



Institución Universitaria

Evaluación del uso de técnicas de Machine Learning para el análisis de patrones de interferencia modal en sensores de specklegramas de fibra óptica

Juan David Arango Moreno

Instituto Tecnológico Metropolitano

Facultad de Ingenierías

Medellín, Colombia

2023

Evaluación del uso de técnicas de Machine Learning para el análisis de patrones de interferencia modal en sensores de specklegramas de fibra óptica

Juan David Arango Moreno

Tesis presentada como requisito parcial para optar al título de:

Magíster en Automatización y Control Industrial

Director:

Ph.D. Jorge Alexis Herrera Ramírez

Codirector:

Ph.D. Juan Felipe Carrasquilla Álvarez

Línea de Investigación:

Visión Artificial y Fotónica

Grupo de Investigación:

Automática Electrónica y Ciencias Computacionales

Instituto Tecnológico Metropolitano

Facultad de ingenierías

Medellín, Colombia

2023

(Dedicatoria o lema)

Los cielos proclaman la gloria de Dios, y el firmamento anuncia la obra de Sus manos. Un día transmite el mensaje al otro día, y una noche a la otra noche revela sabiduría.

Salmos 19:1-2

En esencia, todos los modelos están equivocados, pero algunos son útiles.

George Box

Agradecimientos

Me gustaría expresar mi más profundo agradecimiento a mi director Jorge Alexis Herrera Ramírez, cuyo tiempo y dedicación en mi formación ha sido fundamental para llevar a cabo este proyecto con éxito. No solo me ha guiado en el conocimiento técnico necesario para desarrollar esta tesis, sino que también me ha brindado su sabiduría práctica en distintas áreas y habilidades de la vida.

Quiero agradecer también a mi codirector Juan Felipe Carrasquilla Álvarez y a mi asesor Víctor Hugo Aristizábal Tique, ya que este trabajo se construye no solo con su instrucción y conocimiento, sino también sobre la base de su trabajo previo.

También deseo agradecer a mis compañeros del laboratorio de óptica, cuya presencia y apoyo han hecho que mi aprendizaje sea más agradable y significativo.

Además, quiero expresar mi agradecimiento a los profesores que participaron en este proceso, quienes no solo me proporcionaron información valiosa, sino que también me brindaron su orientación y enfoque para darle más valor a este trabajo.

Tampoco puedo dejar de mencionar el apoyo incondicional de mis padres, quienes siempre me brindaron su ayuda y comprensión durante los momentos difíciles y las nuevas etapas. Sin ellos, este proyecto nunca hubiera sido posible.

Además, quiero reconocer y agradecer a Dios, quien me ha dado las fuerzas y las herramientas necesarias en cada etapa de este trabajo.

Por último, dar mi agradecimiento a las entidades que financiaron algunas fases de esta tesis: el Instituto Tecnológico Metropolitano con el proyecto P20215, el Politécnico Jaime Isaza Cadavid con el proyecto 2020/00132/001, y la Universidad Cooperativa de Colombia con el proyecto INV2903. Su apoyo financiero ha sido de gran ayuda para llevarla a cabo.

Resumen

Los sensores de specklegrama de fibra óptica (FSS), basan su funcionamiento en el análisis de las imágenes tipo speckle que se obtienen a la salida de una fibra multimodo. Estos specklegramas contienen información del estado de la fibra, por ejemplo, una variación de temperatura sobre la fibra cambia la distribución del speckle. Algunos métodos convencionales para analizar este speckle han sido: correlación entre imágenes, medición de potencia y momentos radiales. La principal problemática de estos métodos es su rango dinámico limitado. Por esta razón, este trabajo presenta la evaluación de algunas técnicas de machine learning sobre los FSS y su comparación con los métodos mencionados.

En la primera etapa, se utilizó una simulación FEM (método de elementos finitos) en la plataforma Comsol enlazada con Matlab para generar los specklegramas. Con simulación se crearon varios conjuntos de datos para evaluar algunas técnicas de machine learning y su comparación con los métodos convencionales. Para ello, se desarrollaron varios modelos de redes convolucionales y se entrenaron para predecir temperaturas con specklegramas sintéticos. En estas pruebas se demostró la superioridad de las redes convolucionales sobre los métodos convencionales.

En la segunda etapa, se desarrolló un sistema automatizado para la adquisición de specklegramas experimentales con control PID. Con este se adquirió un conjunto de specklegramas con temperaturas de 25 °C a 200 °C. Estos specklegramas se usaron para entrenar distintas arquitecturas desde redes neuronales clásicas (ANN), redes convolucionales (CNN) y un Transformer de visión (ViT). Las arquitecturas propuestas se compararon con los métodos convencionales y tuvieron un rango dinámico casi 12 veces mayor en la predicción de temperatura. La mejor arquitectura en términos de desempeño y costo computacional fue la MNet-reg. Esta tuvo un error RMSE de 0.943 °C, un tiempo de inferencia de 0.0556 segundos y un número total de parámetros de 6378689.

Se concluye que, el método de análisis para los sensores FSS presentado en esta tesis, mejora radicalmente características metrológicas como el rango dinámico y la sensibilidad, de esta manera se hace cada vez cercano a su implementación en otros entornos diferentes al de laboratorio.

Palabras clave: sensores de fibra óptica, speckle, interferencia modal, redes convolucionales, regresión, aprendizaje de máquina.

Abstract

Fiber Specklegram Sensors (FSS) operate by analyzing the speckle images produced at the output of a multimode fiber. These specklegrams contain information about the state of the fiber, e.g. a temperature variation on the fiber changes the speckle distribution. Some conventional methods to analyze this speckle have been: correlation between images, power measurement and radial moments. The main problem of these methods is their limited dynamic range. For this reason, this thesis presents the evaluation of some machine learning techniques on FSS and their comparison with the mentioned methods.

In the first stage, a FEM (Finite Element Method) simulation in the Comsol platform linked to Matlab was used to generate the specklegrams. With the simulation, several datasets were generated to evaluate some machine learning techniques and their comparison with conventional methods. For this purpose, several convolutional network models were developed and trained to predict temperatures with synthetic specklegrams. These tests demonstrated the superiority of convolutional networks over conventional methods.

In a second step, an automated system for the acquisition of experimental specklegrams with PID control was developed. This system was used to acquire a set of specklegrams at temperatures ranging from 25 °C to 200 °C. These specklegrams were used to train different architectures of classical neural networks (ANN), convolutional networks (CNN) and a vision transformer (ViT). The proposed architectures were compared with conventional methods and had a dynamic range in temperature prediction almost twelve times higher. The best architecture in terms of performance and computational cost was MNet-reg. It had an RMSE error of 0.943 °C, an inference time of 0.0556 seconds, and a total number of parameters of 6378689.

It is concluded that the analysis method for FSS sensors presented in this thesis radically improves metrological characteristics such as dynamic range and sensitivity, thus bringing its implementation at the industrial level ever closer.

Keywords: fiber sensors, speckle, modal interference, convolutional networks, regression, machine learning.

Contenido

	Pág
Agradecimientos	VII
Resumen	IX
Abstract	X
Lista de figuras	XIII
Lista de tablas	XV
Lista de Símbolos y abreviaturas	XVI
Introducción	19
1. Marco Teórico y Estado del Arte	25
1.1. Sensores de specklegrama de fibra óptica (FSS).....	26
1.2. Interferencia modal.....	27
1.3. Métodos de análisis convencionales para los FSS.....	28
1.3.1. Correlación entre imágenes	28
1.3.2. Medición puntual de potencia	29
1.3.3. Momentos radiales	31
1.4. Aprendizaje de máquinas en FSSs.....	32
1.5. Estrategias de medición y diseño para los FSS.....	33
1.5.1. Región de interés (ROI)	33
1.5.2. Uso de dopantes para el diseño.....	34
1.5.3. Longitud de zona sensora	35
1.6. Redes neuronales convolucionales	37
Machine learning	38
2. Justificación y planteamiento del problema	41
2.1. Problema de rango dinámico, sensibilidad y linealidad.....	42
2.2. Metodología.....	43
3. Simulación: specklegramas sintéticos	45
4. Implementación de redes neuronales convolucionales para el análisis de specklegramas sintéticos	50
4.1. Prueba exploratoria: Algoritmo de clasificación	52
4.1.1. Desempeño de pruebas exploratoria con CNN para clasificación con dataset I	53
4.2. Algoritmo de regresión	54
4.2.1. Desempeño de pruebas con CNN para regresión con dataset I	55
4.2.2. Comparación de desempeño entre los métodos de análisis convencionales y la arquitectura CNN-C para regresión con dataset II.....	57
4.3. Entrenamiento con transfer learning.....	59

5. Montaje experimental: specklegramas experimentales	62
5.1. Sistema calefactor.....	62
5.1.1. Acondicionamiento del termistor	63
5.1.2. Control PID	64
5.2. Automatización de la adquisición de specklegramas	65
5.3. Dataset experimental.....	67
6. Arquitecturas de redes neuronales adaptadas para regresión de valores de temperatura de specklegramas experimentales.....	69
6.1. Arquitecturas adaptadas.....	69
6.1.1. VGG16-reg.....	69
6.1.2. MNet-reg.....	69
6.1.3. ENet-reg	70
6.1.4. ANN-reg.....	70
6.1.5. ViT-reg.....	70
6.2. Aumento de datos.....	71
6.3. Optimización de hiperparámetros.....	73
7. Resultados de arquitecturas de redes neuronales adaptadas sobre specklegramas experimentales	75
8. Conclusiones y recomendaciones	82
8.1. Conclusiones	82
8.2. Recomendaciones y trabajo futuro.....	86

