemas se pueden solucionar parcialmente mediante la implementación de técnicas de manufactura aditiva. En el presente trabajo, se construyeron órtesis metacarpianas (MCB) aplicando modelado por deposición fundida. Para asegurar la funcionalidad de las MCB, se estudiaron sus propiedades mecánicas aplicando un enfoque basado en datos. Para la digitalización del miembro superior y la obtención del CAD se implementó el paquete Apple ARkit y técnicas de optimización topológica. Dado que la impresión de las MCB de tamaño completo requiere mucho tiempo se construyeron dos tipos de muestras, MCB de tamaño reducido y MCB de tamaño completo. En particular, se estudiaron tres parámetros de proceso (ancho de extrusión, altura de capa y temperatura de extrusión). Adicionalmente, se recopilaron varias mediciones in-situ a través de un sistema de adquisición de datos personalizado. Una vez construidas las MCB, se utilizó una máquina de ensayos universales para realizar pruebas de compresión y determinar la deformación total ( $\delta$ ) y la carga máxima resistida (CS) por las MCB. En la primera parte del estudio, se aplicaron tres técnicas de machine learning: Lasso, Random Forest y Support Vector Machine para modelar el CS de las MCB de tamaño reducido. Luego, se utilizaron técnicas de Transfer Learning para utilizar la información obtenida de las MCB de tamaño reducido en el modelamiento de  $\delta$  del MCB de tamaño completo. A partir del caso de estudio, se puede afirmar que el enfoque basado en datos es apto para el modelamiento el CS y el  $\delta$  de un MCB construido por FDM.

- Palabras clave:

- **ÓRTESIS**
- **MODELADO POR DEPOSICIÓN FUNDIDA**
- **MACHINE LEARNING**

## Abstract

A cast/brace is a tight garment that restricts movement and provides support to an injured zone. Traditional casts/braces suffer from material wastage, discomfort, patient dissatisfaction, odor, unnecessary weight, and dangerous extraction procedures. These issues can be solved partially by constructing the casts/braces via 3D printing. Toward this end, a personalized metacarpal casts/brace (MCB) was constructed via fused deposition modeling (FDM). Then, the part's mechanical properties were studied to ensure the desired functionality. To obtain the MCB CAD model Apple ARkit and topology optimization were implemented. However, printing the full-size MCB is time-consuming (it takes more than 11 hours for the proposed design), making it hard to collect a sufficient data set for the mechanical properties' investigation. Hence, reduced-size MCBs were used to facilitate the analysis. In particular, three scalar process parameters (i.e., extrusion width, layer height, and extrusion temperature), were studied and several in-situ measurements were collected via a customized sensing system. Later, a universal testing machine was used to measure the total deformation ( $\delta$ ) and resisted compressive load (CS) of the MCB. In the first part of the study, three machine learning methods, Lasso, random forest (RF), and support vector machine (SVM), were applied to the collected data to model the CS of the reduced-size MCB. Then, transfer learning techniques were used to leverage the information from the reduced-size MCB to model  $\delta$  of the full-size MCB. From the case study, the proposed data-driven approach can be used to successfully model the CS and the  $\delta$  of the MCB.

- Keywords:

- **CAST/BRACE**
- **FUSED DEPOSITION MODELING**
- **MACHINE LEARNING**

## Capítulo I

### Introducción

#### Título del Proyecto

Modelamiento de la Interdependencia de Parámetros de Proceso con las Propiedades Mecánicas de Órtesis para Articulaciones Metacarpofalángicas e Interfalángicas Obtenidas vía FDM.

#### Unidad Académica Responsable

Departamento de Ciencias de la Energía y Mecánica, Carrera de Ingeniería Mecánica.

#### Responsable del Proyecto

El responsable del proyecto es el señor TOSCANO CASTILLO JUAN DIEGO, estudiante de la carrera de Ingeniería Mecánica de la Universidad de las Fuerzas Armadas – ESPE. Teléfonos: +593983252957 e-mail: [jdtoscano@espe.edu.ec](mailto:jdtoscano@espe.edu.ec)

#### Línea de Investigación

Las líneas de investigación del proyecto son:

- Materiales y Técnicas de Producción
- Modelamiento Matemático

## **Colaboradores Científicos**

### ***Directores del Proyecto***

- Ing. Santiago David Castellanos Villa. PhD Universidad de las Fuerzas Armadas- ESPE, Ecuador.

### ***Colaboradores Externos***

- Hongyue Sun, PhD, Assistant Professor, University at Buffalo, the State University of New York.
- Ing. Luis Javier Segura Sangucho, Universidad de las Fuerzas Armadas- ESPE, Ecuador.
- Dr. Christian Oswaldo Segura Sangucho, Médico Cirujano de Ortopedia y Traumatología, Universidad Central del Ecuador.

## **Localización Geográfica**

El proyecto se realizará en el Departamento de Ingeniería Mecánica, específicamente en el laboratorio de procesos de manufactura y laboratorio de mecánica de materiales de la Universidad de las Fuerzas Armadas – Sangolquí-Pichincha- Ecuador.

## **Área de Influencia**

El modelado por deposición fundida, FDM por sus siglas en inglés, es un proceso de manufactura aditiva que tiene varias aplicaciones en el campo automotriz, bélico, médico, gastronómico entre otros (Andreas, 2011). En el Ecuador esta técnica se utiliza principalmente con fines publicitarios o en el desarrollo de figuras personalizadas como llaveros, pulseras, vasos, etc., sin



embargo, en los últimos años, se ha incursionado en el campo de la medicina. Por ejemplo, la empresa ECUAPROTESIS 3D se encarga del diseño y construcción de prótesis y otros productos de ortopedia para personas con capacidades físicas reducidas.

La variación de las propiedades mecánicas es un factor importante que determina la funcionalidad de las partes impresas (Mohamed y col., 2015), es por ello que determinar y reducir la variación de las mismas es fundamental para optimizar la calidad y funcionalidad de las partes (i.e., órtesis) impresas por FDM. La variabilidad en las propiedades mecánicas de las partes fabricadas son atribuida a una serie de parámetros de proceso (Mohamed y col., 2015). Los parámetros de proceso son un conjunto de variables y condiciones propias del material, de la máquina (i.e., su estructura y su configuración), y de las condiciones ambientales. Por esta razón, el análisis de los parámetros de proceso y la realización de mediciones in-situ (e.g., temperatura ambiente, vibraciones, humedad, etc.) es fundamental para determinar y controlar la calidad, repetitividad, y consistencia de las partes impresas. Actualmente, se han realizado varios estudios sobre las propiedades mecánicas de las piezas obtenidas por FDM, aplicando varias técnicas y aproximaciones como métodos experimentales, estadísticos y machine learning (Rayegani y Onwubolu, 2014).

Este proyecto pretende fundamentalmente aplicar algoritmos de machine learning para encontrar y entender las relaciones entre las propiedades mecánicas de Órtesis para articulaciones metacarpofalángicas e interfalángicas obtenidas vía FDM y los parámetros de proceso, es decir variables medidas in-situ y variables preestablecidas propias de la configuración de la máquina.

## **Antecedentes**

Tradicionalmente, el desarrollo de órtesis no convencionales ha sido de interés médico para evitar los problemas de las órtesis comúnmente usadas como férulas con yeso o fibra de vidrio. Entre los principales problemas se puede mencionar el peso excesivo, desperdicio de material, incomodidad, insatisfacción del paciente, etc. Así, Gebuhr et al., realizaron un estudio en el cual desarrollaron órtesis funcionales desmontables para el tratamiento de lesiones en el brazo. Este tipo

de órtesis fueron hechas de placas de polietileno superpuestas entre sí y aplicando esta técnica lograron reducir el peso de la órtesis y mejoraron el porcentaje aceptación y satisfacción de los pacientes (Gebuhr y col., 1992).

Con el desarrollo de la manufactura aditiva la construcción de piezas personalizadas se ha facilitado. Por ejemplo, Bernard et al., realizaron un análisis en el cual se describe el alcance del desarrollo de nuevos productos desde un punto de vista de diseño, en este se habla de la facilidad con la cual un objeto real se puede utilizar para realizar prototipos o réplicas con ayuda de escáneres 3D y manufactura aditiva (Bernard y Fischer, 2002).

En la actualidad una de las técnicas para la construcción de órtesis no convencionales es FDM, y su optimización en cuanto a utilidad y construcción ha sido de interés para medicina y la ingeniería. La aplicación de FDM permite la obtención de órtesis personalizadas. Fitzpatrick et al., diseñaron una órtesis para el brazo de un paciente específico con ayuda de un escáner 3D y luego la construyeron aplicando FDM (Fitzpatrick y col., 2017). En Ecuador, Andrade estudió el proceso de manufactura de férulas para el tratamiento de artritis de muñeca aplicando tecnología de impresión 3D y optimización topológica (Andrade, 2019). Otro estudio similar lo realizaron Zhang et al., quienes aplicaron la técnica de optimización topológica en el diseño de órtesis obtenidas por FMD basándose en superficies bidimensionales (Zhang y Kwok, 2019).

Para asegurar la calidad de los productos (i. e., piezas obtenidas por FDM), evitar las pérdidas de material, potenciar las tasas de productividad y reducir el tiempo y costo de producción, las propiedades mecánicas de la pieza obtenida tienen que ser controladas ya que afectan directamente a la funcionalidad y performance de las partes impresas. La calidad de las piezas o productos obtenidos por manufactura aditiva se relacionan con sus características (e.g., resistencia mecánica, acabado superficial, porosidad, precisión dimensional, etc.). Mohamed et al., determinaron que las características de la pieza obtenida están relacionadas con parámetros de proceso referentes a las condiciones ambientales y la configuración de la máquina con la que se realiza el proceso de manufactura (Mohamed y col., 2015). Un estudio similar lo realizaron Imani et al., quienes anali-

zaron el efecto de las condiciones de proceso (i.e., condiciones ambientales y configuración de la máquina) en la porosidad de piezas obtenidas por sinterizado laser selectivo (Imani y col., 2018).

Existen varias técnicas para determinar la interrelación entre los parámetros de proceso y las características de la pieza, una de estas es el análisis de elementos finitos como el realizado por Sheth et al., para estudiar la rigidez de piezas obtenidas por FDM en función de la orientación de la trama (i.e., parámetro de proceso) aplicando las herramientas computacionales SIMULIA y BSAM (Sheth y col., 2017). De igual manera Montero et al., realizaron un análisis en la tecnología de creación de prototipos rápidos, y definieron cuales fueron los parámetros de proceso más significativos (Montero y col., 2001). Otro tipo de enfoque, para el análisis de la relación previamente expuesta, es el modelamiento estadístico como el aplicado por Sood et al., quienes desarrollaron un modelo empírico para relacionar las propiedades mecánicas de partes obtenidas por FDM con los parámetros de proceso, analizando la resistencia a la flexión, tracción e impacto de la pieza (Sood y col., 2010).

Una de las más recientes técnicas con las que se puede determinar las relaciones existentes entre variables de proceso y las características que determinan la calidad y funcionalidad de partes producidas por manufactura aditiva y electrospinning, por ejemplo, es machine learning (Rao y col., 2015; Toscano y col., 2020). Toscano et al., realizaron un estudio en el cual modelaron la interdependencia de las variables de proceso (i.e., configuración de parámetros de la máquina) y mediciones in-situ en las características de un material biocompatible obtenido por eletrospinning aplicando tres técnicas de machine learning (Toscano y col., 2020). Otro estudio similar pero aplicado al proceso de fabricación de filamentos fundidos, FFF por sus siglas en ingles, fue realizado por Rao et al., quienes aplicaron machine learning y un sistema de instrumentación para determinar la influencia de mediciones in-situ de la temperatura y las vibraciones en la detección de defectos en el proceso de FFF (Rao y col., 2015).

Mohamed et al., definió que las propiedades mecánicas de las piezas realizadas de policarbonato también se ven influenciadas por los parámetros de proceso (Mohamed y col., 2015).

Masood et al., investigaron los efectos del estilo de construcción, espesor de la trama y ángulo de trama en las propiedades de tracción de PC y concluyeron que la resistencia a la tracción de los prototipos de PC dependía del estilo de construcción (Masood y col., 2010). Otro estudio similar lo realizaron Rayegani et al., quienes utilizaron técnicas de machine learning avanzado en la optimización de los parámetros para modelar el comportamiento de la resistencia a la tracción (Rayegani y Onwubolu, 2014). En relación a las propiedades mecánicas dinámicas Arivazhagan et al., presentaron una investigación experimental acerca de las propiedades mecánicas dinámicas de partes de ABS obtenidas por FDM y determinaron que el estilo de construcción sólido, generó mejores propiedades dinámicas. También se concluyó que con el incremento de la temperatura las propiedades mecánicas dinámicas tienden a decaer (Arivazhagan y Masood, 2012).

Finalmente, existen investigaciones en las cuales se habla del mejoramiento de las propiedades mecánicas de las piezas elaboradas por FDM. Percoco et al., investigaron la influencia de los tratamientos químicos en la resistencia a la compresión y el comportamiento mecánico de prototipos tratados obtenidos por FDM. En este estudio se investigó los efectos de tres parámetros de proceso y un tratamiento químico específico, en la resistencia a la compresión y concluyeron que con el control de las propiedades de proceso y con un tratamiento químico adecuado, es posible disminuir la rugosidad de la pieza hasta en un 90 % y mejorar sus propiedades mecánicas considerablemente (Percoco y col., 2012).

En los estudios antes mencionados se realiza el análisis de la influencia de los parámetros de proceso en las propiedades mecánicas de piezas obtenidas vía FDM. Sin embargo, estos estudios no consideran la geometría de las aplicaciones reales, dado que fueron realizados en probetas estandarizadas. Según Mohamed et al., la forma geométrica es otro parámetro de proceso que juega un papel fundamental en la calidad final de las piezas obtenidas vía FDM (Mohamed y col., 2015). Por lo cual, en el presente trabajo se pretende realizar el modelamiento de las propiedades mecánicas relacionándolas con los parámetros de proceso (i.e., medidas in-situ, y configuración de la máquina) en una aplicación real y funcional de FDM.

## **Proyectos Relacionados o Complementarios**

### ***Proyectos relacionados con la evolución de las órtesis y sus aplicaciones***

#### **Realizados en el exterior.**

- P. Gebuhr, P. Holmich, T. Orsnes, M. Soelberg, M. Krasheninnikoff y A. G. Kjersgaard, "Isolated ulnar shaft fractures. Comparison of treatment by a functional brace and long-arm cast.," The Journal of bone and joint surgery, vol. 74, 1992.
- M. V. Radomski y C. A. T. Latham, "Occupational therapy for physical dysfunction\*," Lippincott Williams & Wilkins, 2008.
- P. Fitzpatrick, M. I. Mohammed, P. K. Collins y I. Gibson, "Design of a patient specific, 3D printed arm cast," KnE Engineering, pp. 135-142, 2017.
- Y. Zhang y T. H. Kwok, "Customization and topology optimization of compression casts/braces on two-manifold surfaces," Computer-Aided Design, pp. 113-122, 2019.

#### **Realizados en Ecuador.**

- L. Andrade, "Manufactura de Férulas para el tratamiento de artritis de muñeca aplicando tecnología de impresión 3D," ESPE, 2019.

### ***Proyectos relacionados con la evolución de la manufactura aditiva y de análisis de propiedades de proceso***

#### **Realizados en el exterior.**

- F. Rayegani y G. C. Onwubolu, "Fused deposition modelling (FDM) process parameter prediction\* and optimization using group method for data handling (GMDH) and differential evolution (DE)," The International Journal of Advanced Manufacturing Technology, vol. 73, pp. 509-519., 2014.

- C. C. Wang, T. W. Lin, y S. S. Hu, "Optimizing the rapid prototyping process by integrating the Taguchi method with the Gray relational analysis," Rapid prototyping journal, 2007.
- F. Imani, A. Gaikwad, M. Montazeri, P. Y. H. Rao y E. Reutzel, "Layerwise in-process quality monitoring in laser powder bed fusion," In ASME 2018 13th International Manufacturing Science and Engineering Conference, 2018.
- P. K. Rao, J. P. Liu, D. Roberson y Z. J. Kong, "Sensor-based online process fault detection\* in additive manufacturing," ASME 2015 International Manufacturing Science and Engineering Conference, 2015.

#### **Realizados en Ecuador.**

- J. D. Toscano, S. Hajifar, C.O. Segura, J. Segura y H. Sun. (2021, June). Deformation Analysis of 3D Printed Metacarpophalangeal and Interphalangeal Joints via Transfer Learning. In International Manufacturing Science and Engineering Conference (Vol. 85062, p. V001T01A014). American Society of Mechanical Engineers.
- J. D. Toscano, Z. Li, L. J. Segura y H. Sun.(2020, September). A Machine Learning Approach to Model the Electrospinning Process of Biocompatible Materials. In International Manufacturing Science and Engineering Conference (Vol. 84263, p. V002T06A031). American Society of Mechanical Engineers.

#### ***Proyectos relacionados con las propiedades mecánicas de las piezas obtenidas por FDM***

#### **Realizados en el exterior.**


- S. H. Masood, K. Mau y W. Q. Song, "Tensile properties of processed FDM polycarbonate material," Materials Science Forum, vol. 654, pp. 2556-2559, 2010.

## Justificación

Una órtesis es un apoyo u otro dispositivo externo (aparato) aplicado al cuerpo para modificar los aspectos funcionales o estructurales del sistema neuromusculoesquelético (Levy y Barragán, 2003). Estos dispositivos tienen varios beneficios como mejorar la circulación en un área determinada, proteger la piel, controlar la temperatura, acelerar el proceso de recuperación en el caso de alguna lesión, mejorar el rendimiento, reducir el dolor y prevenir contracturas musculares (Zhang y Kwok, 2019). Cuando la función de la órtesis es postural o inmovilizadora, con la finalidad de prevenir, corregir o impedir deformidades, se las denomina órtesis pasivas.

### Figura 1

*Tipos de órtesis*



*Nota:* Órtesis para brazo: (a) Órtesis tradicional (Martínez, s.f.), (b) Órtesis funcionales desmontables (Gebuhr y col., 1992), y (c) Órtesis obtenidas por FDM (Mohamed y col., 2015).

A pesar que tiene muchos usos, las órtesis tradicionales (véase Figura 1(a)) se usan en una forma poco efectiva. La principal función de una órtesis es inmovilizar el cuerpo lesionado y brindar una compresión estable para el tratamiento, lo cuál requiere que estas prendas se ajusten al cuerpo del paciente. Sin embargo, los equipos tradicionales no se pueden ajustar de forma adecuada dado que son realizados manualmente por el ortopedista basado en su experiencia. Otra desventaja de las órtesis tradicionales es que el material del cual son realizados, excede la cantidad necesaria por lo cual existe mucho desperdicio, son pesados, no permiten la ventilación, y por ende son incómodos para los pacientes en su periodo de rehabilitación (Zhang y Kwok, 2019). A mas de esto, el procedimiento de extracción de ciertos tipos de órtesis pasivas, como las férulas

de fibra de vidrio o yesos, son complicados, ya que requieren la acción de equipos externos como sierras eléctricas o pinzas, lo cual aumenta el riesgo de posibles accidentes. Con la finalidad de solucionar los problemas generados por las órtesis tradicionales, se han generado varios tipos de alternativas como órtesis desmontables (véase Figura 1(b)) con las cuales se logra un tratamiento más focalizado y mayor comodidad por parte del paciente sin embargo en ciertos casos no se logra la sujeción adecuada (Gebuhr y col., 1992).

Con el crecimiento de la manufactura aditiva, se puede construir órtesis personalizadas basándose en la forma del cuerpo del paciente y de sus necesidades (Zhang y Kwok, 2019)(véase Figura 1(c)) que se puede utilizar para tratamientos incruentos de fracturas de miembro superior o como inmovilizador temporal, además sería de mucha utilidad en pacientes con patologías como síndrome de túnel carpiano, tendinitis de quervain, sinovitis de muñeca, tendinitis de los extensores o flexores de antebrazo. Sin embargo, para asegurar la funcionalidad de los productos, evitar las pérdidas de material, mejorar las tasas de productividad y reducir el tiempo y costo de producción, las propiedades mecánicas de las prendas obtenidas por AM tienen que ser controladas. Existen parámetros de proceso que caracterizan a las piezas obtenidas por AM. La calidad y las propiedades mecánicas de la pieza fabricada se pueden atribuir a la selección de los parámetros de proceso (Mohamed y col., 2015). FDM es un proceso AM complejo en el cual es difícil la selección óptima de los parámetros de proceso debido a la presencia de un gran número de parámetros que tienen conflictos entre sí. Por lo cual los estudios realizados sobre AM, acerca el diseño y la configuración de parámetros de proceso, usualmente tienen un enfoque fenomenológico, mas no físico, aplicando técnicas estadísticas como ANOVA, signal-to-noise ratio, machine learning calibración Bayesiana, entre otras (Li y col., 2018). Machine learning es un proceso que involucra un conjunto de técnicas o métodos con los cuales, a través de una regresión o clasificación, se puede determinar la influencia de un grupo de variables de entrada en una o más variables de salida (Hastie y col., 2009). Es decir, es una técnica con la cual se puede determinar la influencia de los parámetros de proceso en las propiedades mecánicas (i.e., predecir las propiedades mecánicas) de las órtesis pasivas obtenidas por FMD, logrando así mejorar su calidad, y disminuir los defectos mecánicos.



## **Alcance**

En el presente trabajo se obtendrá un modelo virtual de la mano, muñeca y parte del antebrazo utilizando el sistema de detección de puntos característicos de Apple y, un post procesamiento realizado en XCode, Meshlab y Meshmixer. A partir de este modelo, con ayuda del software FUSION 360, se realizará el diseño CAD de la órtesis pasiva para articulación metacarpiana y se realizará la optimización topológica del mismo. Una vez determinado el modelo CAD, se adecuará un sistema de sensores al equipo de FDM, y se los configurará aplicando Arduino. Posteriormente, se construirá un número adecuado de órtesis y a partir del proceso de impresión, utilizando el sistema de sensores, se obtendrán mediciones in-situ de temperatura, vibración y humedad. Finalmente, las propiedades mecánicas (deformación y carga máxima resistida) de las órtesis serán determinadas a partir de pruebas de compresión en una máquina de ensayos universales. Estas propiedades mecánicas, los datos in-situ obtenidos del proceso de impresión, y los parámetros de configuración de la máquina se utilizarán para realizar el modelamiento de las propiedades mecánicas aplicando técnicas de machine learning que se adecuen para este proceso.

## **Objetivos**

### ***Objetivo General***

Modelar la interdependencia de parámetros de proceso con las propiedades mecánicas de órtesis para articulaciones mtacarpofalángicas e interfalángicas vía FDM

### ***Objetivos Específicos***

- Instrumentar de un sistema de adquisición de datos in-situ en el proceso FDM.
- Elaborar el modelo digital (3D CAD) de una órtesis para miembro superior (brazo).
- Construir la órtesis modelada vía FDM.

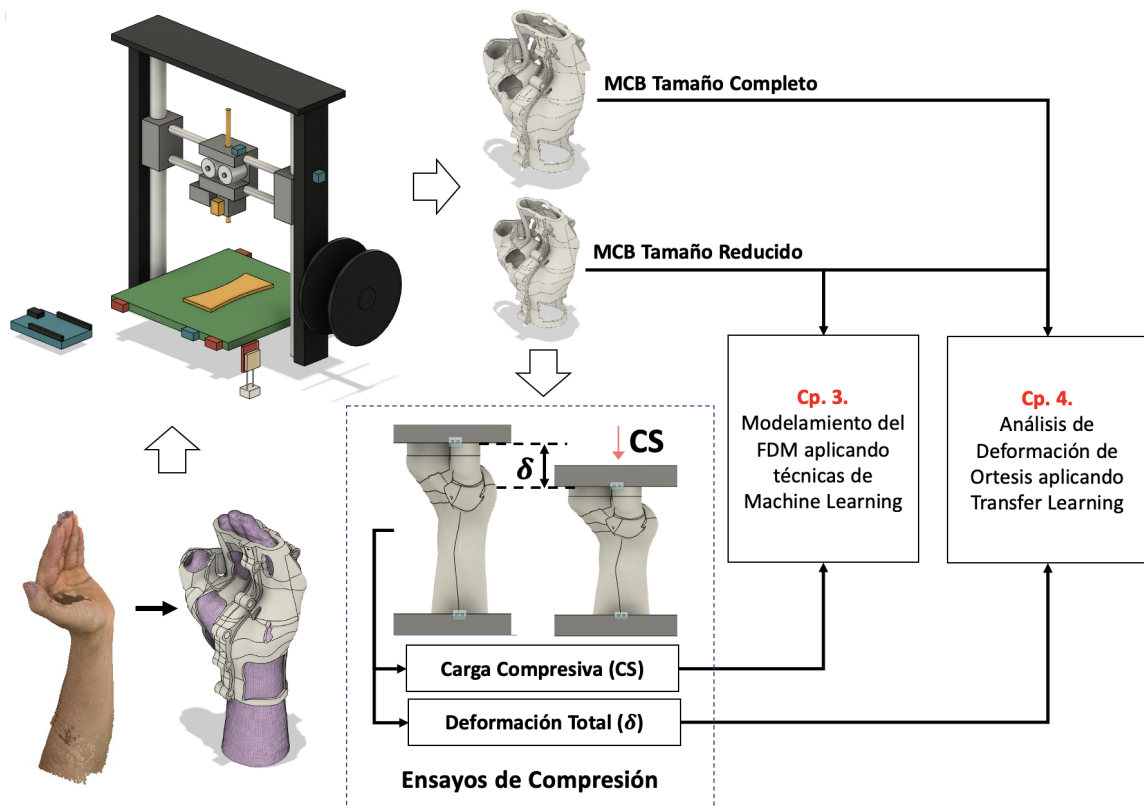
- Determinar las propiedades mecánicas de las órtesis obtenidas por FDM.
- Aplicar de métodos de machine learning para modelar las propiedades mecánicas de las órtesis obtenidas.

## Organización del Proyecto

El presente proyecto se organizará de la siguiente forma. En el capítulo II, se expone el marco teórico en el cual se encuentra explicado los conceptos clave aplicados para el desarrollo del proyecto.

### Figura 2

#### Organización del Trabajo de Titulación



En el capítulo III, se desarrolla el modelamiento de la carga de compresión máxima soportada por las órtesis impresas a escala aplicando tres técnicas de Machine Learning (Lasso, Random Forest y Support Vector Machine). En el capítulo IV, se aplica técnicas de transfer learning para modelar la deformación total de las órtesis en tamaño real, transfiriendo la información obtenida de un grupo de órtesis impresas en tamaño reducido. El capítulo III se basa en un estudio previo publicado en el Manufacturing Science & Engineering Conference(MSEC) 2020 de la Sociedad Americana de Ingenieros Mecánicos (ASME) (Toscano y col., 2020). El capítulo IV se basa en un estudio previo publicado en el MSEC 2021 del ASME (Toscano y col., 2021).

## Capítulo II


### Marco Teórico

#### **Manufactura Aditiva**

La manufactura aditiva por sus siglas en inglés (AM), es un término que fue inicialmente usado para referirse a los procesos en los cuales se añade capas de material secuencialmente y en un orden determinado con la finalidad de obtener un objeto 3D (Unnithan y col., 2019). AM se ha convertido en una tecnología disruptiva en industria manufacturera y el diseño (Huang, Wang y col., 2020). Existen varios sistemas de manufactura aditiva comercial disponible en el mercado como: FDM, deposición directa de metal, sinterizado de láser selectivo, estereolitografía e Inkjet 3D printing (Huang, Wang y col., 2020; Segura y col., 2021). Estas técnicas, son capaces de fabricar partes con una resolución muy fina y han sido ampliamente utilizados para la fabricación de productos especializados (Segura y col., 2019). De estos procesos FDM ha sido utilizado ampliamente en AM ya que con este método, se pueden obtener prototipos funcionales en varios tipos de termoplásticos en un ambiente seguro y amigable (Andreas, 2011).

#### ***Modelado por deposición Fundida (FDM)***

FDM fue desarrollado por Stratasys Inc. en Estados Unidos en 1990 (Montero y col., 2001). En la actualidad FDM es usualmente utilizado para el modelado, generación de prototipos y aplicaciones en producción. En este proceso el material se funde en un estado líquido en un cabezal que posee elementos de calentamiento. Posteriormente el material es depositado selectivamente a través de una boquilla extrusora, la cual se desplaza, siguiendo un patrón basado en un modelo obtenido por diseño asistido por computador, CAD por sus siglas en inglés, generando una construcción capa por capa del sólido 3D requerido como se muestra en la Figura 3.

**Figura 3***Impresión 3D por FDM*

*Nota:* Tomado de *Optimization of fused deposition modeling process parameters: a review of current research and future prospects* por Mohamed y col., 2015.

**Parámetros de Proceso en FDM.** Los parámetros de proceso se describen en la Figura 4.

A continuación, se describen algunos de los parámetros de trabajo en el proceso de FMD:

1. Ancho de de la capa: Se refiere al espesor de la capa de material depositada por la punta de la boquilla, como se muestra en la Figura 5.
2. Espacio libre: Se refiere al espacio entre los segmentos depositados, como se muestra en la Figura 5.
3. Ángulo de trama: Se refiere al ángulo generado por el segmento depositado con respecto al eje x, como se muestra en la Figura 5.
4. Ancho de extrusión: Se refiere al espesor del segmento depositado, se relaciona con el espesor de la boquilla, como se muestra en la Figura 5.