Lista de figuras

Figura 1-1:	Fibras ópticas de índice de paso. (a) multimodo, (b) monomodo. Fuente: Autor...	27
Figura 1-2:	Patrón de speckle resultante de la interferencia modal en una fibra óptica multimodo. Fuente: Autor.	28
Figura 1-3:	Métodos de análisis convencionales para los FSS. (a) Correlación entre imágenes, (b) Fotosensor para medición de potencia. Fuente: Autor.	30
Figura 1-4:	Distintos ROI de lectura para un specklegrama de un sensor FSS. Fuente: Autor. .	33
Figura 1-5:	Respuesta del índice de refracción n con respecto a la temperatura para distintas concentraciones del dopante P_2O_5 en la fibra. Fuente: tomado de (Herrera-Ramírez et al., 2018)....	34
Figura 1-6:	Longitud de zona sensora Z que es afectada por una perturbación. Fuente: Autor. ..	36
Figura 1-7:	Influencia de distintas longitudes de zona sensora Z en la sensibilidad (pendiente) del coeficiente de correlación entre los specklegramas con respecto a la temperatura. Fuente: Autor.	36
Figura 1-8:	a) Imagen de $n \times n$ píxeles, b) imagen convertida a vector, así se representaría para entrenar una red ANN, no se conserva su estructura espacial y cada píxel se tomaría como una característica de entrada. Fuente: Autor.	37
Figura 1-9:	Mapa de características obtenido de una imagen transformada por una operación de convolución con un filtro 3×3 . Fuente: adaptado de developer.nvidia.com.	38
Figura 2-1:	Dependencia entre el rango dinámico y la sensibilidad. Fuente: Autor.	42
Figura 2-2:	Diagrama de la metodología llevada a cabo en esta tesis.	44
Figura 3-1:	Representación esquemática de un montaje FSS para medición de temperatura. La porción resaltada de la fibra corresponde con la sección perturbada y simulada por el método FEM. Fuente: Autor.	45
Figura 3-2:	Representación de malla para la simulación de la propagación de modos de luz en una fibra óptica con el método de elementos finitos (FEM) con una aproximación 2.5D. Fuente: Autor.	46
Figura 3-3:	Generación de specklegramas con FEM a distintas aperturas numéricas (NA). Fuente: Autor.	48
Figura 4-1:	Arquitectura CNN usada para la clasificación de temperaturas con specklegramas de entrada. Fuente: Autor.	53
Figura 4-2:	Matriz de confusión para el algoritmo de clasificación con el dataset I.	54
Figura 4-3:	Arquitectura C usada para regresión de temperaturas con specklegramas de entrada. Fuente: Autor.	55
Figura 4-4:	Predicción con el dataset I en datos de prueba de: a) arquitectura A con ratio de aprendizaje de 4×10^{-5} y 100 épocas. B) arquitectura A con ratio de aprendizaje de 4×10^{-5} y 300 épocas, c) arquitectura A con ratio de aprendizaje de 8×10^{-5} y 300 épocas, d) arquitectura B con ratio de aprendizaje de 8×10^{-5} y 300 épocas, e) arquitectura C con ratio de aprendizaje de 8×10^{-5} y 300 épocas, d) arquitectura D con ratio de aprendizaje de 8×10^{-5} y 300 épocas.	56

Figura 4-5: Caracterización del FSS por el método de análisis: a) correlación entre imágenes, b) medición puntual de potencia, c) primer momento radial, d) segundo momento radial..... 58

Figura 4-6: Temperatura real vs temperatura estimada por algoritmo de regresión con CNN (arquitectura C) entrenado con dataset II. 59

Figura 4-7: Temperatura real vs temperatura del dataset III predicha por: a) Arquitectura C, b) Arquitectura VGG16-reg. 61

Figura 5-1: Sistema calefactor de distintas longitudes de zona sensora para perturbaciones térmicas en la fibra óptica multimodo..... 63

Figura 5-2: Acondicionamiento del termistor de NTC 100 K mediante interpolaciones lineales. Los puntos azules son las muestras caracterizadas de *Marlin*, y los naranjados el resultado de interpolaciones entre las muestras. Fuente: Autor. 64

Figura 5-3: Sistema calefactor con control a lazo cerrado. Fuente: Autor. 65

Figura 5-4: Proceso de adquisición. 1) Matlab envía setpoint al arduino y recibe constantemente la temperatura real, hasta alcanzar el valor deseado. 2) Matlab envía la orden de capturar la imagen a la cámara Thorlabs y la almacena. Fuente: Autor..... 66

Figura 5-5: Nomenclatura de cada specklegrama capturado. Nótese que los elementos en rojo son los únicos que cambian en el dataset. 68

Figura 5-6: Specklegramas experimentales capturados por el sistema automatizado con control PID. 68

Figura 6-1: Ilustración de técnicas de aumento de datos aplicadas a specklegramas experimentales: rotación, contraste, escalado, traslación y adición de ruido. 73

Figura 6-2: Ejemplo de algunos intentos (*trials*) de Optuna en la optimización de hiperparámetros para la arquitectura MNet-reg y su efecto en el entrenamiento..... 74

Figura 7-1: Curva de respuesta del coeficiente de correlación entre specklegramas con el cambio en temperatura. a) Curva para el rango completo de datos experimentales; b) reducción del rango a zona lineal entre 25 °C y 40°C..... 75

Lista de tablas

	Pág.
Tabla 0-1: Publicaciones y eventos presentados durante el desarrollo de la tesis.	22
Tabla 4-1: Arquitecturas de redes convolucionales creadas y evaluadas con los specklegramas simulados con FEM. La arquitectura A0 se usa en una tarea de clasificación de 20 clases, capa de salida densa d20 . Las demás arquitecturas en regresión, capa de salida densa d1	51
Tabla 4-2: Conjuntos de datos de specklegramas simulados con FEM.	51
Tabla 4-3: Comparación de desempeño en la predicción con los datos de prueba del dataset II con el algoritmo de regresión CNN y los métodos convencionales.	59
Tabla 5-1: Parámetros usados en el sistema automatizado con control PID para la toma del dataset experimental de specklegramas. Estos parámetros son modificables según se requiera.	67
Tabla 7-1: Métricas de predicción con el dataset experimental para las arquitecturas entrenadas y para los métodos convencionales.	79
Tabla 7-2: Características de los modelos propuestos usando una GPU NVIDIA RTX 3060 para la predicción del conjunto de prueba de specklegramas experimentales. Las unidades del tiempo de inferencia están en segundos para un batch de 32 imágenes. Las unidades del RMSE, del MAE y del error máximo en °C.	80

Lista de Símbolos y abreviaturas

Símbolos con letras latinas

Símbolo	Término	Unidad SI	Definición
A	Área	m^2	$\iint dx dy$
C	Coeficiente de correlación	1	Ec. 1.1
c	Constante velocidad de la luz en el vacío	km/s	DF
Cto	Coeficiente termo óptico	$1/^\circ C$	DF
E	Campo eléctrico	N/C	Ec. 3.1
I	Intensidad	cd	$I = P/(4\pi r^2)$
k	numero de onda	$1/m$	$k = 2\pi / \lambda$
Kd	Constante derivativa	1	Figura 5-3
Ki	Constante integral	1	Figura 5-3
Kp	Constante proporcional	1	Figura 5-3
n	índice de refracción	1	Ec. 3.3
NA	Apertura numérica	1	$NA = \sqrt{(n_1^2 - n_2^2)}$
P	Potencia	W	Ec. 1.2
T	Temperatura	$^\circ C$	DF
Z	Longitud de zona sensora	m	DF

Símbolos con letras griegas

Símbolo	Término	Unidad SI	Definición
ϵ_0	Permitividad del vacío	F/m	DF
μ_p	Momento de orden p	1	Ec. 1.5
λ	Longitud de onda	m	$\lambda = v/f$

Abreviaturas

Abreviatura	Término
<i>ADC</i>	Analog to Digital Converter
<i>ANN</i>	Artificial Neural Network
<i>CNN</i>	Convolutional Neural Network
<i>FEM</i>	Finite Element Method
<i>FMG</i>	Force Myography
<i>FOSS</i>	Fiber Optic Sensing System
<i>FSS</i>	Fiber Specklegram Sensor
<i>MAE</i>	Mean Absolute Error
<i>MLP</i>	Multi-Layer Perceptron
<i>MMF</i>	Multi Mode Fiber
<i>MSE</i>	Mean Squared Error
<i>NA</i>	Numerical Aperture
<i>NASA</i>	National Aeronautics and Space Administration
<i>NTC</i>	Negative Temperature Coefficient
<i>PID</i>	Proportional Integral Derivative
<i>PWM</i>	Pulse Width Modulation
<i>ReLU</i>	Rectified Linear Unit
<i>RGB</i>	Red Green Blue
<i>RMSE</i>	Root Mean Squared Error
<i>ROI</i>	Region Of Interest
<i>SMF</i>	Single Mode Fiber
<i>TIFF</i>	Tag Image File Format
<i>VGG</i>	Visual Geometry Group
<i>VeLO</i>	Versatile Learned Optimizers
<i>ViT</i>	Vision Transformer

Introducción

La medición precisa y en tiempo real de parámetros físicos como la temperatura, la presión o la deformación es de gran importancia en numerosas aplicaciones industriales, médicas y científicas (Farahi, 2015; Webster & Eren, 2014). En este contexto, el uso de algunos fenómenos físico-ópticos ha sido relevante en el desarrollo de algunas áreas de nuestra sociedad como la medicina y la biofotónica, las tecnologías de la información y las comunicaciones, entre otras (Feng et al., 2018; Fujiwara, Paula, et al., 2017; Grattan & Sun, 2000; Hamory et al., 2016; Leal-Junior et al., 2020; Liu et al., 2020). Además, en el área de la metrología, las mediciones ópticas son de interés ya que ayudan a controlar procesos complejos en ambientes exigentes (Farahi, 2015; Haus, 2010). Por ejemplo, los sensores de fibra óptica han demostrado ser una solución efectiva y confiable debido a sus numerosas ventajas. Entre ellas, se incluyen su tamaño reducido, su inmunidad a la interferencia electromagnética y su capacidad de medir distintas variables a lo largo de la fibra (Arango, Vélez, et al., 2021; Fujiwara, Da Silva, et al., 2019; Grattan & Sun, 2000; Leal-Junior et al., 2020).

Existen diferentes técnicas de medición que utilizan sensores de fibra óptica, entre las cuales se encuentran las interferométricas, las de variación de potencia y las espectrales (Krohn et al., 2015; Matias, 2017). Las interferométricas requieren procesos complejos de fabricación (Z. Li et al., 2020; Tian et al., 2017; Wang et al., 2019; Wei et al., 2022; Yong Zhao et al., 2017; Yujia Zhao et al., 2018), las espectrales son muy robustas pero costosas, debido a la necesidad de equipos adicionales como analizadores de espectro (Chen et al., 2011; Reyes-Vera et al., 2017). Así, por la simplicidad de uso, bajo costo y sensibilidad, las técnicas de variación de potencia son de interés, y es en esta clase de técnicas donde se encuentran los sensores de specklegrama de fibra óptica (FSS por sus siglas en inglés - *Fiber Specklegram Sensor*), que son en los que se centra este trabajo.