Figura 4


Parámetros de proceso en FDM

Parámetros de Proceso en FDM					
Modelo	Material	Máquina FDM	Párametros Ambientales	Orientación de la pieza	Parámetros de trabajo
Archivo STL	Densidad Color Propiedades Mecánicas	Temperatura de construcción del material Temperatura del extrusor Temperatura de salida del material Tempertura de la cama Diámetro de la Boquilla	Humedad Temperatura	Dirección x Dirección y Dirección z	Espacio libre Ángulo de trama Espesor de trama Espesor de la capa Estilo de llenado Factor de encogimiento Espesor del contorno

5. Espesor de contorno: Se refiere al espesor de la sección que corresponde al contorno de la figura, como se muestra en la Figura 5.
6. Estilo de llenado: Se refiere a la forma con la cual la pieza es llenada, se relaciona con la densidad final de la pieza. Existen 3 tipos de llenado
  - Sólido Normal: La parte interior de la pieza de llena completamente.
  - Esparcido: Minimiza el volumen de material y el tiempo de construcción, dejando espacios libres en cada capa. Utiliza una trama unidireccional.
  - Esparcido doble: Reduce el volumen de material y el tiempo de construcción. La trayectoria es un patrón interno cruzado
7. Factor de encogimiento: Se refiere al encogimiento que sufrirá la pieza una vez que esta se enfríe en los ejes, x, y, z.

**Figura 5**

*Esquema de los parámetros de proceso en FMD*



*Nota:* Tomado de *Optimization of fused deposition modeling process parameters: a review of current research and future prospects* por Mohamed y col., 2015.

## Órtesis

Una órtesis es un apoyo u otro dispositivo externo (aparato) aplicado al cuerpo para modificar los aspectos funcionales o estructurales del sistema neuromusculoesquelético (Levy y Barragán, 2003). En general, es una prenda apretada, que se ajusta a la forma del cuerpo humano y provee soporte para la sección del cuerpo en el cual es aplicado. Se utiliza para tratamientos de rehabilitación o para proteger el cuerpo durante un trabajo pesado (Zhang y Kwok, 2019). Las órtesis para miembro superior son dispositivos que, adaptados externamente sobre cualquier región anatómica de la extremidad superior, modifican sus características estructurales o funcionales, con el fin de mantener, mejorar o restaurar la función alterada de la citada extremidad o de alguno de sus segmentos.

### ***Tipos de Órtesis***

Según su función, las órtesis se pueden clasificar como:

1. Pasivas: Se caracterizan por ser no articuladas, sirven para mantener en reposo los diversos segmentos en los cuales es aplicada. Su función principal es postural e inmovilizadora y se encargan de prevenir, corregir o impedir deformidades.

2. Activas: Son una aplicación particular de los exoesqueletos, las cuales consisten en un mecanismo estructural externo acoplado a la persona y cuyas juntas y eslabones corresponden a las de la parte del cuerpo humano que emula (A. Gómez, 2010)

Las órtesis más comunes son:

1. Aparatos ortopédicos: Son utilizados para tratamientos de escoliosis, en proceso de rehabilitación ya que comprimen a los huesos y a los ligamentos, y para inmovilizar articulaciones lo cual disminuye el esfuerzo en la zona afectada (Radomski y Latham, 2008).
2. Tobilleras: Se ajusta alrededor del tobillo, con el fin de inmovilizar la articulación, lo cual permite acelerar el proceso de recuperación de esguinces u otro tipo de lesiones (Slutsky, 2016).
3. Fajas: Se ajusta alrededor de la cintura, comprime el abdomen, centra el peso corporal y libera la tensión de la columna (Chang y Chon, 2012).
4. Banda Estomacal: Es una prenda de compresión que se asemeja a un tubo, y se ajusta en el abdomen de las mujeres embarazadas (Radomski y Latham, 2008).
5. Muñequeras: Se ajusta alrededor de la muñeca, con el fin de inmovilizar la articulación, lo cual permite acelerar el proceso de recuperación de esguinces u otro tipo de lesiones (Slutsky, 2016).
6. Rodilleras: Se ajusta alrededor de la rodilla, con el fin de inmovilizar la articulación, lo cual permite acelerar el proceso de recuperación de esguinces u otro tipo de lesiones (Slutsky, 2016).

### ***Órtesis no convencionales (NCCB)***

Son obtenidas por procesos de AM, especialmente en técnicas como FDM, con la finalidad de contrarrestar las limitaciones de las órtesis convencionales. Las piezas generadas por este método se ajustan de mejor al cuerpo del paciente, de igual manera son más ligeras, brindan



una mayor ventilación, y son más cómodas. Para la fabricación de órtesis aplicando FDM se utiliza como material el ácido poliláctico (PLA) (Mohamed y col., 2015).

### **Figura 6**

*Órtesis obtenida por impresión 3D*



*Nota:* Tomado de *Customization and topology optimization of compressioncasts/braces on two-manifold surfaces* por Zhang y Kwok, 2019.

En la actualidad las órtesis son realizadas empíricamente con herramientas computacionales tipo CAD. El proceso es complicado, ocupa bastante tiempo y la optimización es bastante compleja. Para optimizar las piezas obtenidas sin sacrificar las propiedades mecánicas se utiliza una técnica denominada optimización topológica (Zhang y Kwok, 2019). Este tipo de órtesis se puede utilizar para tratamientos incruentos de fracturas de miembro superior o como inmovilizador temporal, además sería de mucha utilidad en pacientes con patologías como síndrome de túnel carpiano, tendinitis de quervain, sinovitis de muñeca, tendinitis de los extensores o flexores de antebrazo.


### **Optimización Topológica**

La optimización topológica es un método matemático que minimiza el peso de una estructura mientras incrementa su rigidez. Este sistema optimiza la distribución del material en un dominio dado. Las técnicas de optimización topológica más comunes son: método del material sólido isotrópico con penalización paramétrica, método de ajuste de nivel y método de estructura de suelo. Todos estos métodos se basan en análisis de elementos finitos por lo cual generan una alta demanda de recursos computacionales. La aplicación de este método en un espacio tridimensional

es demandante para el computador por lo cual los resultados obtenidos usualmente son limitados (Zhang y Kwok, 2019).

### Figura 7

*Proceso de obtención de una órtesis para brazo*



*Nota:*(a) Escaneo del paciente (b) reconstrucción de la superficie, (c) diseño de la órtesis, (d) Tres diseños optimizados: tórax, muñecas, piernas (Zhang y Kwok, 2019).

## Machine Learning

### *Supervised Learning*

Es un proceso mediante el cual se determina la influencia de un grupo de variables de entrada (i.e., variables medidas in-situ o preestablecidas) en una o más variables de salida (Hastie y col., 2009). A través de proceso se obtiene una función hipótesis que mapea las respuestas (i.e., variables de salida) en base a las entradas (i.e., variables de entrada), a partir de una base de datos en la cual existe una relación funcional desconocida (Russell y Norvig, 2002). Las variables de salida pueden ser cualitativas, cuantitativas o categóricas ordenadas (Hastie y col., 2009).

### *Tipos de Variables*

1. Variables Cuantitativas: Este tipo de variable se relaciona con una medida cuantitativa (i.e., representada por códigos numéricos) (Hastie y col., 2009).
2. Variables Categóricas: También denominadas discretas o cualitativas, este tipo de variable

es descriptiva y no define una jerarquía establecida (Hastie y col., 2009).

3. Variables categóricas ordenadas: En este tipo de variables existe un orden entre los valores obtenidos, pero no existe una noción métrica apropiada (Hastie y col., 2009).

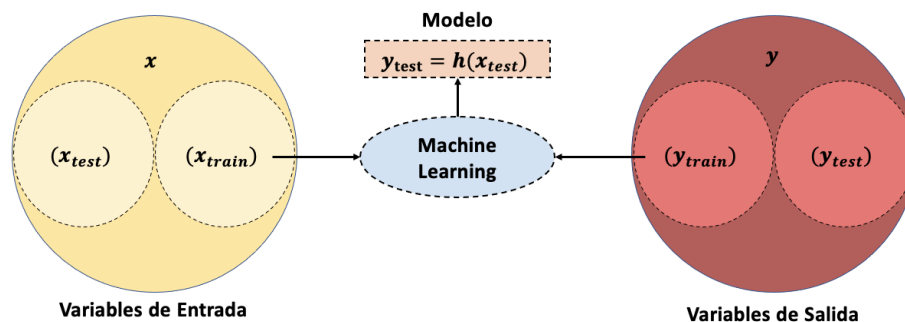
### **Datos de Entrenamiento y Datos de Prueba**

El grupo de datos de entrenamiento es un conjunto de pares (entrada-salida), en los cuales cada valor (numérico o no numérico) de salida  $y_i$  tiene una relación funcional desconocida  $f$  con su entrada correspondiente  $x_i$  es decir  $y = f(x)$ . Este grupo de datos es utilizado por el algoritmo de ML para definir una función hipótesis  $h$  la cual se aproxima al valor real de la función  $f$  (Russell y Norvig, 2002).

El grupo de datos de prueba es un conjunto de pares (entrada -salida) que no pertenecen al grupo de entrenamiento, pero que mantienen la misma relación  $f$  presente en el grupo de entrenamiento. Este grupo es utilizado para medir la exactitud de la función hipótesis  $h$  generada a partir del grupo de entrenamiento. Se dice que una hipótesis generaliza bien, si es capaz de predecir correctamente los valores de  $y$  que no pertenecen al grupo de entrenamiento (Russell y Norvig, 2002) La relación entre los grupos de entrenamiento (train) y de prueba (test), se puede observar en la Figura 8.

**Figura 8**

*Relación entre variables de entrada y salida en machine learning*



*Nota:* Donde  $h$  es una función hipótesis que predice la información de los datos de prueba generada a partir del grupo de entrenamiento.

## **Regresión y Clasificación**

Se habla de regresión cuando las variables a predecir (i.e., variables de salida) son cuantitativas, mientras que en la clasificación las variables a predecir (i.e., variables de salida) son cualitativas (Hastie y col., 2009).

### **Métodos de Regresión de ML**

Un método de aproximación se define como una estructura que relaciona las variables de entrada. (i.e., predictores) con las variables de salida (i.e., respuestas). Los métodos de aproximación pueden ser paramétricos o no paramétricos. Los métodos de aproximación paramétricos generan modelos en los cuales la información se resume en un conjunto de parámetros de valor fijo mientras que en los no paramétricos el número de parámetros efectivos es ilimitado y tiene la factibilidad de crecer según el número de muestras utilizadas para el modelamiento (Russell y Norvig, 2002). Existen varios métodos de ML que se pueden utilizar para regresiones, incluyendo redes neuronales recurrentes (Huang, Segura y col., 2020), descomposición de tensores (Segura, Muñoz y col., 2020), procesos gaussianos, entre otros. Sin embargo, en el presente trabajo se implemento Lasso, Random Forest y Support Vector Machine.

**Lasso.** Es un método lineal de regresión, que retiene o descarta variables en el proceso de modelado. Este modelo genera una selección continua de subconjuntos, resolviendo el problema de mínimos cuadrados expresado en la Ecuación 1 (Hastie y col., 2009).

$$\hat{\beta}^{Lasso} = \underset{\beta}{\operatorname{argmin}} \left\{ \frac{1}{2} \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (1)$$

Donde,  $\hat{\beta}^{Lasso}$  es un vector de coeficientes estimados,  $y_i$  es la variable de respuesta para la muestra i-esima, N es el numero de muestras,  $x_{ij}$  es una matriz que contiene los elementos predictores para la j-esima variable de la i-esima muestra, p es el numero de variables predictoras y finalmente  $\lambda$  es un coeficiente que tiene un valor de 0 a 1 y que ese encarga de truncar la variable de entrada (Hastie y col., 2009).

**Random Forest (RF).** Es un modelo de regresión que promedia varios modelos indepen-

dientes aproximados (i.e., modelos que predicen la variable de respuesta), con el fin de reducir la variabilidad. El método RF construye un conjunto grande de arboles no correlacionados y los remedia. En el método de RF existen parámetros independientes que se escogen usualmente por validación cruzada que determinan la forma de modelado, para el caso de RF, estos parámetros son,  $m$  que define el numero de variables agrupadas en la formación de los arboles y  $B$  que es el numero de arboles que serán promediados. El modelo de regresión RF se describen en la ecuación 2 (Hastie y col., 2009).

$$\bar{f}_{rf}^B(x) = \frac{1}{B} T(\mathbf{x}; \Theta_b) \quad (2)$$

Donde,  $\bar{f}_{rf}^B$  es la función de regresión  $T$  es el conjunto de arboles,  $B$  es el numero de arboles,  $\mathbf{x}$  es un matriz que contiene las variables de predicción y  $\Theta_B$  es una estructura que caracteriza el  $b$ -esimo árbol (Hastie y col., 2009).

**Support Vector Machine (SVM).** Finalmente Support Vector Machine (SVM) es una técnica de clasificación que se utiliza para obtener funciones de regresión. Se basa en la función Kernel, esta función construye define los limites de cada uno de los grupos generados en el proceso de clasificación. Los limites generados son lineales en un espacio transformado. La función Kernel puede ser: lineal, polinómica o radial, y la función aplicada depende de la naturaleza de los datos (i.e., la que mejor se ajuste y que genere menos errores). Existen parámetros independientes que caracterizan ala función Kernel y dependen del tipo de función aplicada y se usan como métodos de control de los resultados obtenidos. El modelo de regresión SVM se muestra en la Ecuación 3 (Hastie y col., 2009).

$$\hat{f}(x) = \sum_{i=1}^N \hat{\alpha}_i K(x, x_i) \quad (3)$$

Donde,  $\hat{f}(x)$  es la función de regresión,  $N$  es el numero de muestras,  $K(x, x_i)$  es el producto interno de la función Kernel, y  $\hat{\alpha}_i = (\mathbf{H}\mathbf{H}^T - \lambda_S \mathbf{V}\mathbf{M}\mathbf{I})^{-1} \mathbf{y}$ ; donde  $\mathbf{H}\mathbf{H}^T$  es una matriz que se conforma de los productos internos de los pares de muestras analizadas,  $\lambda_S \mathbf{V}\mathbf{M}$  es un parámetros de regulación y finalmente,  $\mathbf{y}$  es la variable a predecir (Hastie y col., 2009).

## Transfer Learning (TL)

### **Domain Adaptation(DA) y Transfer Learning(TL)**

En muchas aplicaciones de ML, es necesario generar un modelo que pueda cumplir una función específica utilizando datos de entrenamiento pertenecientes a una distribución determinada (dominio fuente), y ocupar dicho modelo en un grupo de datos de prueba provenientes de una distribución diferente (dominio objetivo) (Chopra y col., 2013). El problema de usar diferentes distribuciones de datos de entrenamiento y de prueba se conoce como Domain Adaptation (DA) (Chopra y col., 2013) y el proceso de transferir dicha información entre dominios se denomina Transfer Learning (TL). Una motivación común para aplicar técnicas de TL es la escasez de datos en la tarea objetivo. En general cuando se usa TL el número de parámetros entrenables en la tarea objetivo se puede reducir significativamente, lo que permite un aprendizaje efectivo aun cuando la cantidad de datos para dicha tarea es pequeña (Choi y col., 2017).

### **Métodos DA**

En el presente estudio, el método utilizado para adaptar los dominios y posteriormente generar la regresión fue el Semi-supervised Transfer Component Analysis.


**Transfer Component Analysis(TCA).** Sea  $\mathcal{D}_S = \{(x_{S_1}, y_{S_1}), \dots, (x_{S_{n_1}}, y_{S_{n_1}})\}$  el dominio de origen, donde  $x_{S_i}$  es el predictor y  $y_{S_i}$  es la respuesta correspondiente. De manera similar, sea  $\mathcal{D}_T = \{x_{T_1}, \dots, x_{T_{n_2}}\}$  denota el dominio de destino respuestas, donde  $x_{T_i}$  es su predictor correspondiente. Adicionalmente debe considerarse que  $\mathcal{P}(X_S)$  y  $\mathcal{Q}(X_T)$  denoten las distribuciones marginales de  $X_S = \{x_{S_i}\}$  y  $X_T = \{x_{T_i}\}$ . Transfer component analysis (TCA y otras técnicas de DA) no se basa en el supuesto de que  $\mathcal{P} = \mathcal{Q}$ , que es un requerimiento de varias técnicas de DA. TCA asume la existencia de una función de transformación  $\phi$  tal que  $P(\phi(X_S)) \approx P(\phi(X_T))$  y  $P(Y_S|\phi(X_S)) \approx P(Y_T|\phi(X_T))$ .

Una vez desarrollada la transformación, se pueden aplicar métodos de regresión convencionales como  $\phi(X_S)$  y su respuesta correspondiente  $Y_S$ . Luego, el modelo de regresión obtenido se puede aplicar a  $\phi(X_T)$  para predecir  $\phi(X_S)$  (Pan y col., 2010) como se puede observar en la Figura 9. Si no existen datos de respuestas para  $X_T$ , la función  $\phi$  se puede obtener minimizando la distancia entre  $P(Y_S|\phi(X_S))$  y  $(Y_T|\phi(X_T))$  no se puede lograr; por tanto, Pan (Pan y col., 2010) sugirió obtener un  $\phi$  tal que:

1. Las distribuciones marginales  $P(\phi(X_S))$  y  $P(\phi(X_T))$  se alinean bien y la distancia entre las mismas se minimiza mediante la transformación.
2.  $\phi(X_S)$  y  $\phi(X_T)$  tienen las características importantes de  $X_S$  y  $X_T$ .

### Figura 9

Esquema representativo del Método TCA



*Nota:* Donde  $f$  es una función de regresión generada partir de la información proporcionada por el SD.

Pan (Pan y col., 2010) y sus colaboradores asumieron que  $P(Y_S|\phi(X_S)) \approx P(Y_T|\phi(X_T))$  también es satisfactorio bajo las condiciones antes mencionadas. Para cumplir la condición 1, se basaron en una técnica de máxima discrepancia media (MMD) basada en la reducción de dimensio-

alidad (Pan y col., 2008), que integra  $X_S$  y  $X_T$  en un espacio latente común de menor dimensión a través de una función transformación no lineal  $\phi$ . Sin embargo, resolver este problema demanda recursos computacionales. Por lo tanto, desarrollaron un enfoque mas eficiente para aprender  $\phi$  y minimizar el MMD  $Dist(X_S, X_T)$  entre las medias empíricas de ambos dominios. Para cumplir con la segunda condición y preservar las características de los datos, la técnica propuesta intenta preservar al máximo la varianza de los datos. Este proceso es similar al análisis de componentes principales (PCA) y al análisis de componentes principales con kernel (KPCA). Finalmente, ambas condiciones pueden unificarse y resolverse como un problema de optimización de trazas (Pan y col., 2010).

**Semi-supervised Transfer Component Analysis(SSTCA).** En muchas aplicaciones reales, el método DA puede ser configurarse de forma semi-supervisada, es decir este metodo puede beneficiarse de las respuestas existentes en los datos del TD. Basándose en este principio con la finalidad de descubrir el conocimiento latente en la relación entre los valores respuesta del SD y TD, el TCA se puede utilizar en un entorno semi-supervisado donde la información de la respuesta del TD se codifica para transferir componentes (Pan y col., 2010). Esta extensión se llama SSTCA. En particular, SSTCA se basa en tres principios:

1. Minimizar la distancia de distribución entre los datos del SD y TD (similar al TCA)
2. Maximizar la dependencia estadística entre los predictores y las respuestas
3. Conservación de las características locales de ambos dominios

Para obtener más detalles sobre estas tres propiedades y cómo se formulan, consulte el trabajo de Pan y sus colaboradores (Pan y col., 2010). Estas propiedades se pueden formular, combinar y resolver como un problema de optimización.



### Capítulo III


#### Modelamiento del FDM aplicando técnicas de Machine Learning

##### Introducción

Una órtesis se describe como un soporte externo que modifica las características funcionales o estructurales del sistema neuromusculoesquelético (Levy y Barragán, 2003). Estos dispositivos son prendas que se ajustan al cuerpo del paciente para brindar apoyo a la zona lesionada durante el proceso de rehabilitación (Zhang y Kwok, 2019). El desarrollo de órtesis no convencionales (NCCB, por sus siglas en inglés) (Figura 1(b)) ha sido de interés médico e ingenieril con el fin de solucionar los problemas causados por las órtesis tradicionales (Figura 1(a)).

##### Figura 10

*Proceso de FDM*



El desarrollo de la manufactura aditiva (AM) y la impresión 3D, ha generado un progreso significativo en la fabricación de estructuras complejas (Segura, Zhao, Zhou y col., 2020). AM incluye un conjunto de técnicas de construcción en las que el material se agrega secuencialmente capa por capa para obtener un objeto 3D (Unnithan y col., 2019). El modelado de deposición fundida (FDM) es un tipo AM desarrollado por Stratasys Inc. en 1990 (Montero y col., 2001). Hoy en día, FDM se utiliza para modelar y fabricar prototipos utilizados en la industria y otros sectores productivos.

En FDM el material se fusiona y se coloca mediante una boquilla de extrusión, esta boquilla se mueve siguiendo una ruta predefinida basada en un modelo de diseño asistido por computadora (CAD), generando así un sólido 3D capa a capa como se muestra en la Figura 10. FDM también se utiliza para construir NCCB (Figura 6(b)). Fitzpatrick et al., Diseñaron un aparato ortopédico para un paciente usando un escáner 3D y luego construyeron el NCCB por FDM (Fitzpatrick y col., 2017). Adicionalmente, Andrade en Ecuador también estudió el proceso de fabricación de órtesis para muñecas aplicando FDM y optimización de topología (Andrade, 2019).

Para asegurar la calidad de los objetos obtenidos por FDM, evitar desperdicios de material, incrementar las tasas productivas y reducir el tiempo y costo de producción, se deben controlar las propiedades mecánicas de las piezas obtenidas. Estas propiedades tienen un efecto significativo sobre la funcionalidad y el rendimiento de las piezas impresas. Mohamed et al., afirma que la calidad de la pieza y las propiedades mecánicas de la pieza obtenida mediante FDM, están relacionadas con los parámetros del proceso (es decir, condiciones ambientales, vibraciones y configuración de la máquina) (Mohamed y col., 2015).

En la actualidad, se han realizado varios estudios para analizar las propiedades mecánicas de las piezas obtenidas por AM. Masood et al., investigaron sobre los efectos del estilo de impresión, el ancho de extrusión y el ángulo de construcción en la resistencia a la tracción de las piezas impresas con policarbonato, concluyendo que la resistencia a la tracción tenía una fuerte relación con el estilo de impresión (Masood y col., 2010). Adicionalmente, Fuentes de la Universidad de Sevilla construyó NCCB a través de FDM y desarrolló ensayos mecánicos de carga axial para definir sus propiedades mecánicas (Fuentes, 2017).

Un método de aproximación que se puede utilizar para definir la relación entre los parámetros del proceso y las características de un producto obtenido por un proceso de manufactura complejo es Machine Learning (ML)(Rao y col., 2015; Toscano y col., 2020). ML es un conjunto de técnicas que se pueden utilizar para definir la influencia de un grupo de variables de entrada en una variable de salida (Hastie y col., 2009). ML obtiene una función de hipótesis que mapea las

respuestas (es decir, variables de salida) en función de las variables de entrada en la que existe una relación funcional desconocida (Russell y Norvig, 2002). Toscano et al., describieron un enfoque de ML para modelar el proceso de electrospinning, y obtener la relación entre los parámetros del proceso, las mediciones in-situ y el diámetro de las fibras obtenidas aplicando tres técnicas de ML (Toscano y col., 2020). Además, Rao et al desarrollaron una investigación de ML aplicada a un proceso de fabricación complejo, la fabricación de filamentos fundidos (Rao y col., 2015).

Los estudios descritos anteriormente analizan la influencia de los parámetros del proceso sobre las propiedades mecánicas de las piezas obtenidas por FDM. Sin embargo, estos estudios no consideran la geometría de las piezas para aplicaciones reales. La mayoría de estos estudios se desarrollaron sobre probetas estandarizadas y en la mayoría de los casos se despreciaron las mediciones in-situ de vibraciones o condiciones ambientales. Mohamed et al., afirmaron que la geometría y las condiciones ambientales también juega un papel importante en la calidad de las piezas impresas (Masood y col., 2010).

## **Método**

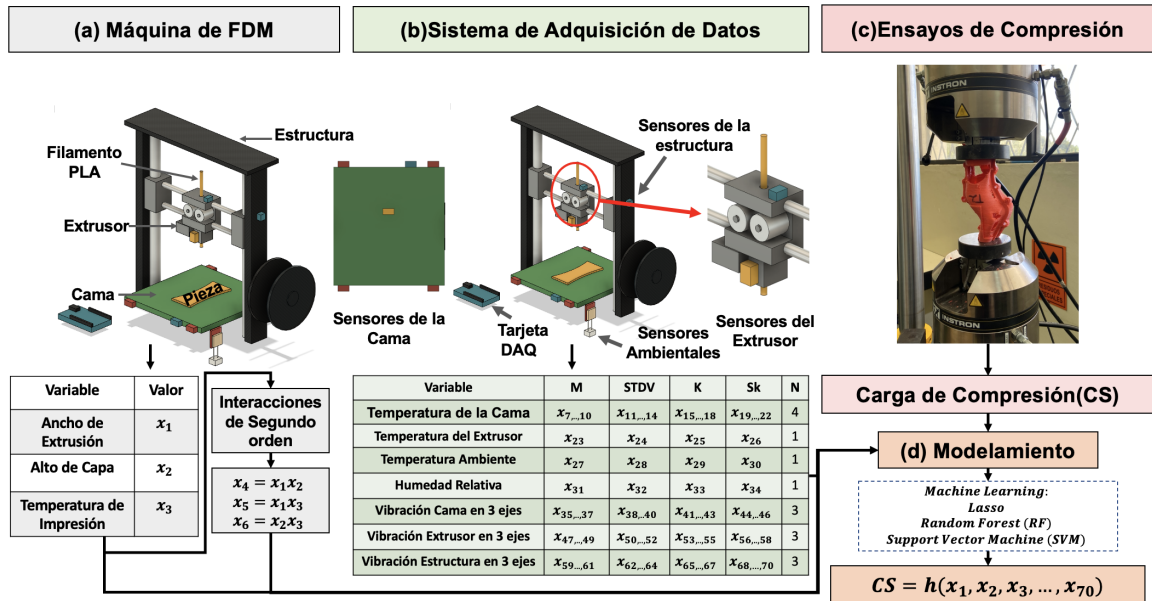
El siguiente estudio está centrado en modelar la carga de compresión máxima (CS) resistida por MCB obtenidos por FDM aplicando técnicas de ML. Las variables de proceso (PV) (es decir, mediciones in situ y variables preestablecidas) se consideran variables de entrada y la carga máxima resistida se utiliza como variable de salida en el proceso de modelado. Los PV se obtienen de la máquina FDM y de un sistema de adquisición de datos. Adicionalmente, la CS (es decir, la variable de salida) se obtiene de una prueba de compresión desarrollada en una máquina de ensayos universales Instron 8801 como se muestra en la Figura 11.

### ***Diseño, Fabricación, Modelamiento y Caracterización del MCB***

Para desarrollar un modelo MCB el primer paso es definir la posición adecuada del brazo para el tratamiento de lesiones metacarpianas. Una vez definida la posición se utilizó un iPhone

Figura 11

Método para el modelamiento del CS aplicando técnicas de ML



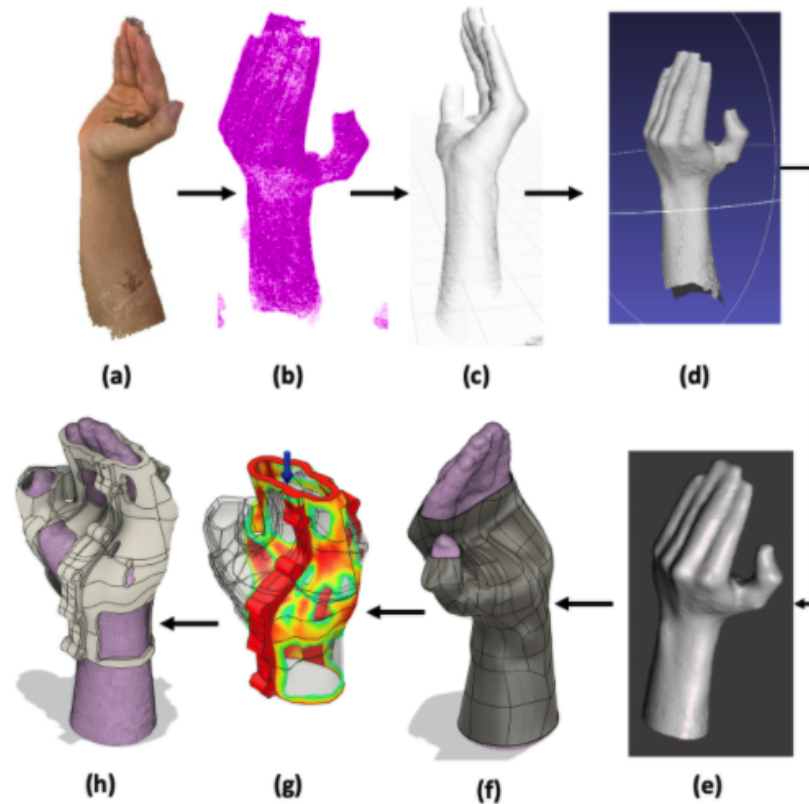
Nota: (a) Máquina FDM, (b) Sistema de Adquisición de datos, (c) Ensayos de Compresión y, (d) Modelamiento.