Los FSSs han recibido mucha atención en los últimos años debido a sus ventajas y bajo costo. Este tipo de sensor se basa en el análisis de los patrones de speckle o *ruido modal*, que se forman con la interferencia modal de una fibra multimodo. La distribución de estos patrones de speckle, o también llamados specklegramas, se ve afectada cuando se perturba la fibra (Efendioglu, 2017; Fujiwara et al., 2018). Es decir, algunas perturbaciones sobre la fibra pueden verse reflejados en el specklegrama a la salida de esta. Estas perturbaciones pueden corresponder a variables físicas como deformaciones, temperatura, flexiones, presión, entre otras (Castaño et al., 2018; Fujiwara,

Da Silva, et al., 2019; Fujiwara, Paula, et al., 2017; Hoyos et al., 2013; Hu et al., 2022; Liu et al., 2020; Rodriguez-Cobo et al., 2015a; Vangety et al., 2022). Así pues, el desempeño de estos sensores está ligado a la capacidad de extracción de la relación de los cambios del specklegrama con los cambios de la variable que se esté midiendo. De ahí la importancia primordial del tipo de método de análisis del specklegrama, ya que este es determinante en si sí se puede extraer la correspondencia entre el valor de la variable y el specklegrama, sobre qué rango es posible hacer esta correspondencia, qué sensibilidad se tiene para detectar pequeños cambios de la variable y con qué precisión se detecta esta variable.

Existen diversos métodos de análisis para los specklegramas como la correlación entre imágenes (Fujiwara et al., 2018; Gubarev et al., 2016), la medición de potencia (Arístizabal et al., 2016) y análisis estadísticos como momentos radiales (Efendioglu, 2017; Efendioglu et al., 2013). Sin embargo, aún existen limitaciones en estos métodos que restringen su uso más generalizado en el campo de los sensores. Los investigadores tienen gran interés en aumentar el rango dinámico de los FSSs, ya que estos sensores pueden tener sensibilidad a diferentes variables de interés en la metrología (Leal-Junior et al., 2020; Yin et al., 1999). De esta manera, si estos métodos se mejoran, los FSSs pueden tener impactos significativos a nivel tecnológico, debido a su bajo costo y las demandas en la industria actual.

En la búsqueda por mejorar estas características metroológicas en los FSS, se ha propuesto usar técnicas de *machine learning*, que han tenido gran impacto en los últimos años en áreas como las ciencias exactas, ingeniería e incluso en las ciencias sociales (Carleo & Troyer, 2017; Gómez et al., 2020; Lee et al., 2021; Rajpurkar et al., 2017; Rosenbusch et al., 2021; Rupp et al., 2012; Tarallo et al., 2019). Además de su impacto específico en investigaciones ópticas (Genty et al., 2021; Ma et al., 2019, 2021). En el estado del arte se encuentran algunas pruebas exploratorias del uso de técnicas de *machine learning* en FSSs de años anteriores (Cuevas et al., 2018; Fujiwara, Wu, et al., 2017). Posterior a estas se investiga el uso de redes convolucionales para clasificación sobre los FSSs y las ventajas que tienen estas redes para trabajar con imágenes (Liu et al., 2020). Y en el último año el estudio de este tipo de sensores ha experimentado un aumento más que notorio (Hu et al., 2022; G. Li et al., 2022; Reyes-Gonzalez et al., 2022; Vangety et al., 2022).

La importancia de esta tesis radica en la búsqueda de un mejor método de análisis para los sensores FSSs basado en técnicas de machine learning. Por esto se puede decir que, un factor distintivo de este trabajo es *el estudio de distintas arquitecturas de machine learning como método de análisis en specklegramas de un FSS para regresión de temperatura y la generación de bases de datos propias para su entrenamiento, tanto simuladas como experimentales*. Las arquitecturas evaluadas en este trabajo fueron: redes neuronales clásicas o perceptrones multicapa (ANN por sus siglas en inglés, *Artificial Neural Network*), redes neuronales convolucionales (CNN por sus siglas en inglés, *Convolutional Neural Network*) y Transformers de visión (ViT por sus siglas en inglés, *Vision Transformer*), que se han investigado en los últimos años en visión artificial (Dosovitskiy et al., 2020; Touvron et al., 2020). Aunque se presentan diferentes arquitecturas, en el desarrollo de este trabajo la arquitectura más predominante es la CNN, esto por su conocido buen desempeño en el estudio de imágenes. Así, en esta investigación se realizaron pruebas de clasificación con CNN y de regresión con todas las arquitecturas propuestas, ya que en el contexto de variables como la temperatura, la regresión es una técnica más adecuada debido a la naturaleza continua de la variable (Arango, Aristizabal, et al., 2021). De esta manera, los objetivos de esta tesis fueron los siguientes:

Objetivo general:

Desarrollar una metodología basada en técnicas de *machine learning* (redes neuronales CNN y ANN) para el análisis de patrones de speckle típicos de un sensor FSS. Esta metodología se aplicará sobre una base de datos, que a su vez será simulada y generada por medio del método de elementos finitos, con intención de mejorar la relación rango-sensibilidad del método de análisis actual de sensores FSS.

Objetivos específicos:

- Desarrollar un procedimiento de simulación por el método de elementos finitos para la generación de una base de datos de patrones de speckle, que den cuenta de los fenómenos físico-ópticos dados en un sensor FSS ante una perturbación física.
- Determinar y adaptar una arquitectura de redes neuronales adecuada para el estudio y predicción de variables a partir de secuencias de imágenes del tipo patrón de speckle.

- Implementar el modelo desarrollado para la predicción de la base de datos y comparar los resultados con la predicción de los métodos convencionales de los sensores FSS. Esta comparación se llevará a cabo con el uso de herramientas métricas.

Las publicaciones y eventos presentados durante el desarrollo de este trabajo se muestran en la siguiente Tabla 0-1:

Tabla 0-1: Publicaciones y eventos presentados durante el desarrollo de la tesis.

Tipo	Revista/Evento	Título	Estado	Cuartil	Anexo
Artículo	Computer Optics	Numerical study using finite element method for the thermal response of fiber specklegram sensors with changes in the length of the sensing zone	Publicado	Q1	Anexo A
Artículo	Journal of Physics Conference Series	Deep learning classification and regression models for temperature values on a simulated fibre specklegram sensor	Publicado	Homologación B publindex 2021	Anexo B
Artículo	Photonic Sensors	Use of a convolutional neural network to predict temperature values in a simulated fiber specklegram sensor and comparison with conventional methods of analysis	En revisión	Q2	Anexo C
Artículo	Data in Brief	Synthetic dataset of speckle images for fiber optic temperature sensor	Publicado	Q2	Anexo D
Ponencia	8 th International Week of Science, Technology, and Innovation (8 th IWSTI)	Comparison of deep learning architectures in regression and classification models for prediction of temperature values in a simulated fiber specklegram sensor	Presentada	N/A	Anexo E
Ponencia	XVII Encuentro Nacional de Óptica y la VIII Conferencia Andina y del Caribe en Óptica y sus Aplicaciones	Using a Convolutional Neural Network to Predict Temperature Values in a Simulated Fiber Specklegram Sensor and its Comparison with Conventional Interrogation Methods	Presentada	N/A	Anexo F

Tipo	Revista/Evento	Título	Estado	Cuartil	Anexo
Ponencia	XXIX Congreso nacional de física	Redes neuronales convolucionales en sensores de specklegrama de fibra óptica y su comparación con otros métodos de análisis convencionales	Presentada	N/A	Anexo G

También están en proceso de escritura otros 3 artículos, correspondientes a:

- Sistema de adquisición de specklegramas automatizado con control PID en preparación para publicación en la revista *Software X*.
- Dataset de 1001 specklegramas experimentales correspondiente a perturbaciones de temperatura entre 25 °C y 200 °C.
- Modelo MNet-reg para predicción de temperatura en specklegramas experimentales.

Además se han llevado a cabo otros trabajos relacionados en el laboratorio de óptica y fotónica del ITM, en los que se aprovecharon los conocimientos adquiridos en esta tesis, tales como: *Design of Porous-Core Photonic Crystal Fiber Based on Machine Learning approach* (finalizando escritura del artículo), *Detección automática de temperatura a partir de la distribución modal de sensores basados en redes de periodo largo: enfoque basado en el aprendizaje profundo* (ponencia presentada en el XXIII Simposio Chileno de Física, Anexo H).

La estructura de esta tesis se organizó de la siguiente manera:

El capítulo 1 aborda el estado del arte alrededor de los FSS, el marco teórico necesario de estos sensores y algunos conceptos relacionados con redes neuronales convolucionales. El capítulo 2 presenta la justificación de este trabajo en el contexto científico que se realiza, la posibilidad de mejora en los FSS, y la propuesta metodológica. El capítulo 3 lleva a cabo la generación de specklegramas sintéticos a través del método de elementos finitos (FEM). El capítulo 4 presenta las arquitecturas de redes convolucionales desarrolladas y usadas como método de análisis sobre los specklegramas sintéticos. El capítulo 5 aborda el desarrollo de un sistema automatizado con control PID para adquirir specklegramas experimentales. El capítulo 6 muestra el entrenamiento de distintas arquitecturas con los specklegramas experimentales adquiridos con el sistema automático desarrollado en el capítulo 5. En el capítulo 7 se muestran los resultados obtenidos con los métodos convencionales y las arquitecturas de machine learning para los datos experimentales. Además, se

comparan las arquitecturas entre sí en términos de desempeño y costo computacional. Por último, el capítulo 8 presenta las conclusiones de este trabajo, recomendaciones y trabajo futuro.

1. Marco Teórico y Estado del Arte

El avance científico y tecnológico ha permitido mantener y ampliar el interés por explorar ciertos fenómenos físico-ópticos. Igualmente, ha permitido incrementar la utilización de estos fenómenos en áreas como la ingeniería, medicina, aviación, entre otros (Feng et al., 2018; Fujiwara, Wu, et al., 2017; Grattan & Sun, 2000; Hamory et al., 2016; Leal-Junior et al., 2020; Liu et al., 2020). Uno de los sectores donde el uso de principios ópticos es de gran interés es la metrología. Esta última juega un papel fundamental en diversos procesos industriales o investigativos, ya que la medición de variables se hace cada vez más necesaria para cumplir con los requerimientos actuales en algunos procedimientos de automatización, de control de calidad o de desarrollo de productos. Por esta razón, la *metrología óptica* se ha expandido mundialmente tanto en procesos industriales como científicos. Además, las características intrínsecas de las mediciones ópticas ayudan en el control de procesos de alta complejidad en ambientes exigentes (Farahi, 2015; Haus, 2010), lo que hace más llamativas estas tecnologías.