MWL72LL/A para el escaneo el brazo y el antebrazo, como se muestra en la Figura 12 (a). Para este proceso, se ocupó la aplicación móvil Capture, la cual combina la ARkit (i.e., el paquete de realidad aumentada iOS) con la tecnología de detección que activa Face ID en la cámara frontal del teléfono (i.e., TrueDepth) para facilitar y mejorar el proceso de digitalización (Miller, 2020).

Como resultado del proceso de digitalización, se genera un archivo tipo SCN, que contiene los puntos de característicos del brazo (Ver Figura 12(b)). XCode v11.6 se usó para convertir el archivo y obtener una malla (Ver Figura 12 (c)). Con ayuda de MeshLab v2020.02 se procesó la malla y se reconstruyó la superficie del brazo como se muestra en la Figura 12 (d). MeshLab es un sistema de código abierto, portátil y extensible para procesar y editar mallas triangulares 3D no estructuradas Cignoni y col., 2008. La superficie obtenida se convierte en un cuerpo sólido utilizando el software Autodesk Meshmixer versión 3.5.474, como se muestra en la Figura 12 (e). Luego, Autodesk FUSION 360 versión 2.08809 se ocupó para generar una superficie a partir del

**Figura 12**

*Diseño, Fabricación, Modelamiento y Caracterización del MCB*



modelo previo (Ver Figura 12 (f)). Para definir la geometría de la órtesis se llevaron a cabo varias simulaciones de compresión y un proceso de optimización topológica. Para dicho proceso se consideraron las propiedades mecánicas base del PLA, (59MPa de resistencia a la tracción y un módulo de Young de 1280 MPa (Farah y col., 2016)) una carga de 2000N (Ver Figura 12 (g)). La fuerza de compresión simulada representa el 80 % de la carga máxima soportada por prototipos cilíndricos idealizados sometidos a compresión pura (Fuentes, 2017). Finalmente, el modelo CAD del MCB (Ver Figura 12 (h)) se transforma en una malla para continuar con el proceso de impresión.

### ***Maquina de FDM***

Una vez obtenido el modelo MCB, se utiliza una máquina FDM (Ver Figura 11(a)) para imprimir las piezas en 3D. Tres variables de entrada se obtienen de los parámetros proceso de la

máquina FDM, es decir, ancho de extrusión, altura de la capa y temperatura de impresión. Estas variables son factores controlables en el proceso FDM, y es fundamental modelar sus efectos en el CS de las MCB. El ancho de extrusión y la altura de la capa están relacionados con el ancho y el espesor de la capa depositada por la boquilla (Mohamed y col., 2015) como se muestra en la Figura 15. La temperatura de impresión predefinida se relaciona con la temperatura que el extrusor que debe alcanzar y mantener durante el proceso impresión. Estudios anteriores han demostrado que estas variables están relacionadas con las propiedades mecánicas de las piezas obtenidas por FDM (Mohamed y col., 2015; Rayegani y Onwubolu, 2014).

### ***Sistema de Adquisición de Datos (DAQ)***


El sistema de adquisición de datos (DAQ, por sus siglas en inglés), se encarga de la lectura, almacenamiento y posterior análisis de de la información captada por varios sensores en un sistema determinado (González y col., 2012). Durante el proceso de impresión se obtuvieron varias mediciones in-situ de las variables transitorias del proceso de FMD. Para el presente estudio, se registraron los valores de la temperatura (ambiente, cama y extrusor), humedad relativa (ambiente) y las vibraciones (extrusor, cama y del soporte) en los tres ejes como se puede observar en la Figura 11(b). El sistema DAQ propuesto se enfoca en la fase I de un statistical surveillance, es decir, establecer un modelo base y caracterizar su distribución estadística (Hajifar y col., 2021).

**Medición de la Temperatura.** Para la medición de la temperatura ambiente y la humedad relativa se utilizó un sensor de adquisición de señal digital DTH11 que fue conectado a una tarjeta Arduino Mega 2560. Adicionalmente, para obtener la temperatura de la cama se ocupó cuatro sensores analógicos LM35 ubicados en los extremos de la cama. Finalmente, un termistor NTC100k fue conectado a un puente de resistencias para la medición de la temperatura del extrusor como se muestra en la Figura 13.

**Medición de las Vibraciones.** La medición de las vibraciones se realizó con ayuda de tres acelerómetros tri-axiales ADXL355 conectados a una tarjeta Arduino Mega 2560, como se muestra en la Figura 13. El primer acelerómetro se posicionó en la cara superior de la cama. El segundo

Figura 13

Esquema representativo del circuito utilizado en el Sistema de Adquisición de Datos




acelerómetro se colocó en la cara lateral de una de las columnas de la estructura. Finalmente, para determinar las vibraciones del extrusor se posicionó el último acelerómetro en la cara superior del mismo, de modo que el cableado no interfiera con el movimiento requerido (ver Figura 11(b)).

### **Pruebas Mecánicas**

Una vez finalizado el proceso de impresión, las piezas obtenidas se sometieron a una prueba de compresión en una máquina de ensayos universales Instron 8801 como se muestra en la Figura 11(c). La pieza se cargó progresivamente y finalmente se registró la CS (Ver Figura 14) misma que se utilizó como variable de salida en el proceso de modelado.


### **Modelamiento**

Para el modelamiento se consideraron variables escalares y transitorias. Las variables escalares son parámetros controlables en el proceso FDM. En particular, se estudió la influencia de:

**Figura 14***Ensayos de Compresión*

el ancho del extrusión, la altura de la capa (Ver Figura 15), y la temperatura de impresión. Por otro lado, las variables transitorias son parámetros que varían en función del tiempo y usualmente no son controlables. Para cuantificar el efecto de estos parámetros en la CS se realizaron mediciones in-situ de la humedad y temperatura (ambiente), las temperaturas de trabajo del (cama, y extrusor) y las vibraciones de la cama, estructura y extrusor. Para facilitar el análisis de estas señales, se calcularon sus parámetros estadísticos media(M), desviación estándar(STDV), kurtosis(K) y Skewnes(S) como se puede observar en la Figura 11(b).

La respuesta CS se obtiene de las pruebas mecánicas desarrolladas con una máquina de pruebas universal Instron 8801. Finalmente, esta variable de salida se modeló en función de sus predictores (es decir,  $x_1, x_2, \dots, x_{70}$ ). En particular se exploraron tres técnicas de ML: Lasso, Random Forest y Support Vector Machine.

**Figura 15***Parámetros de Proceso*



**Tabla 1***Diseño de Experimentos para las MCB de Tamaño Reducido*

<b>N</b>	<b>Ancho de Extrusión<sub>(mm)</sub></b>	<b>Altura de la capa <sub>(mm)</sub></b>	<b>Temperatura de Impresión<sub>(°C)</sub></b>
1	0.8	0.48	200
2	0.63	0.48	200
3	0.715	0.39	210
4	0.8	0.39	210
5	0.63	0.48	220
6	0.8	0.3	220
7	0.8	0.48	220
8	0.715	0.39	220
9	0.715	0.39	210
10	0.715	0.39	200
11	0.715	0.48	210
12	0.63	0.3	220
13	0.715	0.3	210
14	0.63	0.39	210
15	0.715	0.39	210
16	0.63	0.3	200
17	0.8	0.3	200
18	0.715	0.39	210
19	0.715	0.39	210

## Caso de Estudio

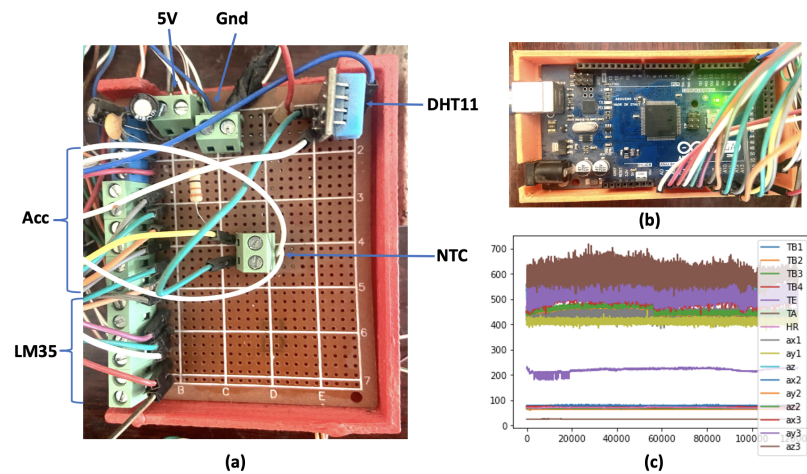
Como se mencionó en las secciones previas, se realizó un estudio de un MCB construido a escala por FDM diseñado para un brazo real y se modeló su CS utilizando tres métodos de ML: Lasso, RF y SVM.

### Proceso FDM

En la construcción del MCB se utilizó una impresora Aurora Z605 RepRap 3D FDM con una boquilla de 0,6 mm. El filamento utilizado fue PLA de 1,75 mm de diámetro. Los MCB de tamaño reducido se construyeron siguiendo un diseño de experimentos (DOE) central compuesto variando los tres parámetros de proceso mencionados anteriormente. Como resultado del DOE se definieron 19 muestras por imprimir (Véase la Tabla 1). Durante el proceso de impresión se registró las medidas in-situ de humedad, temperatura y vibraciones utilizando el sistema DAQ mostrado en la Figura 16.

**Figura 16**

*Sistema DAQ*




*Nota: Sistema DAQ: (a) Circuito DAQ, (b) Tarjeta DAQ y, (c) Ejemplo de señales captadas con el Sistema DAQ*

## Resultados

Antes de aplicar individualmente los modelos de regresión, primero se eliminaron los resultados de las muestras defectuosas. Encontramos que se existen casos de sobre extrusión, separación de las capas y errores en impresiones de detalles, en muestras 1, 16, 17 y 19 (Véase la Figura 17). Por esta razón, estas muestras no se consideraron en el proceso de modelado. Una vez que se eliminaron las muestras defectuosas, se procede a separar aleatoriamente los datos en grupos de entrenamiento y prueba. El grupo de entrenamiento se usa para generar los modelos de regresión, mientras que el grupo de prueba se utiliza para evaluar el rendimiento de la predicción de las técnicas aplicadas. En este estudio, se estableció el 80 % de los datos como grupo de entrenamiento y el otro 20 % como grupo de prueba. Tres técnicas de Machine Learning (Lasso, RF, SVM) se aplicaron al grupo de entrenamiento y se evaluaron en el grupo prueba. El proceso de modelado se repitió cien veces para obtener una evaluación sistemática de los modelos.

**Figura 17**

*Muestras Defectuosas MCB*



*Nota:* Ejemplo de muestras defectuosas: (a) Sobre extrusión (b) Error de impresión en detalles y (c) Separación entre capas

Para evaluar el rendimiento de Lasso, RF y SVM, el error relativo promedio para las cien repeticiones fue calculado. El error relativo se evalúa con  $\bar{E}_m = \frac{1}{100} \sum_{i=1}^{100} \left| \frac{P_i - R_o}{R_i} \times 100 \right|$  donde  $\bar{E}_m$ ,

**Tabla 2**

*Error relativo de los modelos de ML utilizados*

<b>Modelo</b>	<b>Error D. Entrenamiento( %)</b>	<b>Error D.Prueba( %)</b>
Lasso	9.80 (4.69)	31.78(62.32)
Random Forest	6.46(0.65)	15.79(4.35)
Support Vector Machine	0.53(1.94)	17.12(4.51)

*Nota:* Cuadro comparativo de los errores relativos obtenidos para el grupo de prueba y de entrenamiento de los modelos Lasso, RF y SVM en las 100 replicaciones analizadas

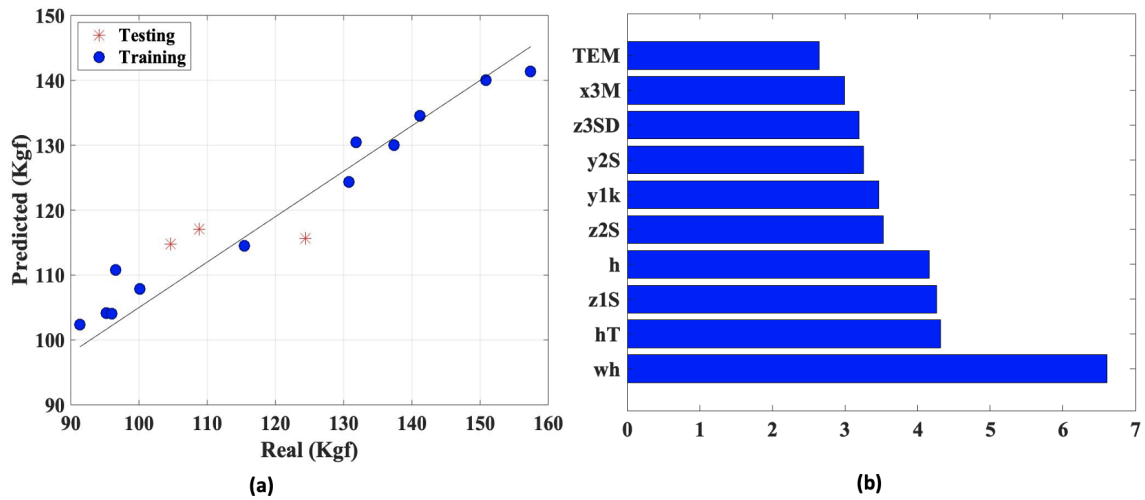
es el error relativo promedio,  $P_i$  es el valor predicho, y  $R_i$  es el valor real.

La Tabla 2 muestra los errores relativos promediados de CS y sus desviaciones estándar (entre paréntesis) de los tres métodos aplicados para los conjuntos de datos de prueba y entrenamiento. De la Tabla 2, el enfoque de RF superó a los otros métodos al modelar las respuestas individualmente. Para tener una ilustración del rendimiento de la predicción, la Figura 18(a), muestra la relación entre los valores reales y predichos de RF para las muestras de entrenamiento y prueba en la réplica número 100. Los resultados de la replica 100 se muestran en la Figura 18, y se puede ver una evidente concordancia con la regresión obtenida.

Adicionalmente, el análisis de la precisión de la disminución media (MDA), esta calculado para la 100<sup>ma</sup> ejecución, de modo que se pueden definir las variables más influyentes en la variable de respuesta CS. Generalmente, cuanto mayor es la puntuación del índice MDA, más importantes son las variables (Han y col., 2016). La Figura 18(b) muestra los resultados de la MDA de las 10 variables mas importantes en el modelo obtenido. Se observa que los factores más significativos (es decir, variables) son las interacciones de segundo orden ancho de extrusión por altura de capa ( $wh$ ), altura de capa por temperatura de impresión ( $hT$ ) seguido de varios parámetros relacionados con las vibraciones ( $z_{1S}$ ,  $z_{2S}$ ,  $y_{1k}$ , etc.).

**Figura 18**

*Ilustración de los resultados de ML*



*Nota:* (a) Resultados del modelo de RF para datos de entrenamiento y prueba en la predicción de la CS y (b) RF % MDA (10 variables más importantes)

## Resumen

Una órtesis, es una prenda ajustada que restringe el movimiento y brinda apoyo a la zona lesionada del paciente. Los aparatos ortopédicos tradicionales conllevan varios problemas como: desperdicio de material, incomodidad, insatisfacción del paciente, mal olor, peso excesivo y procedimientos de extracción peligrosos. Estos problemas se pueden resolver parcialmente mediante la construcción de órtesis por modelado de deposición fundida (FDM, por sus siglas en inglés). FDM es un tipo de manufactura aditiva con el cual se puede construir piezas complejas y personalizadas, incluyendo órtesis meta carpianas (MCB, por sus siglas en inglés). En el proceso de FDM, la calidad y las propiedades mecánicas de la piezas impresas están relacionadas con varios parámetros de proceso. Por esta razón, es importante modelar el efecto de los parámetros de proceso en las propiedades mecánicas de la pieza con el fin de garantizar la funcionalidad final de la pieza. Con este fin, en el presente capítulo se estudia sistemáticamente el proceso FDM en la construcción de un MCB, a través de un estudio experimental y el modelado basado en técnicas de Machine

Learning. Para obtener el modelo CAD del MCB se aplicó técnicas de digitalización usando Apple ARkit y optimización topológica. Posteriormente, se estudiaron tres variables de proceso (ancho de extrusión, altura de la capa y temperatura de impresión) para el diseño de experimentos y se imprimieron diecinueve muestras. Durante el proceso de impresión se recopilaron mediciones in-situ a través de un sistema de adquisición de datos. Una vez obtenidas las muestras, se utilizó una máquina de ensayos universal para medir la carga de compresión máxima soportada por los MCB previamente impresos. Finalmente, se aplicaron tres técnicas de machine learning; Lasso, Random Forest (RF) y Support Vector Machine (SVM), para modelar la carga máxima en soportada por los MCB en función de las variables escalares predefinidas y de las variables funcionales obtenidas de las mediciones in-situ RF mostró el mejor desempeño en la predicción de CS seguido de SVM y finalmente Lasso. En particular, el enfoque de RF puede predecir el CS con un error de 15,79%.

## Capítulo IV

### Análisis de Deformación de órtesis Metacarpofalangias e Interfalangias vía Transfer


#### Learning

#### Introducción

Las órtesis son prendas ajustadas que brindan soporte al paciente durante el proceso de rehabilitación de fracturas y otro tipos de lesiones. Tradicionalmente, estos aparatos ortopédicos se construyen manualmente con yeso o fibra de vidrio (Daines y col., 2014). Por lo cual, las órtesis tradicionales poseen ciertas desventajas, como desperdicio de material, peso excesivo, malos olores e incomodidad (Zhang y Kwok, 2019). Por enfrentar estos problemas, el desarrollo de órtesis no convencionales (NCCB) (ver Figura 1(b)) ha sido de interés médico e ingenieril. Sin embargo, la construcción de NCCB es un proceso complejo debido a que la funcionalidad de la pieza requiere una alta personalización y flexibilidad.

#### Figura 19

*Distribución de esfuerzos y tiempo de impresión de los MCB*



Con el desarrollo de la manufactura aditiva (AM), es posible la construcción de piezas altamente flexibles y personalizadas. En particular, en el presente trabajo se analiza NCCB construidas por modelado deposición fundida (FDM). En FDM, el material se agrega capa por capa hasta que se obtiene un objeto en 3D, como se muestra en la Figura 3. A pesar de su capacidad para producir piezas complejas, FDM es un proceso lento que requiere una cantidad considerable de tiempo pa-

ra construir piezas en tamaño mediano/grande (Mohamed y col., 2015). Esta característica puede dificultar la aplicación de FDM en la fabricación y modelamiento de NCCB. Adicionalmente, para garantizar la funcionalidad de las NCCB se debe controlar sus propiedades mecánicas, mismas que están relacionadas con los parámetros de proceso (e.g., temperatura de impresión, ancho de extrusión) (Hajifar y col., 2019; Pei y col., 2015). Es importante mencionar que los estudios disponibles han analizado la resistencia relacionada con la carga de las piezas impresas (Ahn y col., 2002; Rayegani y Onwubolu, 2014), despreciando la deformación total ( $\delta$ ) de la misma. Por esta razón, en este capítulo se realiza un análisis de  $\delta$ . Esta propiedad mecánica nos brinda información referente al comportamiento funcional de las partes impresas (O'Brien y col., 2002).

Por las razones mencionadas anteriormente, encontrar los parámetros de proceso adecuados para construir un NCCB completamente funcional con la  $\delta$  adecuado generalmente implica un proceso prueba y error, lo cual incrementa el tiempo necesario para tener un MCB listo y funcional. Por lo tanto, es fundamental encontrar métodos o enfoques que permitan a los profesionales ahorrar tiempo durante las fases de diseño y construcción de las NCCB construidas por FDM.

En este capítulo, se explora el uso de Transfer Learning (es decir, Domain Adaptation) para resolver este problema. De esta manera se logra facilitar la recolección de datos que tiende a consumir mucho tiempo. Domain Adaptation (DA) tiene como objetivo transferir la información aprendida de un dominio fuente (SD) a un dominio objetivo (TD) nuevo pero relacionado (Lu y col., 2016). En particular, analizamos la impresión 3D de una órtesis metacarpiana (MCB), (ver Figura 22(a)) que se puede aplicar para fracturas, esguinces y luxaciones. Imprimimos MCB de tamaño reducido conservando la forma, el material y la estrategia de impresión del MCB de tamaño completo. En el presente trabajo, las muestras SD son MCB de tamaño reducido y TD son MCB de tamaño completo, respectivamente como se puede observar en la Figura 19.

El objetivo de este estudio es modelar la deformación total ( $\delta$ ) de MCB sujetas a cargas de compresión 22(c)). Inicialmente, el modelo MCB 3D se obtiene de la digitalización del antebrazo izquierdo y la mano de una persona como se muestra en la Figura 22(a.1). Posteriormente, se



realiza optimización topológica para reducir el peso de la MCB sin sacrificar la resistencia de la misma. Como era previsto, el proceso de impresión de las muestras SD lleva considerablemente menos tiempo que las muestras TD (ver Figura 19). Se utiliza una máquina de ensayos universales Instron 8801 para realizar las pruebas de compresión de las muestras de ambos dominios. Semi Supervised Transfer Component Analysis (SSTCA) se utiliza para transferir información de SD a TD y su rendimiento se compara con una regresión lineal utilizando solo los datos del SD. Como se demostrará en el caso de estudio, la respuesta TD  $\delta$  se predice con precisión al aprovechar la información de SD. El enfoque implementado supera a los métodos convencionales de modelado de entrada/salida, como la regresión lineal, donde no se considera DA. En general el enfoque propuesto es aplicable a otros procesos de fabricación de AM.

## Revisión Bibliográfica

### *Órtesis*

Las órtesis se han utilizado en muchas aplicaciones para tratar varios problemas, como fracturas de tobillo, brazo, escoliosis entre otras (Esmanhotto y Esmanhotto, 2013; Radomski y Latham, 2008). Para su fabricación, tradicionalmente se han utilizado materiales como yeso, poliuretano y fibra de vidrio; sin embargo, su construcción implica procesos manuales que generan desperdicio de material (Zhang y Kwok, 2019). Esmanhotto, descubrió que al cambiar la disposición de las capas de yeso puede ayudar a reducir el peso de las órtesis sin afectar su funcionalidad (Esmanhotto y Esmanhotto, 2013) lo cual indica que el proceso puede ser optimizado. Otro problema de las órtesis tradicionales es su peso excesivo y carencia de ventilación, lo que puede generar molestias a los pacientes durante el proceso de rehabilitación (Lin y col., 2016). Guyton (Guyton, 2005), analizó las complicaciones iatrogénicas de las órtesis concluyendo que, el uso de estos aparatos ortopédicos puede desencadenar complicaciones graves, como el síndrome del túnel carpiano, infecciones cutáneas y dermatitis.

Como alternativa para mitigar los problemas de las órtesis tradicionales, se han desarrollado varios NCCB, como órtesis desmontables e impresas por técnicas de AM. Debido a su alta flexibilidad y gran versatilidad, AM permite producir piezas ligeras y complejas. Por ejemplo, Chen et al., desarrolló un modelo impreso en 3D personalizado para un paciente en el tratamiento de las fracturas del radio distal (Chen y col., 2017). Rao diseñó y fabricó una NCCB impreso en 3D personalizado para la inmovilización del tobillo (Rao y col., 2015). A pesar de la existencia de estudios referentes a la construcción de órtesis por AM, la mayoría de estos se centraron en la fabricación y personalización de las mismas, despreciando la importancia de su comportamiento mecánico.

Varios estudios han comprobado que las órtesis impresas en 3D son significativamente más livianas, permiten la circulación de aire y se ajustan mejor a la anatomía del paciente en comparación con las órtesis tradicionales. A pesar de esto, el tiempo de fabricación FDM es más lento que los métodos tradicionales. Este problema se relaciona con tiempo requerido durante la fase de diseño y personalización del dispositivo. En consecuencia, es necesario encontrar métodos/enfoques que permitan ahorrar tiempo durante las fases de diseño y construcción.


### ***Deformación de las Órtesis***

A pesar de la existencia de estudios relacionados con la construcción de NCCB por AM, estos análisis previos se enfocan netamente en la fabricación (Lin y col., 2016; Zhang y Kwok, 2019). Es decir, la calidad del producto y su comportamiento en condiciones de carga/esfuerzo no se han considerado según nuestro conocimiento.

Una de las propiedades mecánicas esenciales del MCB que describe el desempeño de las piezas bajo condiciones de carga/esfuerzo es la deformación  $\delta$ . Esta propiedad está relacionada directamente con la cantidad de energía que la pieza puede soportar antes de fallar (O'brien y col., 2002). La  $\delta$  total es una medida puramente geométrica que tiene un componente plástico ( $\delta_p$ ) que disipa energía, y un componente elástico ( $\delta_e$ ), que almacena energía (O'brien y col., 2002). En general, la capacidad de almacenar ( $\delta_e$ ) o disipar energía ( $\delta_p$ ) es fundamental ya que define el comportamiento dúctil o frágil de un material.

Figura 20

Tipo de Falla del MCB




*Nota:* (a) Comportamiento frágil del MCB en ensayo de compresión y, (b) Comportamiento dúctil del MCB en ensayo de compresión

En particular, la selección de los parámetros del proceso puede influir en las propiedades mecánicas de las piezas (Mohamed y col., 2015), incluido su comportamiento dúctil o frágil (Ver Figura 20). El comportamiento frágil se caracteriza por una deformación puramente elástica (es decir,  $\delta \approx \delta_e$ ). Por lo tanto, los materiales que se comportan como frágiles solo almacenan energía, por lo cual al momento del fallo toda la energía guardada se libera generando una explosión (O'brien y col., 2002), (Ver Figura 20(a)). Por otro lado, en condición dúctil, antes de fallar, la pieza almacena energía hasta un punto y luego experimenta un proceso de disipación (mientras se deforma plásticamente) (es decir,  $\delta = \delta_p + \delta_e$ ). Por esta razón en el fallo, el material se desgarrar (O'brien y col., 2002), como se muestra en la Figura 20 (b). En consecuencia, dado que en el presente estudio

se utilizó el mismo material (PLA) para todas las muestras, la deformación dúctil ( $\delta_{ductil} = \delta_p + \delta_e$ ) tenderá a ser mayor que la deformación frágil ( $\delta_{fragil} = \delta_e$ ) como se puede observar en la Figura 21.

**Figura 21**

*Esquema representativo de los tipos de deformación*



*Nota:*(a) Gráfico carga-deformación y, (b) Descripción de los diversos tipos de deformación (Toscano y col., 2021)

Esta condición variable (es decir, comportamiento frágil/dúctil) se puede aprovechar para diferentes aplicaciones de NCCB. Mihalko (Mihalko y col., 1989), analizó las propiedades mecánicas y las características de los materiales con lo que se fabrican las órtesis tradicionales. Su estudio concluyó que en las últimas semanas de tratamiento, las órtesis deben resistir el aumento de actividad del paciente. Es decir, es preferible un comportamiento dúctil si la órtesis estará sujeta a golpes o impactos ocasionales. Un análisis similar fue realizado por Brodsky (Brodsky y col., 2007). Su equipo de trabajo estudió las propiedades físicas y la disipación de energía de un tipo particular órtesis utilizados en las plantillas de pacientes con diabetes. Brodsky afirma que en este caso, las órtesis actúan como amortiguadores o distribuidoras de carga por lo cual un comportamiento dúctil es buscado. Por otro, la ductilidad no es deseada para aplicaciones detalladas o cuando la inmovilización es crítica. Daines (Daines y col., 2014) analizó el mejor material para moldear modelos en niños. Su estudio concluyó que la deformación grande se extiende sobre un área considerable; por lo cual, las órtesis de materiales dúctiles son menos precisas que las órtesis construidas con materiales frágiles.

### **Domain Adaptation**

Si los datos SD y TD comparten estructuras similares, como la distribución de esfuerzos mostrada en la Figura 19, DA se puede utilizar para modelar el TD aprovechando la información en SD. En general, los estudios de DA se han centrado principalmente en tareas de clasificación, en áreas como bioinformática, visión artificial, procesamiento de lenguaje, procesamiento de imágenes, detección de objetos entre otras (Chopra y col., 2013; Hajifar y Sun, 2020; Kouw y Loog, 2018; Moon y col., 2020; Van Kasteren y col., 2010; Widmer y col., 2010). Sin embargo, las aplicaciones de DA no se limitan a la clasificación, y también se ha utilizado en regresión. Por ejemplo, Garcke (Garcke y Vanck, 2014) propuso dos métodos de regresión basados en la ponderación de importancia de los dominios. En particular, se asigna un peso a cada instancia de un dato secundario de manera que los datos mejoren y faciliten la predicción de un dato TD. En este capítulo, se explora el DA para la predicción del perfil de  $\delta$  de las MCB obtenidas por FDM. Un perfil se define como la relación funcional entre una variable de respuesta y uno o más predictores (Hajifar y Mahlooji, 2021). De esta manera se logra reducir el tiempo de prueba y error en el diseño y construcción de un MCB altamente personalizado.