En la metrología óptica se destacan algunas técnicas que usan fenómenos como: fluorescencia, absorción, interferencia, polarización, fenómenos no-lineales, variación de potencia óptica, entre otros (Gåsvik, 2002; Gresty, 1979). Entre estas técnicas de sensado que usan principios ópticos, se resaltan aquellos que utilizan las propiedades de propagación de la luz en una guía de onda (por ejemplo, una fibra óptica), como método de transducción de la variable física a medir.

Dentro de las técnicas que usan sensores de fibra óptica más comunes se encuentran: las técnicas interferométricas, las técnicas de variación de potencia y las técnicas espectrales (Krohn et al., 2015; Matias, 2017). Las técnicas interferométricas suelen ser muy sensibles a los efectos ambientales (Fu et al., 2007), además requieren algunos procesos complejos de fabricación (Z. Li et al., 2020; Tian et al., 2017; Wang et al., 2019; Wei et al., 2022; Yong Zhao et al., 2017; Yujia Zhao et al., 2018). Por otra parte, las técnicas espectrales tienden a ser muy robustas y estables, pero necesitan de equipos adicionales para la adquisición, y esto aumenta drásticamente el costo del sensor (Chen et al., 2011; Reyes-Vera et al., 2017). Finalmente, las técnicas de variación de potencia, si bien suelen presentar sensibilidades menores a las técnicas interferométricas, son menos vulnerables a efectos externos (Efendioglu et al., 2011; Z. Zhang & Ansari, 2006). Así, estas últimas pueden tener un buen desempeño a bajo costo. Dentro de estas técnicas se encuentra el *Sensor de Specklegrama de Fibra Óptica*.

Así, este trabajo se enfoca en el análisis de los sensores FSSs que se basan en la interferencia modal presente en las fibras ópticas multimodo. Cuando la luz se acopla a una fibra multimodo, se generan diferentes direcciones de propagación de la luz, conocidas como modos de propagación, cada uno con desfases distintos. Estos modos pueden interferir entre sí, lo que resulta en una distribución de intensidades única o un patrón de speckle característico en la salida de la fibra. Mediante el análisis de este patrón espacial de variación de intensidades, es posible extraer información sobre parámetros físicos o perturbaciones que afecten a la fibra.

1.1. Sensores de specklegrama de fibra óptica (FSS)

Los primeros sistemas FSS se investigaron en los años 90 (Wu et al., 1991; Yu et al., 1994) demostrando la utilidad que tiene el fenómeno de interferencia modal (que se explica en la siguiente sección) en la medición de algunas variables físicas. Con el avance investigativo se han establecido algunos métodos para la medición de los FSS y, actualmente, se están acercando cada vez más a aplicaciones reales (Efendioglu, 2017; Fujiwara et al., 2018; G. Li et al., 2022; Liu et al., 2020; Vangety et al., 2022). Estos sensores, como se abordó antes brevemente, son de gran interés por su sencillez, bajo costo, estabilidad y aplicabilidad directa. Además, otra ventaja que tienen los FSS con respecto a otras alternativas, es que solo necesitan de una fibra óptica multimodal común, sin ningún tratamiento ni elementos grabados en su interior, ya que la misma fibra es la que funciona como transductor de la variable.


Los FSS basan su funcionamiento en la interpretación del patrón de interferencia modal que ocurre a la salida de una fibra óptica multimodo. Esta interferencia también se conoce como ruido modal, que es algo indeseado en el área de las comunicaciones, sin embargo, es útil en el área de la metrología. Esto se debe a que, al cambio de algunas perturbaciones sobre la fibra, el patrón de interferencia o specklegrama también sufre cambios en su distribución espacial (Efendioglu, 2017; Fujiwara et al., 2018). De manera que, si se tienen las herramientas matemáticas adecuadas, se puede conocer el valor de la perturbación externa por medio del análisis del specklegrama. Las variables que suelen medir los FSS son temperaturas (Arango, Vélez, et al., 2021; Castaño et al., 2018; Rodríguez-Cobo et al., 2015b), deformaciones mecánicas (Hoyos et al., 2013), flexiones (Liu

et al., 2020), pesos (Vangety et al., 2022), localización de la perturbación (Cuevas et al., 2018), químicos (Fujiwara, Da Silva, et al., 2019), entre otras (Fujiwara, Wu, et al., 2017; Hu et al., 2022).

1.2. Interferencia modal

La interferencia modal es un fenómeno que ocurre a la salida de una fibra óptica multimodo. Una fibra óptica multimodo (MMF), a diferencia de una fibra óptica monomodo (SMF), tiene las dimensiones aptas para que a ciertas longitudes de onda ocurra la propagación de distintos modos de luz a través del núcleo de la fibra (ver Figura 1-1). Un modo de luz o modo de propagación es una trayectoria específica que recorren las ondas electromagnéticas dentro de la fibra óptica. Nótese que un haz de luz proveniente de un láser puede generar distintos modos en una fibra. Al ocurrir distintos caminos ópticos según los modos existentes y los diferentes retrasos de fase de cada modo de propagación, el campo óptico total a la salida de la fibra se convierte en un patrón complejo de speckle o specklegrama (Hill et al., 1980; Kajenski et al., 1992). Consecuentemente, este es un patrón de intensidades espacialmente variable, con intensidad máxima en las zonas que la interferencia de los modos es totalmente constructiva, y ausencia de luz en las zonas que la interferencia es totalmente destructiva (Cuevas et al., 2018; Reis et al., 2017) (ver Figura 1-2).


Figura 1-1: Fibras ópticas de índice de paso. (a) multimodo, (b) monomodo. Fuente: Autor.



El specklegrama que se obtiene es de gran utilidad metrológica, ya que contiene información acerca de las perturbaciones que se hacen sobre la fibra. La predicción de la magnitud de perturbación

será robusta dependiendo de las herramientas matemáticas que se usen. En otras palabras, el desempeño de los FSSs depende del método de análisis.

Figura 1-2: Patrón de speckle resultante de la interferencia modal en una fibra óptica multimodo. Fuente: Autor.



1.3. Métodos de análisis convencionales para los FSS

Se han usado distintos métodos para analizar los specklegramas de FSSs. Todos ellos buscan caracterizar la imagen con respecto a la variable que perturba la fibra. En este trabajo se evalúan algunos de los más usados, así, cada vez que nos refiramos a los *métodos convencionales* nos referimos específicamente a tres métodos: correlación entre imágenes (Arango, Vélez, et al., 2021; Fujiwara et al., 2018; Gubarev et al., 2016), medición puntual de potencia (Aristizabal et al., 2016) y momentos radiales (Efendioglu, 2017; Efendioglu et al., 2013).

1.3.1. Correlación entre imágenes

Este método calcula la correlación que hay entre un specklegrama de referencia y cualquier otro specklegrama perturbado con una magnitud distinta en la variable a medir (Figura 1-3). Posteriormente se caracteriza el sensor en una zona donde el índice de correlación se comporte continuo y suave, y así, poder linealizar el sensor en ese rango. Esta ha sido una de las técnicas más usadas para los FSS, que con un solo descriptor extraído de la imagen se puede obtener una aproximación directa de la magnitud de perturbación que afectó a la fibra. Esta correlación se realiza por medio de procesamiento digital de imágenes y puede ser calculada para cada specklegrama n mediante la ecuación (1.1) (Gubarev et al., 2016):

$$C = \frac{\sum_i \sum_j ((I_{ref}(i,j) - \langle I_{ref} \rangle) \cdot (I_n(i,j) - \langle I_n \rangle))}{\sqrt{(\sum_i \sum_j (I_{ref}(i,j) - \langle I_{ref} \rangle)^2) (\sum_i \sum_j (I_n(i,j) - \langle I_n \rangle)^2)}}, \quad (1.1)$$

donde $\langle I_{ref} \rangle$ es la intensidad promedio del specklegrama de referencia, $I_{ref}(i, j)$ es la intensidad en el píxel con coordenadas (i, j) del specklegrama de referencia, $\langle I_n \rangle$ es la intensidad promedio del specklegrama n , y $I_n(i, j)$ es la intensidad en el píxel con coordenadas (i, j) del specklegrama n .

Existen diversas variaciones en el cálculo de la correlación entre imágenes para analizar los specklegramas en fibra óptica, pero los resultados no difieren significativamente. Un método comúnmente utilizado es el coeficiente normalizado del producto interno (NIPC, por sus siglas en inglés – normalized inner-product coefficient) (Feng et al., 2018; Fujiwara et al., 2018; Fujiwara, Silva, et al., 2019; Hu et al., 2022). Otro método utilizado es el ZNCC (Zero-mean normalized cross-correlation) (Fujiwara et al., 2018). Estas técnicas de correlación se han utilizado ampliamente para extraer el valor de la variable de perturbación. Sin embargo, el valor de correlación calculado, que es el único descriptor resultante de toda la información de la imagen, tiene una relación útil con la variable de interés solo en rangos cortos, debido a que las curvas resultantes suelen presentar discontinuidades, no linealidades u oscilaciones. Adicionalmente, la precisión de este método también se ve afectada por esta variabilidad. Por lo tanto, resulta valioso explorar nuevos métodos de análisis que aprovechen toda la información contenida en los specklegramas y que permitan solventar algunos de los inconvenientes mencionados.

1.3.2. Medición puntual de potencia

En este método se mide la potencia generada por la intensidad de luz que hay en una zona específica del specklegrama. Esta potencia, como se dijo anteriormente, dependerá de la interferencia modal. Al igual que el método de correlación entre specklegramas, se usa para caracterizar el sensor en el rango dinámico donde el comportamiento entre la perturbación y esta medida sean lineales.


Este descriptor puede medirse por medio de un fotosensor analógico a la salida de la fibra, pero también puede calcularse como la potencia de un área del specklegrama obtenido con una cámara., La ecuación (1.2) (Aristizabal et al., 2016) describe este cálculo:

$$P \approx \sum P_e = \frac{1}{2} c \varepsilon_0 n_{0 \text{ core}} \Sigma |\vec{E}_e|^2 A_e, \quad (1.2)$$

donde P es la potencia total, e es el elemento de área A_e (en este caso cada píxel), c la velocidad de la luz, ε_0 la permitividad del vacío y $n_{0 \text{ core}}$ el índice de refracción del núcleo. Esta potencia es calculada sobre el área de medición. En la práctica, se suele calcular la suma de las intensidades (niveles de gris) en un área de la imagen, ya que este valor es proporcional a la potencia total.

Este método es atractivo por su fácil implementación, pero las curvas de relación entre la medición de potencia y la variable de perturbación obtenidas suelen tener discontinuidades, cambios abruptos, zonas de bajas sensibilidades o baja precisión. Esto se debe a que el valor de potencia en una zona arbitraria será dependiente de las proporciones en las que los modos propagantes aporten a la intensidad de esa zona. Por tanto, para un valor de la variable de interés, puede ocurrir que un cambio de esta represente la eliminación total del aporte de un modo a la potencia de la zona medida y entonces haya un cambio abrupto en la curva de relación. Adicionalmente, también puede suceder que ese cambio no afecte la interferencia de los modos para esa zona medida, es decir, no afecte su potencia, lo que representa una zona de baja o nula sensibilidad al cambio de la variable de perturbación. Así el comportamiento de este método suele ser estable solo por tramos cortos, es decir, bajo rango dinámico, y con bajas o muy altas sensibilidades dependiendo del rango. Esto hace este método inestable y de difícil uso para la caracterización del sensor, lo que vuelve a poner de manifiesto la necesidad de desarrollar otros métodos de análisis para estos sensores.

Figura 1-3: Métodos de análisis convencionales para los FSS. (a) Correlación entre imágenes, (b) Fotosensor para medición de potencia. Fuente: Autor.



1.3.3. Momentos radiales

Otra manera de analizar los patrones de ruido modal es por medio de análisis estadísticos (Efendioglu, 2017; Efendioglu et al., 2013; Spillman et al., 1989). Por ejemplo, el uso de momentos radiales, una herramienta estadística para describir la distribución radial de intensidades en imágenes digitales es una alternativa usada en los FSS (Efendioglu, 2017; Efendioglu et al., 2013). Estos momentos se pueden calcular hallando primero los promedios en las direcciones x y y (Efendioglu, 2017):

$$\mu_x = \frac{\sum_{x,y} xI(x,y)}{\sum_{x,y} I(x,y)}, \quad (1.3)$$

$$\mu_y = \frac{\sum_{x,y} yI(x,y)}{\sum_{x,y} I(x,y)}, \quad (1.4)$$

Donde $I(x, y)$ es la intensidad en las coordenadas (x, y) . Con las ecuaciones (1.3) y (1.4) se puede hallar el momento radial de orden p mediante la siguiente expresión:

$$\mu_p = E\{r^p\} = \frac{\sum_{x,y} [(x-\mu_x)^2 + (y-\mu_y)^2]^{p/2} I(x,y)}{\sum_{x,y} I(x,y)}. \quad (1.5)$$

Estos momentos radiales tienen algunas ventajas y desventajas (Efendioglu, 2017; Efendioglu et al., 2013). Como ventajas, no dependen de un specklegrama de referencia como lo hace el método de correlación. La medición de estos momentos es normalizada con respecto a la intensidad total, por lo que no es afectada por fluctuaciones en la fuente de luz, como sí podría serlo el método de medición de potencia. Adicionalmente, son poco sensibles a rotaciones o cambios de escala. Sin embargo, las curvas de relación con la variable de medición, similarmente a los métodos anteriores, también se ve limitada en rango por variaciones abruptas, no linealidades o bajas sensibilidades en ciertos rangos.

Así, nuevamente, el uso de esta herramienta, si bien es útil, está mayormente confinado a la caracterización del sensor en segmentos cortos, donde cada uno de estos tramos puede presentar diferentes niveles de sensibilidad y precisión. Esta limitación resalta la importancia de buscar otros

métodos analíticos más robustos y eficaces. Métodos que permitan expandir los rangos de medición manteniendo al mismo tiempo una sensibilidad y precisión más estables.

1.4. Aprendizaje de máquinas en FSSs

El uso de algoritmos inteligentes ha adquirido bastante aceptación en distintos ámbitos científicos y tecnológicos, y los FSS no son la excepción. Se pueden observar los resultados de los primeros experimentos que se están obteniendo con el uso de técnicas de aprendizaje de máquina en trabajos recientes. Cuevas et al, 2018, utilizan redes neuronales como complemento a una serie de procesamientos de specklegrama captados en cámara, para posteriormente predecir el lugar donde se perturba una fibra óptica. Ellos obtuvieron 99 % en la exactitud cuando predicen 3 clases distintas (localizaciones) y 71 % cuando predicen 10 clases (localizaciones).

En (Fujiwara, Wu, et al., 2017) se presenta un FSS para medir señales de fuerzas miográficas (FMG) usando un número reducido de transductores, 3, en comparación con la forma convencional que se basa en el uso de múltiples electrodos distribuidos en la zona de estudio. En este caso, los autores tenían como objetivo reconocer algunos gestos y posiciones que toma la mano de una persona por medio de su sistema de fibra óptica, lo que es de utilidad en estudios biomédicos o en aplicaciones de interfaces humano-computador. Ellos propusieron un procesamiento computacional de los specklegramas captados introduciéndolos a una red neuronal artificial (ANN) alcanzando una exactitud promedio de 89,9 % en el reconocimiento de gestos de la mano como mano abierta, mano cerrada, flexión de la muñeca, señal V, pulgar arriba, entre otras. Por otro lado, (Liu et al., 2020), proponen el uso de redes neuronales convolucionales (CNN), para la clasificaron de 21 flexiones de fibra óptica, entrenando la CNN con los specklegramas obtenidos de estas flexiones. Ellos obtuvieron 92,8% de exactitud en una fibra de 105 μm de diámetro y 96,6 % en una fibra de 200 μm de diámetro.

El uso de técnicas de *machine learning* en FSSs ha seguido creciendo en el último año, como lo muestran trabajos en la clasificación de pesos (Vangety et al., 2022) y en la clasificación de curvaturas (G. Li et al., 2022). En este sentido, vale la pena mencionar que la propuesta de esta tesis tiene como aspecto novedoso y destacable, la evaluación de distintas arquitecturas que van

más allá de la clasificación, al incorporar esquemas de regresión en specklegramas producidos en medición de temperatura, lo que hasta el momento sigue siendo novedoso en el estado del arte.


1.5. Estrategias de medición y diseño para los FSS

Además de las técnicas anteriormente descritas, hay algunas estrategias que se encuentran en la literatura que pueden mejorar el desempeño de los FSS. Estas se pueden implementar en los métodos convencionales o en metodologías que surjan con el uso de *machine learning*. Estas pueden ser de gran utilidad en trabajos futuros. En esta tesis se hace uso de la longitud de zona sensora (Sección 1.5.3) para el diseño del sensor, tanto en la etapa de simulación como en la etapa experimental.

1.5.1. Región de interés (ROI)

Se ha demostrado en la literatura que la selección adecuada de una zona del specklegrama resulta en un mejor desempeño en la medida del FSS (Figura 1-4) (Aristizabal et al., 2016). Sobre esta región de interés o ROI (por sus siglas en inglés – *Region Of Interest*) se realiza el procesamiento según el método de análisis que se desee utilizar. Además, se ha demostrado que el tamaño del ROI óptimo es el más cercano al tamaño de una *mota o speckle* promedio del specklegrama cuando se usa el método de medición de potencia (Aristizabal et al., 2016).

Figura 1-4: Distintos ROI de lectura para un specklegrama de un sensor FSS. Fuente: Autor.




Es importante tener en cuenta que el ROI afecta el desempeño de los FSS, al menos con los métodos convencionales (Sección 1.3.). Este desempeño se ve afectado por el tamaño del ROI (Aristizabal et al., 2016), pero también por su ubicación dentro de la imagen. Por ejemplo en (Arango, Vélez, et al., 2021), publicación hecha en el marco de esta tesis, se escogen ubicaciones específicas en las

que el sensor se comporta de manera estable durante la mayor cantidad de rango. Es decir que no escoger un ROI apropiado, limita el rango dinámico del sensor.

1.5.2. Uso de dopantes para el diseño

En (Herrera-Ramirez et al., 2018) se obtiene el comportamiento del índice de refracción de una fibra, simulada por el método de elementos finitos, con respecto a la temperatura. Este experimento simulado se realiza con distintas concentraciones del dopante pentóxido de fósforo, P_2O_5 (12 %, 27 % y 75 %), demostrando las implicaciones que tiene el uso de estos dopantes para el diseño de un FSS según los requerimientos que se tengan para una aplicación en específico. Esto debido a que cambios en el índice de refracción ocasionan cambios en la interferencia modal y en consecuencia en el patrón de *speckle*. En la Figura 1-5 se puede observar cómo la dependencia del índice de refracción del núcleo (core) de la fibra con respecto a la temperatura cambia con las diferentes concentraciones del dopante. Además, la figura también muestra cómo es posible invertir la relación de los valores de índice entre el núcleo y el revestimiento (cladding) de la fibra. Como resultado de esta inversión, se alcanza un punto en el que, a partir de ciertas temperaturas, la condición de reflexión total interna ya no puede mantenerse. Esto implica que a medida que la temperatura aumenta, la diferencia en los índices de refracción entre el núcleo y el revestimiento de la fibra puede disminuir hasta un punto crítico donde la luz ya no puede ser completamente reflejada, lo que provoca una pérdida de señal.

Figura 1-5: Respuesta del índice de refracción n con respecto a la temperatura para distintas concentraciones del dopante P_2O_5 en la fibra. Fuente: tomado de (Herrera-Ramírez et al., 2018).



Hay algunas implicaciones que puede tener el uso de dopantes en el diseño de los FSSs. Entre ellas está el controlar el rango de medición máximo que el sensor puede alcanzar, modificar la sensibilidad del sensor al procurar que el cambio con la temperatura de la diferencia de índices


entre núcleo y revestimiento sea alto o diseñar un sensor que mida (propague luz adecuadamente) solo a temperaturas negativas.