### **Método**

Para predecir la deformación  $\delta$  de MCB obtenido por FDM, se estudio tres parámetros de proceso; temperatura de impresión, altura de capa y ancho de extrusión como se muestra en la Figura 22. La altura de la capa se ajusta en un rango de  $0.3mm$  a  $0.48mm$ , el ancho de extrusión de  $0.63mm$  a  $0.8mm$  y la temperatura de impresión de  $200^{\circ}C$  a  $220^{\circ}C$ . En estudios anteriores, estos parámetros han mostrado una fuerte influencia con las propiedades mecánicas de la pieza 3D (Ahn y col., 2002; Mohamed y col., 2015; Wang y col., 2007). Además, los rangos de parámetros se seleccionan en función de las características de la impresora (por ejemplo, el diámetro de la boquilla define el ancho de extrusión y la altura de la capa) y su capacidad para imprimir la geometría deseada (por ejemplo, un ancho de extrusión más grueso daría lugar a la pérdida de detalles finos

durante el proceso de impresión). Con base en estos parámetros, se utiliza un diseño central compuesto y full-factorial para determinar el número de muestras para la SD y TD, respectivamente. Para la construcción MCB, el tiempo de impresión es proporcional al tamaño de la pieza impresa; por lo tanto, el potencial de DA se explota tomando partes más pequeñas (es decir, partes de tamaño reducido) como SD y partes más grandes (es decir, partes de tamaño completo) como TD. Una vez finalizado el proceso de impresión, el  $\delta$  de cada muestra se mide mediante una prueba de compresión realizada en una máquina de prueba universal Instron 8801 (consulte la Figura 22 (c)). Luego, modelamos el  $\delta$  con los parámetros de proceso (es decir, temperatura de impresión, altura de capa y ancho de extrusión) como se muestra en la Figura 22(d).

**Figura 22**

*Método para el modelamiento de  $\delta$  aplicando técnicas de DA*



*Nota:* (a) Diseño del MCB y Máquina FDM, (b) Proceso de Impresión, (c) Ensayos Mecánicos, y, (d) Modelamiento.

### **Caracterización del MCB**

El diseño, fabricación y modelamiento del MCB se describe en la sección . Una vez finalizado el proceso de impresión, la pieza adquirida se somete a una prueba de compresión con una

máquina de prueba universal Instron 8801, como se muestra en la Figura 22. El MCB construido se carga hasta que falla, y el  $\delta$  se registra durante la prueba de compresión, como se muestra en la Figura 14. A continuación, se explicara los procedimientos de DA para modelar y predecir el  $\delta$  obtenido de TD usando SD y TD como datos de entrenamiento.

### ***Domain Adaptation***

Para aprovechar completamente la información potencial de las partes de tamaño reducido (SD) y generalizarla a las partes de tamaño completo (TD), explotamos las capacidades de adaptación de dominio. Para ello, utilizamos el análisis de componentes de transferencia semi-supervisado (SSTCA)(Pan y col., 2010).

Para evaluar el desempeño de SSCTA, se utilizan pruebas fuera de la muestra. Más específicamente, en iteraciones específicas (una iteración por cada observación objetivo), se supone que una de las observaciones objetivo no está etiquetada y que las otras observaciones objetivo junto con las observaciones fuente están etiquetadas. A partir de entonces, se aplica SSTCA a la configuración semi-supervisada mencionada y se calcula su error correspondiente. Finalmente, el rendimiento general se puede calcular promediando el error sobre todas las observaciones objetivo.

Para evaluar el desempeño de SSCTA, se utilizan pruebas fuera de la muestra. Específicamente, en ciertas iteraciones (una iteración por cada muestra del TD), se supone que se desconoce la respuesta de una de las muestras del TD. Al mismo tiempo se asumen que se tiene información sobre los valores de respuesta de las muestras restantes del TD y SD si tienen respuesta. Posteriormente, se aplica SSTCA en la configuración semi-supervisada mencionada anteriormente y se calcula su error correspondiente. Finalmente, el rendimiento general se puede calcular promediando el error de todas las observaciones del TD. En particular el desempeño del método propuesto se compara con un escenario sin DA donde se aplica una regresión lineal a los datos de origen. Posteriormente, el modelo obtenido se utiliza para predecir las respuestas de los datos del TD. Los parámetros del SSTCA se seleccionan de forma iterativa para minimizar el error resultante.

## Caso de Estudio

Como se mencionó en los apartados anteriores, se analizó un caso de estudio real de un MCB construido por FDM.

### Proceso FDM

En la construcción del MCB se utiliza una máquina Aurora Z605 RepRap 3D FDM con una boquilla de 0,6 mm, que utiliza un filamento de PLA de 1,75 mm de diámetro. Los MCB de tamaño reducido (SD) y de tamaño completo (TD) se obtienen de un diseño de experimentos central compuesto de 19 corridas y un diseño de experimentos full-factorial de 10 corridas respectivamente, variando los parámetros del proceso controlables es decir, ancho de extrusión, altura de capa y temperatura de impresión.

### Resultados

El SD se compone de 19 partes de tamaño reducido (50 % de tamaño real) y el TD consta de 10 partes de tamaño completo (tamaño del paciente). El ancho de extrusión ( $x_1$ ), la altura de la capa ( $x_2$ ), la temperatura de impresión ( $x_3$ ) y sus interacciones de segundo orden ( $x_1x_2$ ,  $x_1x_3$  y  $x_2x_3$ ) se consideran predictores. La Figura 23 muestra la influencia de las variables de entrada sobre la deformación para SD y TD. Para implementar SSTCA, utilizamos el "Domain Adaptation Toolbox" de MATLAB (Yan, 2020). Ajustamos la dimensión del nuevo subespacio como se describe en la sección donde la dimensión del nuevo subespacio puede variar de 1 a 6. Para los parámetros restantes de SSTCA, seguimos a Pan (Pan y col., 2010).

En la Tabla 3 se muestra un resumen de los resultados del Error absoluto medio (MAE) y la desviación estándar del error del TD. El MAE de la prueba se calcula de la siguiente manera:

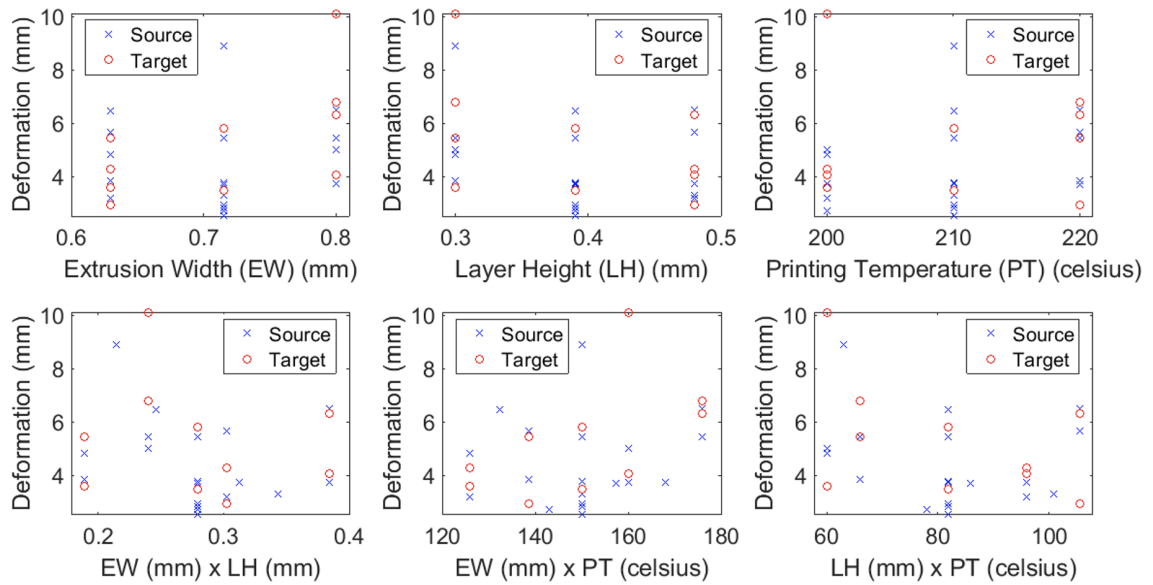
$$MAE = \frac{\sum_{i=1}^{n_2} |\delta_i - \hat{\delta}_i|}{n_2} \quad (4)$$

donde  $\delta_i$  y  $\hat{\delta}_i$  son la deformación real y la deformación predicha para la  $i$ -ésima muestra en el TD, respectivamente.



**Figura 23**

*Influencia de los predictores en  $\delta$  para SD y TD*



Como se puede observar en la Tabla 3, el método basado en SSTCA supera al modelo de referencia (Regresión lineal), donde esta regresión se ajusta únicamente con los datos del SD. El modelo de referencia se selecciona para emular el caso en el que el investigador únicamente consideraría los datos de tamaño reducido al no tener el recurso temporal para recopilar los datos de tamaño completo.

Como se describe en la sección , la capacidad de SSTCA para generalizar un modelo se basa en dos principios:

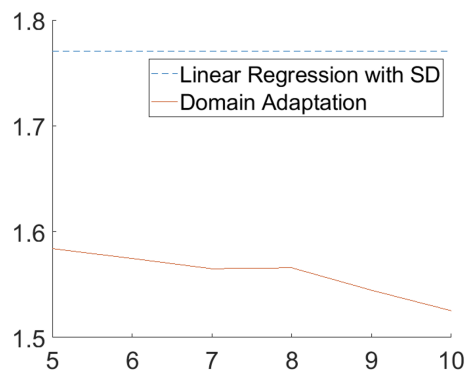
1. Alinear los dominios de los datos de origen(SD) y destino (TD)
2. Descubrir el conocimiento latente en la relación entre las variables respuesta del SD y del TD

En el presente estudio, SSTCA no se puede beneficiar significativamente de la alineación de los dominios, dado que el diseño de experimentos para ambos dominios se basan en rangos y parámetros idénticos. Por lo tanto, se atribuye el desempeño superior del SSTCA a su capacidad de descubrir información latente entre dominios.

**Tabla 3***MAE y Desviación estándar del error en el TD*

<b>Modelo</b>	<b>MAE</b>	<b>Desviación estándar del Error</b>
Regresión Lineal	1.7706	2.048
SSTCA	1.5252	2.0051

Para confirmar que el rendimiento superior del SSTCA se deriva del segundo punto, se analizó el impacto del número de observaciones de TD en el rendimiento de SSTCA. Con ese fin, se seleccionó aleatoriamente diferente número muestras de las partes de tamaño completo (es decir, partes del tamaño del paciente) para incluirlas en la TD. Posteriormente, se procedió a iterar cada ensayo 100 veces con la finalidad de disminuir el impacto de la aleatoriedad en los resultados mismos que son ilustrados en la Figura 24. De este gráfico, se puede concluir que SSTCA generalmente tiene un mejor desempeño si existe un mayor número de observaciones en el TD. Este fenómeno se justifica, ya que una mayor cantidad de muestras de TD facilita el descubrimiento de las relaciones existentes entre las etiquetas (respuestas) de SD y TD.

**Figura 24***Número de Observaciones en TD*

## Resumen

Una órtesis es un dispositivo diseñado para proporcionar inmovilización o apoyo a la zona lesionada del paciente durante el proceso de rehabilitación. Las órtesis tradicionales no se ajustan a los pacientes con precisión, ya que a menudo los ortopedistas los hacen manualmente en función de su experiencia. Adicionalmente se pueden identificar varios problemas con las órtesis tradicionales, como el desperdicio de material, peso excesivo, y poca ventilación, por lo tanto, afectan la comodidad de los pacientes durante su recuperación. Con el desarrollo de AM, NCCB se puede personalizar completamente en función de la forma del cuerpo del paciente, así como de las necesidades requeridas según el tratamiento adecuado. Las investigaciones existentes referentes a impresión 3D de NCCB, son principalmente focalizados en la fabricación. Es decir su rendimiento en condiciones de carga aún no se ha considerado completamente. Esto se debe a que la impresión de NCCB puede llevar mucho tiempo. En este capítulo, se propone aplicar Transfer Learning para utilizar la información recopilada del NCCB de tamaño reducido (SD) para el modelado y la predicción de la deformación del NCCB del tamaño completo (TD). Se estudió la deformación total (es decir, la variable de salida) ya que esta variable refleja información sobre la ductilidad del NCCB en condiciones de carga. En general sería preferible un comportamiento dúctil si el yeso está sujeto a golpes o impactos ocasionales. En particular, se usa SSTCA para alinear los datos de NCCB de tamaño reducido y de tamaño completo, y se muestra que después de la SSTCA, la NCCB del tamaño del paciente se puede predecir con precisión.

## Capítulo V

### Conclusiones y Trabajo Futuro

#### Conclusiones

Las órtesis se describen como soportes o dispositivos externos que se aplican al cuerpo para modificar las características funcionales o estructurales del sistema neuromusculoesquelético. El desarrollo NCCB ha sido investigado por equipos médicos y de ingeniería para evitar los problemas causados por las órtesis tradicionales. Con el desarrollo AM es posible la construcción de piezas complejas y personalizadas. FDM es una técnica de AM que se utiliza para construir NCCB personalizados. En el presente trabajo, se muestra un método eficaz para modelar un NCCB para lesiones metacarpianas como fracturas, esguinces, torceduras y contracturas. Sin embargo para asegurar la funcionalidad de los NCCB, las propiedades mecánicas de las mismas tienen que ser controladas. Las investigaciones existentes referentes a impresión 3D de NCCB, son principalmente focalizados en la fabricación. Es decir su rendimiento en condiciones de carga aún no se ha considerado completamente.

El objetivo de la primera parte de este estudio (ver Capítulo III) es modelar la CS soportada por el NCCB en función de parámetros de proceso escalares (es decir, ancho de extrusión, altura de la capa y temperatura de impresión) así como de parámetros de proceso funcionales (vibraciones, temperatura y humedad). Para lograr este objetivo, se utilizó un diseño de experimentos central compuesto para la recolección de datos y se diseñó un DAQ personalizado para recolectar varias medidas in-situ. El DAQ fue capaz de capturar adecuadamente las variaciones de vibraciones, temperatura y humedad relativa durante el proceso de impresión. Para obtener el CS, se realizaron pruebas de compresión en una máquina de ensayos universales Instron 8801. Finalmente se exploran tres métodos de ML, Lasso, RF y SVM. RF mostró el mejor desempeño en la predicción de CS seguido de SVM y finalmente Lasso. En particular, el enfoque de RF puede predecir el CS con un error de 15,79 % y 6.46 % en los datos de prueba y entrenamiento respectivamente.

Uno de los problemas generados en el proceso de FDM es la recopilación de datos. Esto se debe a que la impresión de NCCB puede llevar mucho tiempo. En la segunda parte de este proyecto (ver Capítulo IV), se propone utilizar TL para utilizar la información recopilada de las NCCB de tamaño reducido (SD) en el modelado y predicción de la deformación de las NCCB de tamaño completo (TD). En particular, se estudió la deformación total ya que esta variable puede reflejar información sobre ductilidad de las NCCB en condiciones de carga. En general un comportamiento dúctil es deseado cuando el NCCB está sujeto a golpes o impactos ocasionales, mientras que un comportamiento frágil es deseado cuando se requieren aplicaciones precisas o cuando el paciente estará en reposo absoluto. Se utilizó el método SSTCA para alinear los dominios de datos de NCCB del SD y TD, y se muestra que después de la aplicación del SSTCA, la NCCB del tamaño del paciente se puede predecir con precisión y que el error obtenido se reduce considerablemente al utilizar las observaciones del TD.

### **Trabajo Futuro**

Para el modelado de las propiedades mecánicas se propone (1) extraer otras características funcionales de las mediciones in-situ distintas de la media, la desviación estándar, kurtosis y skewness. Después de establecer el modelo, también se planea (2) explorar el monitoreo y control del proceso para el FDM. Adicionalmente se plantea (3) considerar las mediciones in-situ siguiendo la metodología de TL, y (4) aplicar los métodos de TL al modelado conjunto de otras propiedades mecánicas.

## Referencias

- A. Gómez, A. G. y. F. V., J. Archilla. (2010). Ortesis activas y desarrollo del modelo cinemático para miembro superior. *Congreso Nacional de Ingeniería Mecánica, Bucaramanga*.
- Ahn, S.-H., Montero, M., Odell, D., Roundy, S. & Wright, P. K. (2002). Anisotropic material properties of fused deposition modeling ABS. *Rapid prototyping journal*, 8(4), 248-257.
- Andrade, L. (2019). Manufactura de Férulas para el tratamiento de artritis de muñeca aplicando tecnología de impresión 3D. *ESPE*.
- Andreas, G. (2011). Understanding Additive Manufacturing—Rapid Prototyping, Rapid Tooling, Rapid Manufacturing.
- Arivazhagan, A. & Masood, S. (2012). Dynamic mechanical properties of ABS material processed by fused deposition modelling. *Int. J. Eng. Res. Appl*, 2(3), 2009-2014.
- Bernard, A. & Fischer, A. (2002). New trends in rapid product development. *CIRP Annals*, 635-652.
- Brodsky, J. W., Pollo, F. E., Cheleuitte, D. & Baum, B. S. (2007). Physical properties, durability, and energy-dissipation function of dual-density orthotic materials used in insoles for diabetic patients. *Foot & Ankle International*, 28(8), 880-889.
- Chang, K.-Y. & Chon, S.-C. (2012). The effect of abdominal-compression belt on balance ability with one leg standing. *Journal of the Ergonomics Society of Korea*, 31(2), 337-343.
- Chen, Y.-J., Lin, H., Zhang, X., Huang, W., Shi, L. & Wang, D. (2017). Application of 3D-printed and patient-specific cast for the treatment of distal radius fractures: initial experience. *3D Printing in Medicine*, 3(1), 1-9.
- Choi, K., Fazekas, G., Sandler, M. & Cho, K. (2017). Transfer learning for music classification and regression tasks. *arXiv preprint arXiv:1703.09179*.
- Chopra, S., Balakrishnan, S. & Gopalan, R. (2013). Dlid: Deep learning for domain adaptation by interpolating between domains. *ICML workshop on challenges in representation learning*, 2(6).

- Cignoni, P., Callieri, M., Corsini, M., Dellepiane, M., Ganovelli, F. & Ranzuglia, G. (2008). Mesh-lab: an open-source mesh processing tool. *Eurographics Italian chapter conference, 2008*, 129-136.
- Daines, S. B., Aronsson, D. D., Beynnon, B. D., Sturnick, D. R., Lisle, J. W. & Naud, S. (2014). What is the best material for molding casts in children? *Journal of Pediatric Orthopaedics*, 34(7), 743-748.
- Esmanhotto, A. & Esmanhotto, G. (2013). A simple idea for reducing the cost and weight of plaster-cast orthoses. *Revista Brasileira de Ortopedia*, 48(1), 17-21.
- Farah, S., Anderson, D. G. & Langer, R. (2016). Physical and mechanical properties of PLA, and their functions in widespread applications—A comprehensive review. *Advanced Drug Delivery Reviews*, 107, 367-392.
- Fitzpatrick, A. P., Mohammed, M. I., Collins, P. K. & Gibson, I. (2017). Design of a patient specific, 3D printed arm cast. *KnE Engineering*, 135-142.
- Fuentes, M. (2017). Diseño y Ensayo de Férulas Personalizadas mediante Impresión. *Universidad de Sevilla*.
- Garcke, J. & Vanck, T. (2014). Importance weighted inductive transfer learning for regression. *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, 466-481.
- Gebuhr, P., Holmich, P., Orsnes, T., Soelberg, M., Krasheninnikoff, M. & Kjersgaard, A. (1992). Isolated ulnar shaft fractures. Comparison of treatment by a functional brace and long-arm cast. *The Journal of bone and joint surgery. British volume*, 74(5), 757-759.
- González, V., Barrientos, D., Blasco, J., Carrió, F., Egea, X. & Sanchis, E. (2012). Data Acquisition in Particle Physics Experiments. *Data Acquisition Applications*. IntechOpen.
- Guyton, G. P. (2005). An analysis of iatrogenic complications from the total contact cast. *Foot & Ankle International*, 26(11), 903-907.
- Hajifar, S. & Mahlooji, H. (2021). Phase II monitoring of generalized linear profiles under different types of changes. *Scientia Iranica*, 28(1), 557-571.

- Hajifar, S., Purnanandam, R., Sun, H. & Zhou, C. (2019). Exploring the Multi-Stage Effects of Material Preparation and Printing on 3D Printing Product Quality. *International Manufacturing Science and Engineering Conference*, 58745, V001T01A025.
- Hajifar, S. & Sun, H. (2020). Online Domain Adaptation for Continuous Cross-Subject Liver Viability Evaluation Based on Irregular Thermal Data. *arXiv preprint arXiv:2011.12408*.
- Hajifar, S., Sun, H., Megahed, F. M., Jones-Farmer, L. A., Rashedi, E. & Cavuoto, L. A. (2021). A forecasting framework for predicting perceived fatigue: Using time series methods to forecast ratings of perceived exertion with features from wearable sensors. *Applied Ergonomics*, 90, 103262.
- Han, H., Guo, X. & Yu, H. (2016). Variable selection using mean decrease accuracy and mean decrease gini based on random forest. *2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*, 219-224.
- Hastie, T., Tibshirani, R. & Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer Science & Business Media.
- Huang, J., Segura, L. J., Wang, T., Zhao, G., Sun, H. & Zhou, C. (2020). Unsupervised learning for the droplet evolution prediction and process dynamics understanding in inkjet printing. *Additive Manufacturing*, 35, 101197.
- Huang, J., Wang, T., Segura, L. J., Joshi, G. S., Sun, H. & Zhou, C. (2020). Spatiotemporal Fusion Network for the Droplet Behavior Recognition in Inkjet Printing. *International Manufacturing Science and Engineering Conference*, 84256, V001T01A038.
- Imani, F., Gaikwad, A., Montazeri, M., Rao, P., Yang, H. & Reutzel, E. (2018). Layerwise in-process quality monitoring in laser powder bed fusion. *ASME 2018 13th International Manufacturing Science and Engineering Conference*.
- Kouw, W. M. & Loog, M. (2018). An introduction to domain adaptation and transfer learning. *arXiv preprint arXiv:1812.11806*.
- Levy, A. E. & Barragán, J. M. C. (2003). *Ortopodología y aparato locomotor: ortopedia de pie y tobillo*. Elsevier.



- Li, J., Jin, R. & Hang, Z. Y. (2018). Integration of physically-based and data-driven approaches for thermal field prediction in additive manufacturing. *Materials & Design*, 139, 473-485.
- Lin, H., Shi, L. & Wang, D. (2016). A rapid and intelligent designing technique for patient-specific and 3D-printed orthopedic cast. *3D Printing in Medicine*, 2, 1-10.
- Lu, W., Liang, B., Cheng, Y., Meng, D., Yang, J. & Zhang, T. (2016). Deep model based domain adaptation for fault diagnosis. *IEEE Transactions on Industrial Electronics*, 64(3), 2296-2305.
- Martínez, B. (s.f.). *Tipos de Fractura y como se tratan*. <https://www.prensalibre.com/vida/salud-y-familia/cuales-son-los-tipos-de-fractura-de-brazo-y-como-se-tratan/>
- Masood, S. H., Mau, K. & Song, W. (2010). Tensile properties of processed FDM polycarbonate material. *Materials Science Forum*, 654, 2556-2559.
- Mihalko, W. M., Beaudoin, A. J. & Krause, W. R. (1989). Mechanical properties and material characteristics of orthopaedic casting material. *Journal of Orthopaedic Trauma*, 3(1), 57-63.
- Miller, D. (2020). StandardCyborg Cocoa [Accessed: 2020-08-20].
- Mohamed, O. A., Masood, S. H. & Bhowmik, J. L. (2015). Optimization of fused deposition modeling process parameters: a review of current research and future prospects. *Advances in Manufacturing*, 3(1), 42-53.
- Montero, M., Roundy, S., Odell, D., Ahn, S.-H. & Wright, P. K. (2001). Material characterization of fused deposition modeling (FDM) ABS by designed experiments. *Society of Manufacturing Engineers*, 10(13552540210441166), 1-21.
- Moon, J., Das, D. & Lee, C. G. (2020). Multi-step online unsupervised domain adaptation. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 41172-41576.
- O'Brien, J. F., Bargteil, A. W. & Hodgins, J. K. (2002). Graphical modeling and animation of ductile fracture. *Proceedings of the 29th annual conference on Computer graphics and interactive techniques*, 291-294.

- Pan, S. J., Kwok, J. T., Yang, Q. y col. (2008). Transfer learning via dimensionality reduction. *AAAI*, 8, 677-682.
- Pan, S. J., Tsang, I. W., Kwok, J. T. & Yang, Q. (2010). Domain adaptation via transfer component analysis. *IEEE Transactions on Neural Networks*, 22(2), 199-210.
- Pei, E., Lanzotti, A., Grasso, M., Staiano, G. & Martorelli, M. (2015). The impact of process parameters on mechanical properties of parts fabricated in PLA with an open-source 3-D printer. *Rapid Prototyping Journal*, 21(5), 604-617.
- Percoco, G., Lavecchia, F. & Galantucci, L. M. (2012). Compressive properties of FDM rapid prototypes treated with a low cost chemical finishing. *Research Journal of Applied Sciences, Engineering and Technology*, 4(19), 3838-3842.
- Radomski, M. V. & Latham, C. A. T. (2008). *Occupational therapy for physical dysfunction*. Lippincott Williams & Wilkins.
- Rao, P. K., Liu, J. P., Roberson, D. & Kong, Z. J. (2015). Sensor-based online process fault detection in additive manufacturing. *ASME 2015 International Manufacturing Science and Engineering Conference*.
- Rayegani, F. & Onwubolu, G. C. (2014). Fused deposition modelling (FDM) process parameter prediction and optimization using group method for data handling (GMDH) and differential evolution (DE). *The International Journal of Advanced Manufacturing Technology*, 73(1-4), 509-519.
- Russell, S. & Norvig, P. (2002). *Artificial intelligence: a modern approach*.
- Segura, L. J., Muñoz, C. N., Zhou, C. & Sun, H. (2020). Sketch-Based Tensor Decomposition for Non-Parametric Monitoring of Electrospinning Processes. *International Manufacturing Science and Engineering Conference*, 84263, V002T09A002.
- Segura, L. J., Wang, T., Zhou, C. & Sun, H. (2021). Online droplet anomaly detection from streaming videos in inkjet printing. *Additive Manufacturing*, 38, 101835.

- Segura, L. J., Zhao, G., Sun, H. & Zhou, C. (2019). Gaussian process tensor responses emulation for droplet solidification in freeze nano 3D printing of energy products. *International Manufacturing Science and Engineering Conference*, 58745, V001T01A024.
- Segura, L. J., Zhao, G., Zhou, C. & Sun, H. (2020). Nearest neighbor gaussian process emulation for multi-dimensional array responses in freeze nano 3d printing of energy devices. *Journal of Computing and Information Science in Engineering*, 20(4).
- Sheth, S., Taylor, R. M. & Adluru, H. (2017). Numerical investigation of stiffness properties of FDM parts as a function of raster orientation. *Solid Freeform Fabrication*.
- Slutsky, D. J. (2016). *Techniques in Wrist and Hand Arthroscopy E-Book*. Elsevier Health Sciences.
- Sood, A. K., Ohdar, R. K. & Mahapatra, S. S. (2010). Parametric appraisal of mechanical property of fused deposition modelling processed parts. *Materials & Design*, 31(1), 287-295.
- Toscano, J. D., Hajifar, S., Segura, C. O., Segura, L. J. & Sun, H. (2021). Deformation Analysis of 3D Printed Metacarpophalangeal and Interphalangeal Joints via Transfer Learning. *International Manufacturing Science and Engineering Conference*, 85062, V001T01A014.
- Toscano, J. D., Li, Z., Segura, L. J. & Sun, H. (2020). A Machine Learning Approach to Model the Electrospinning Process of Biocompatible Materials. *International Manufacturing Science and Engineering Conference*, 84263, V002T06A031.
- Unnithan, A. R., Sasikala, A. R. K., Park, C. H. & Kim, C. S. (2019). *"Biomimetic Nanoengineered Materials for Advanced Drug Delivery"*. Elsevier.
- Van Kasteren, T., Englebienne, G. & Kröse, B. J. (2010). Transferring knowledge of activity recognition across sensor networks. *International Conference on Pervasive Computing*, 283-300.
- Wang, C. C., Lin, T.-W. & Hu, S.-S. (2007). Optimizing the rapid prototyping process by integrating the Taguchi method with the Gray relational analysis. *Rapid prototyping journal*.
- Widmer, C., Toussaint, N. C., Altun, Y., Kohlbacher, O. & Rätsch, G. (2010). Novel machine learning methods for MHC class I binding prediction. *IAPR International Conference on Pattern Recognition in Bioinformatics*, 98-109.
- Yan, K. (2020). A domain adaptation toolbox.

Zhang, Y. & Kwok, T.-H. (2019). Customization and topology optimization of compression casts/braces on two-manifold surfaces. *Computer-Aided Design*, 111, 113-122.