Sin embargo, si se pretende diseñar un sensor con un rango extendido, es necesario contar con un método de análisis que pueda aprovechar todo este rango, ya que los métodos convencionales descritos en la *Sección 1.3* presentan limitaciones en cuanto al rango que pueden alcanzar (Arango, Vélez, et al., 2021; Fujiwara et al., 2018). En este sentido, el uso de técnicas de machine learning se presenta como una alternativa eficaz para abarcar un amplio rango de predicción. La principal ventaja de utilizar técnicas de machine learning radica en su capacidad para adaptarse a no linealidades presentes en los datos (Chollet, 2021). Además, estas técnicas tienen la capacidad de generalizar correctamente la predicción a partir de datos de entrenamiento. En este sentido, este trabajo ha cumplido con uno de sus objetivos propuestos al generar bases de datos simulados para la prueba y entrenamiento de técnicas de machine learning que puedan aprovechar mejor las posibilidades de este tipo de sensores. Esta base de datos es de acceso público y está asociada a la publicación (Arango et al., 2023). Además, como se muestra en capítulos más adelante, los alcances propuestos de esta tesis se superan al haber implementado también un montaje experimental automatizado que permitió la generación de una base de datos experimental y la prueba en datos reales de diferentes esquemas de aprendizaje de máquinas.

1.5.3. Longitud de zona sensora


Como parte del trabajo de esta tesis (Arango, Vélez, et al., 2021), se determinó que no solo la magnitud de la perturbación que afecta a la fibra influye en el cambio del specklegrama, sino también la cantidad de fibra afectada por dicha perturbación. A esto se le conoce como *longitud de zona sensora* (Figura 1-6), en otras palabras, la longitud de fibra que está siendo perturbada. Esta longitud de zona sensora incide en la sensibilidad del cambio del specklegrama con respecto al cambio de la perturbación (Arango, Vélez, et al., 2021). A mayor longitud de zona sensora mayores cambios tendrán los specklegramas provenientes de una fibra afectada por cierta variable.

Figura 1-6: Longitud de zona sensora Z que es afectada por una perturbación. Fuente: Autor.



Ya que la longitud de zona sensora es un parámetro que cambia la sensibilidad del specklegrama con respecto a la variable que se vaya a medir, puede ser utilizada para el diseño de un sensor FSS según se requiera. En la Figura 1-7 se muestra la influencia de la longitud de zona sensora en la sensibilidad del sensor.

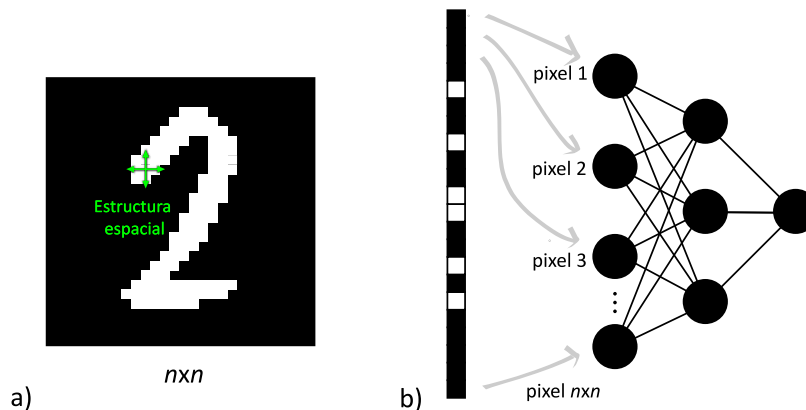
Figura 1-7: Influencia de distintas longitudes de zona sensora Z en la sensibilidad (pendiente) del coeficiente de correlación entre los specklegramas con respecto a la temperatura. Fuente: Autor.



1.6. Redes neuronales convolucionales

Las redes neuronales convolucionales, o CNN (por sus siglas en inglés *Convolutional Neural Networks*), son una técnica de aprendizaje de máquinas utilizadas principalmente en imágenes. Esto se debe a que las imágenes son datos con *dependencia espacial significativa*. Esta dependencia espacial se refiere a la relación entre los píxeles vecinos, que tienden a tener valores similares. Las convoluciones, utilizadas en las CNN, aprovechan esta dependencia espacial para extraer información relevante (Chollet, 2021). Esto se ilustra en la Figura 1-8a, donde la imagen conserva su estructura espacial y esta sería la entrada a la CNN. En contraste, la Figura 1-8b muestra cómo las redes neuronales artificiales convencionales (ANN, por sus siglas en inglés *Artificial Neural Networks*), también conocidas como perceptrones multicapa, tratan la información de una imagen al aplanarla en un vector mediante la operación *flatten* (Geron, 2017). Esto implica una pérdida de la información estructural de la imagen. Como consecuencia, las CNN suelen tener mejor desempeño para trabajar con datos con relaciones espaciales, como las imágenes (O'Shea & Nash, 2015).


Figura 1-8: a) Imagen de $n \times n$ píxeles, b) imagen convertida a vector, así se representaría para entrenar una red ANN, no se conserva su estructura espacial y cada píxel se tomaría como una característica de entrada. Fuente: Autor.



Las CNN recorren las imágenes con filtros de diferentes tamaños realizando una operación conocida como *convolución* (. Esta convolución produce un mapa de características (Chollet, 2021)

que resalta regiones relevantes de la imagen de acuerdo con los patrones aprendidos en el proceso de entrenamiento de la red . (Figura 1-9).

Figura 1-9: Mapa de características obtenido de una imagen transformada por una operación de convolución con un filtro 3x3. Fuente: adaptado de developer.nvidia.com.



Entrenando arquitecturas CNN, podemos resolver tareas en imágenes como: clasificación (Krizhevsky et al., 2017), detección (Girshick et al., 2013), segmentación semántica (Long et al., 2014), inclusive generación de nuevas imágenes (Karras et al., 2017). El uso de convoluciones, además del uso de *pooling* (Chollet, 2021; Geron, 2017), mejora el rendimiento de algunas tareas sobre el rendimiento de las redes convencionales ANN (o MLP, *Multi-layer Perceptron*).

A continuación, se explican brevemente algunos términos importantes que se manejan en el resto de este trabajo:

Machine learning

El *machine learning* o aprendizaje de máquina, es una rama de la inteligencia artificial que se enfoca en el desarrollo de algoritmos que permiten a las computadoras aprender reglas y representaciones a partir de los datos (Chollet, 2021; Geron, 2017). En este se utilizan técnicas como la regresión, clasificación, clustering y redes neuronales para identificar patrones y hacer predicciones.

Transfer learning

El *transfer learning* o transferencia de aprendizaje es una técnica usada en aprendizaje de máquina que permite utilizar conocimientos previos aprendidos en un modelo entrenado y transferirlos a otro modelo para una tarea diferente. Esto se logra al reutilizar parte de los parámetros y pesos

aprendidos en el modelo previo y ajustarlos al nuevo conjunto de datos (lo que se conoce como *fine tuning* o ajuste fino) y minimiza drásticamente el tiempo de entrenamiento (Geron, 2017).

Tensor

Un *tensor* es una estructura matemática para representar datos numéricos en múltiples dimensiones. Para más claridad, es bueno tener en cuenta que se usan comúnmente en diferentes campos, ya que un tensor de una dimensión es un vector, un tensor de dos dimensiones es una matriz y un tensor de tres o más dimensiones simplemente se llama tensor de n dimensiones. Por ejemplo, una imagen RGB es un tensor de 3 dimensiones, no por tener 3 canales (R-G-B), sino por tener 3 dimensiones (ancho-alto-profundo). Mientras que una imagen a escala de grises es un tensor de 2 dimensiones.

Optimización

La *optimización* es el proceso donde se modifican los parámetros de un algoritmo (de manera inteligente) con el fin de obtener la combinación apropiada para una tarea particular. En el contexto de esta tesis, la optimización se usa para entrenar de manera óptima una red neuronal para que prediga correctamente temperaturas a partir de specklegramas de fibra óptica. Uno de los optimizadores más usados en redes neuronales en los últimos años es Adam (Kingma & Ba, 2014).

Overfitting

El *overfitting* o sobre aprendizaje es un problema común en el entrenamiento de modelos de aprendizaje de máquina, donde un modelo se ajusta demasiado bien a los datos de entrenamiento, y no lo hace con el mismo desempeño con los datos de prueba. Esto afecta uno de los mayores intereses cuando creamos modelos de machine learning, que es la capacidad para generalizar (Chollet, 2021; Geron, 2017). Para evitar el sobreajuste se recomienda en primer lugar tener suficientes datos para entrenar, con todas las condiciones con las que se va a aplicar finalmente la red, también el uso de regularización como el *dropout* (se explica a continuación).

Dropout

La técnica de *dropout* es una estrategia de regularización comúnmente utilizada en las redes neuronales que consiste en cancelar aleatoriamente una fracción de neuronas en una capa durante el entrenamiento (Chollet, 2021; Geron, 2017), lo que obliga al modelo a aprender diferentes trayectorias. Es decir, la red está obligada a identificar más características y no depender de unas pocas.

Pooling

La operación de *pooling* es una técnica de reducción de dimensionalidad comúnmente utilizada en las redes neuronales convolucionales para disminuir la cantidad de parámetros y mejorar el desempeño del modelo. Hay distintos tipos de *pooling*, en este trabajo se llevó a cabo el *maxpooling*, que consiste en escoger el valor mayor entre varios píxeles y conseguir así la reducción de dimensionalidad (Chollet, 2021; Geron, 2017).

Flatten

La operación de *flatten* es una operación de preprocesamiento que se utiliza en las redes neuronales para convertir los datos de entrada en un vector unidimensional antes de ser alimentados a una capa densa. Esta operación se utiliza con frecuencia después de las capas convolucionales para *aplanar* los mapas de características y convertirlos de un tensor a un vector unidimensional (Chollet, 2021; Geron, 2017). (Como el ejemplo mostrado anteriormente en la Figura 1-8).

Softmax

La función *softmax* es una función de activación comúnmente utilizada en la capa de salida de las redes neuronales convolucionales para obtener una distribución de probabilidad sobre las diferentes clases de salida (Chollet, 2021; Geron, 2017). Esta se utiliza comúnmente en tareas de clasificación multiclase, en este trabajo se utiliza para un modelo de clasificación de 20 clases de temperatura.

2. Justificación y planteamiento del problema

Como se mencionó anteriormente, las técnicas de variación de potencia son de interés por su combinación de robustez, bajo costo y fácil implementación. Además de las ventajas mencionadas, a ello se suman las ventajas asociadas al uso de sensores de fibra óptica en general como son (Arango, Aristizabal, et al., 2021; Fujiwara, Da Silva, et al., 2019; Grattan & Sun, 2000; Leal-Junior et al., 2020):

- Inmunidad a las perturbaciones electromagnéticas.
- Tamaño reducido (a comparación de otros sistemas metrológicos).
- Medición de diferentes variables (temperatura, deformación, variables químicas, vibración, entre otros).
- Resistencia del material a altas temperaturas y a la corrosión.


Estas versatilidades hacen a los sistemas basados en fibra óptica atractivos en varias áreas como la de la aeronáutica (Hamory et al., 2016), en la medicina (Feng et al., 2018; Mishra et al., 2011; Reyes-Gonzalez et al., 2022) en algunos procesos industriales (Leal-Junior, Marques, et al., 2018), en la supervisión de salud estructural (Kinet et al., 2014), en robótica (Leal-Junior, Frizzera, et al., 2018), en el análisis de la marcha (Vilarinho et al., 2017) o en la detección de compuestos químicos (Fujiwara, Da Silva, et al., 2019; Y. Zhang et al., 2017).

A pesar de las ventajas que podemos encontrar en estos sensores, y hablando específicamente de los *sensores de specklegrama de fibra óptica*, estos todavía son susceptibles de mejora en algunas de sus características de manera que les permita alcanzar una madurez suficiente para que su uso sea más frecuente y extendido. Para mejorar la capacidad metrológica de los sensores FSS, se ha propuesto en este trabajo un método de análisis utilizando técnicas de *Machine Learning* que han demostrado ser muy efectivas en áreas tan diversas como la física, ingeniería, química, marketing y psicología, (Carleo & Troyer, 2017; Gómez et al., 2020; Lee et al., 2021; Rajpurkar et al., 2017; Rosenbusch et al., 2021; Rupp et al., 2012; Tarallo et al., 2019) y más específicamente para nuestro interés, en la óptica, sensórica y fotónica (Genty et al., 2021; lafolla et al., 2021; Ma et al., 2019, 2021; Oldfrey et al., 2019). Así, en este trabajo se muestra la evaluación y desarrollo de este tipo de técnicas para mejorar las características del sensor.

2.1. Problema de rango dinámico, sensibilidad y linealidad

Como ocurre en muchos sensores, el rango dinámico de un sensor va a estar íntimamente relacionado con su sensibilidad y viceversa (Webster & Eren, 2014). Es decir, si un sensor es muy sensible, este suele tener un rango dinámico limitado, y si un sensor tiene un rango dinámico muy amplio, este suele tener una baja sensibilidad. En el caso de los FSSs, se puede alcanzar una sensibilidad alta, pero los métodos convencionales de potencia o correlación presentan dificultades para mantener esa sensibilidad sobre un rango amplio, esto por discontinuidades, no linealidades o cambios abruptos en las curvas de respuesta. Es así que, extender el rango dinámico mientras se conserva la sensibilidad es de gran interés para la comunidad científica (Leal-Junior et al., 2020; Yin et al., 1999). En la Figura 2-1 se muestra un ejemplo de un FSS analizado mediante la técnica de correlación entre specklegramas (uno de los métodos de análisis convencionales). Esta figura muestra la respuesta del coeficiente de correlación con el cambio de temperatura. Se puede notar que la curva de respuesta es discontinua, así para este ejemplo, esto restringe el rango útil del sensor a valores de temperatura entre 15°C y 35°C, aproximadamente. Además, también puede darse que distintas temperaturas dan como respuesta un mismo valor de coeficiente de correlación. Lo que complica los procesos de medición o caracterización del sensor.

Figura 2-1: Dependencia entre el rango dinámico y la sensibilidad. Fuente: Autor.



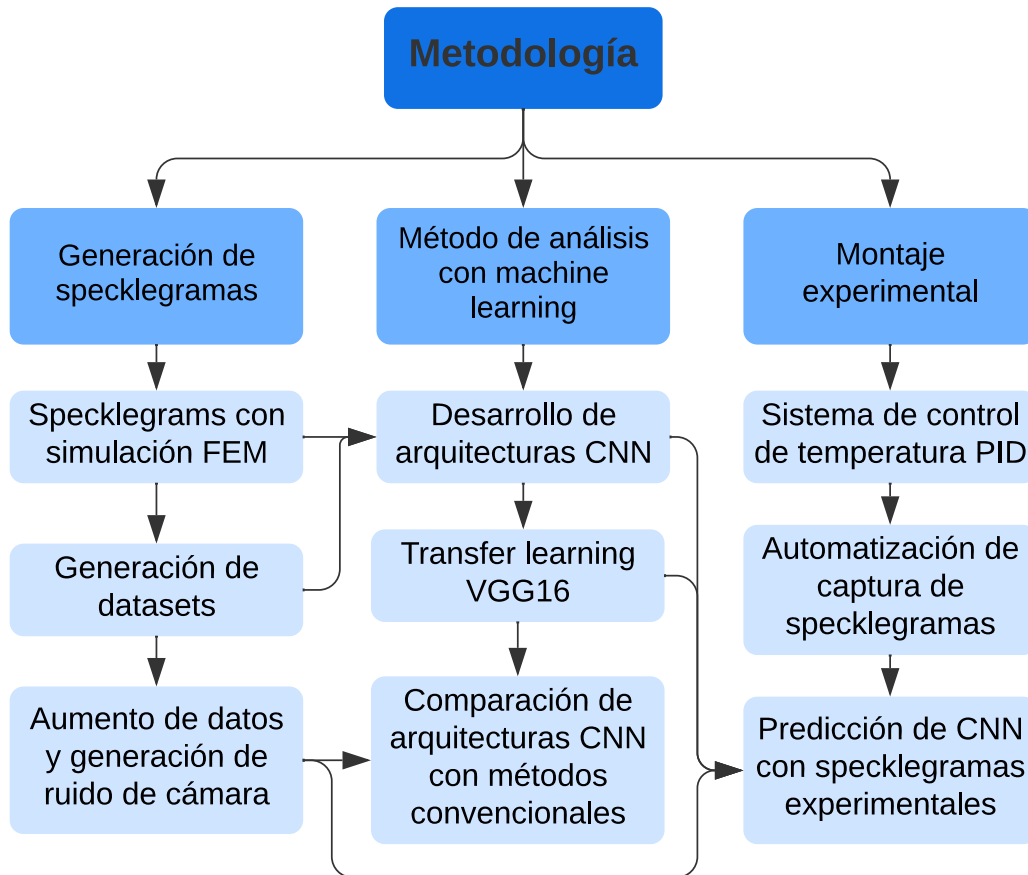
Además de las características metrológicas de rango dinámico y sensibilidad, esta tesis también busca mejorar la manera en la que se aprovecha la información en los specklegramas en su análisis. Generalmente, como ya se mencionó, en el análisis de los FSSs se hace uso de una sola característica de la imagen, un valor escalar. Lo que produce curvas de respuesta discontinuas o altamente no lineales. Implicando el uso de linealizaciones por tramos, ajustes polinomiales, interpolaciones tipo *spline* o técnicas de regresión no lineales que pueden limitar la interpretación, calibración y uso del sensor (Islam & Mukhopadhyay, 2019; Xia et al., 2016). Teniendo en cuenta lo anterior, el problema planteado es: Desarrollar una metodología para mejorar las características metrológicas de los sensores de specklegrama de fibra óptica para que conserven sensibilidad ampliando su rango dinámico. Así, este trabajo evalúa distintos modelos de redes neuronales: ANN (o MLP), CNN y Transformers de visión para aprovecharlos en la extracción de características particulares de cada specklegrama, en lugar de depender de un único valor escalar. Además, se aprovecha la capacidad de estas redes neuronales para adaptarse a problemas altamente no lineales (Chollet, 2021).

2.2. Metodología

La metodología de este proyecto está de acuerdo con lo que se encontró en el estado del arte en el momento de su propuesta y de los que se definieron como objetivos específicos. Así el problema planteado estaba en determinar un método de análisis para mejorar los sensores de specklegramas de fibra, usando simulaciones computacionales para la generación de los patrones de speckle y con la aplicación de técnicas de aprendizaje de máquinas para abordar ese análisis. Esto llevó al uso del método FEM para las simulaciones, a la selección de redes neuronales convolucionales (CNN) debido a su capacidad para extraer información espacial de imágenes y la posterior selección de un esquema de regresión en la salida de la CNN, que es un enfoque que se concluyó como más adecuado y que hasta ahora no se ha usado en el estado del arte para FSSs con temperatura. Adicionalmente, la metodología de análisis desarrollada a partir de las bases de datos simuladas se evaluó sobre los datos obtenidos con un sistema experimental, superando el alcance de los objetivos planteados inicialmente.

Una representación esquemática de estas etapas, de acuerdo con los objetivos específicos propuestos y las pruebas sobre datos experimentales adicionales, se pueden observar en la Figura 2-2.


Figura 2-2: Diagrama de la metodología llevada a cabo en esta tesis.



3. Simulación: specklegramas sintéticos

Las simulaciones para obtener los specklegramas sintéticos se llevaron a cabo en la plataforma Comsol Multiphysics integrada con el software Matlab. El método usado en estas simulaciones se conoce como el método de elementos finitos (*FEM – por sus siglas en inglés*), en donde se modela la propagación de un campo óptico a lo largo de una fibra MMF. Las simulaciones se realizaron modelando la propagación en el tramo de longitud de zona sensora (*Sección 1.5.3*), es decir, donde la temperatura perturba la fibra (Figura 3-1). De esta manera se aproximó el comportamiento de una fibra MMF bajo perturbaciones, sin simular la porción de fibra no perturbada, lo que incluiría un costo computacional innecesario (Arango, Vélez, et al., 2021).


Figura 3-1: Representación esquemática de un montaje FSS para medición de temperatura. La porción resaltada de la fibra corresponde con la sección perturbada y simulada por el método FEM. Fuente: Autor.



Además, en la simulación se asume una fibra óptica con índice de refracción constante a lo largo de su eje de propagación, de esta manera es válido hacer una aproximación 2.5D del problema (Arango, Vélez, et al., 2021; Arístizabal et al., 2016). Bajo esta aproximación, se reduce drásticamente el costo computacional en comparación con la simulación de una propagación 3D. En este enfoque, primero encontramos el estado del sistema en un plano específico en términos del campo óptico (por convención, este se toma como el campo eléctrico de la onda electromagnética) y luego lo propagamos en la dirección normal Z . En otras palabras, expresamos este campo eléctrico como $\vec{E}(x, y, z) = e^{i\beta z}\vec{E}(x, y)$, donde β es la constante de propagación del modo asociado con $\vec{E}(x, y)$. Para calcular el campo eléctrico $\vec{E}(x, y)$ de cada modo, se resuelve numéricamente la ecuación de Helmholtz (ecuación (3.1)), con el método de elementos finitos

(FEM) (Aristizabal et al., 2006; Arístizabal et al., 2016; Torres et al., 2011). El proceder fue entonces, discretizar en elementos triangulares la sección transversal de la fibra en un plano de referencia $Z = 0$, resolver la ecuación (3.1) en cada elemento y luego ensamblar los resultados para obtener la solución general para cada modo (Figura 3-2).

Figura 3-2: Representación de malla para la simulación de la propagación de modos de luz en una fibra óptica con el método de elementos finitos (FEM) con una aproximación 2.5D. Fuente: Autor.



La ecuación de Helmholtz, que describe el campo eléctrico de cada modo, es la siguiente:

$$\nabla \times \nabla \times \vec{E}(x,y) - k_0^2 n^2 \vec{E}(x,y) = 0, \quad (3.1)$$

donde $k_0 = 2\pi/\lambda_0$ es el número de onda para la longitud de onda λ_0 , n es el índice de refracción. En general, este índice de refracción n varía con el cambio de temperatura en cada eje, pero debido a la isotropía del material de la fibra, estas diferencias se pueden despreciar y los índices de refracción en cada eje se pueden aproximar de acuerdo con la siguiente ecuación (3.2) (Arango, Vélez, et al., 2021):

$$n_x \approx n_y \approx n_z \approx n_0 + C_{TO}(T - T_0) \quad (3.2)$$

donde n_x , n_y y n_z son los índices de refracción en cada uno de los ejes, n_0 es el índice de refracción inicial, C_{TO} es el coeficiente termo óptico, T la temperatura en un instante de simulación y T_0 la temperatura de referencia (generalmente la temperatura ambiente). A su vez, el índice de refracción inicial del núcleo se calcula con la ecuación de Sellmeier, ecuación (3.3) (Arango, Vélez,

et al., 2021), y por su parte, el índice de refracción inicial del revestimiento se calcula con la ecuación (3.4):

$$n_{0co}^2(\lambda[\mu m]) = 1 + \frac{0.6961663\lambda_0^2}{\lambda_0^2 - 0.0684043^2} + \frac{0.4079426\lambda_0^2}{\lambda_0^2 - 0.1162414^2} + \frac{0.8974794\lambda_0^2}{\lambda_0^2 - 9.896161^2} \quad (3.3)$$

$$n_{0cla} = \sqrt{n_{0co}^2 - NA^2}, \quad (3.4)$$

donde n_{0co} es el índice de refracción inicial del núcleo, n_{0cla} es el índice de refracción inicial del revestimiento, λ_0 es la longitud de onda inicial y NA la apertura numérica.

De esta manera, como se mencionó, podemos obtener el campo vectorial $\vec{E}(x, y)$ y las constantes de propagación de cada modo en el plano $Z = 0$. Después, podemos propagar cada modo a lo largo de un Z dado, utilizando la expresión $e^{i\beta z}\vec{E}(x, y)$. Así, como también se mencionó anteriormente, la superposición en amplitud compleja de todos los modos, lo que es equivalente a decir la interferencia modal, produce el patrón de speckle o specklegrama en el plano Z deseado (Aristizabal et al., 2016). Esta interferencia o superposición de modos que se propagan a través de la fibra puede expresarse como la ecuación (3.5):

$$A(x, y) = \sum_{m=0}^M E_m(x, y) \exp [j\phi_m(x, y)] \quad (3.5)$$


donde M es el número total de modos que se propagan en la fibra, E_m es la distribución de amplitud de cada modo m y ϕ_m es la fase de cada modo m . Esta expresión representa entonces la distribución de amplitud compleja del campo óptico en el plano final de perturbación de la fibra. Sin embargo, para la simulación de la adquisición de un specklegrama usando una cámara, se requiere la representación en intensidades del resultado anterior. Es decir, la simulación final de la imagen obtenida por una cámara digital se obtiene con la ecuación (3.6):

$$I(x, y) = |A(x, y)|^2 = \sum_{n=0}^M \sum_{m=0}^M E_m E_n \exp [j(\phi_m - \phi_n)]. \quad (3.6)$$

Es de anotar que la simulación obtenida será más fiel entre más fino sea el enmallado de los elementos del método FEM (Figura 3-2). Pero entre más finos sean estos, el costo computacional será más alto por el aumento de los cálculos. Por esta razón, se procura un enmallado óptimo entre tiempo de simulación y fidelidad de simulación. Además, también para optimizar, se implementó un enmallado más fino en el núcleo que en el revestimiento de la fibra, ya que la propagación de los modos a través del revestimiento es escasa y de poco interés para nuestro problema.

Teniendo en cuenta todas las consideraciones anteriores se realizaron algunas pruebas de simulación. En la Figura 3-3 se muestran algunos ejemplos de specklegramas sintéticos, a tres distintas aperturas numéricas, y con todos los demás parámetros iguales (tamaño de enmallado, índice de refracción del núcleo, índice de refracción del revestimiento, coeficiente termo-óptico, diámetro de núcleo, diámetro de revestimiento, longitud de onda, longitud de zona sensora y temperatura). En la figura se puede notar la influencia directa que tiene la apertura numérica en la tanto en la distribución del patrón de speckle como en el tamaño de los speckles.

Figura 3-3: Generación de specklegramas con FEM a distintas aperturas numéricas (NA). Fuente: Autor.



Distintos conjuntos de datos fueron generados con este método para entrenar una CNN, los primeros se crearon con el objetivo de realizar algunas pruebas preliminares, de manera que se tenían en cuenta aperturas numéricas bajas, specklegramas con pocos modos y en general parámetros que ayudaran a la simulación y a la observación del fenómeno. Estos conjuntos de datos se publicaron en (Arango et al., 2023) como una base de datos de acceso abierto incluyendo 601 specklegramas simulados por FEM y aumento de datos hasta tener un total de 138230

specklegramas. Este resultado es un indicador del cumplimiento del primer objetivo específico propuesto.

4. Implementación de redes neuronales convolucionales para el análisis de specklegramas sintéticos

De acuerdo con lo propuesto como objetivos de este proyecto, se crearon y probaron distintas arquitecturas convolucionales para su evaluación sobre los specklegramas simulados. En la Tabla 4-1 se describen las arquitecturas creadas y evaluadas. Además, a lo largo del desarrollo del proyecto se obtuvieron tres conjuntos de datos sintéticos, las especificaciones de estos se muestran en la Tabla 4-2. Estos dataset se fueron generando de acuerdo con la disponibilidad de recursos computacionales y con criterios incrementales que se iban incluyendo para tener un dataset más representativo de las posibles situaciones prácticas que se pueden encontrar. Por esto, se usa un dataset específico para cada prueba, ya que a medida que se avanzaba en el método de análisis con *machine learning*, también se avanzaba en la generación de specklegramas. El primer conjunto de datos se generó de un modo exploratorio y con un costo computacional bajo. El segundo se generó con otros parámetros para tener más modos en los specklegramas, implicando un mayor costo computacional. Y el tercero se generó con más rango dinámico y parámetros más similares a los de aplicaciones experimentales. De manera que, a medida que se generaba un nuevo dataset de specklegramas sintéticos, se aumentaba el costo computacional, pero también se acercaba más a parámetros comerciales de la fibra óptica, longitud de onda del láser, entre otros.

Todo este trabajo computacional permitió mostrar la validez de la aproximación al análisis de los specklegramas usando herramientas del aprendizaje máquinas, adquirir la experiencia y madurez en cuanto al manejo de las herramientas computacionales, así como el reconocimiento de los factores más determinantes en la implementación de este esquema en un montaje experimental. Así, como se muestra en los siguientes capítulos, sobrepasando el alcance inicial propuesto para esta tesis, se obtuvo un montaje experimental de sensor FSS con el que se generaron datos en los que se probaron nuevas arquitecturas. En esos capítulos, se explica con detalle el proceso de entramiento de estas nuevas arquitecturas, incluyendo la optimización de hiperparámetros, entre otros elementos.

Tabla 4-1: Arquitecturas de redes convolucionales creadas y evaluadas con los specklegramas simulados con FEM. La arquitectura A0 se usa en una tarea de clasificación de 20 clases, capa de salida densa **d20**. Las demás arquitecturas en regresión, capa de salida densa **d1**.

Arquitectura	CNN																		ANN			Dataset
	c64	c64	p2	c128	c128	p2	c64	c20	p2	-	-	-	-	-	-	-	-	-	d256	d20	-	
A0	c64	c64	p2	c128	c128	p2	c64	c20	p2	-	-	-	-	-	-	-	-	-	d256	d20	-	I
A	c64	c64	p2	c128	c128	p2	c64	c20	p2	-	-	-	-	-	-	-	-	-	d256	d1	-	I
B	c64	c64	p2	c128	c128	p2	c100	c100	p2	-	-	-	-	-	-	-	-	-	d256	d1	-	I
C	c64	c64	p2	c256	c256	p2	c192	c192	p2	c128	c128	p2	-	-	-	-	-	-	d2048	d1	-	I,II,III
D	c64	c64	p2	c256	c256	p2	c192	c192	p2	c128	c128	p2	-	-	-	-	-	-	d256	d1	-	I
VGG16-reg *	c64	c64	p2	c128	c128	p2	c256	c256	c256	p2	c512	c512	c512	p2	c512	c512	c512	p2	d2048	d2048	d1	III

c → Convolución

p → Pooling

d → Densa (capa de ANN totalmente conectada)

* Se tomó la VGG16 en la etapa convolucional para realizar una transferencia de aprendizaje y se modificó la etapa densa para ser entrenada y tener una sola neurona de salida con activación lineal (originalmente la VGG16 tiene 1000 neuronas de salida correspondiente a 1000 clases). A esta nueva arquitectura adaptada para regresión la llamamos VGG16-reg.

Tabla 4-2: Conjuntos de datos de specklegramas simulados con FEM.

Dataset	Longitud de onda (nm)	Apertura numérica	Rango de temperatura	Número de imágenes	Longitud de zona sensora (mm)	Diámetro del núcleo (µm)	Diámetro del revestimiento (µm)
I	632.8	0.13	0 °C a 100 °C	1001	0.3	9	40
II	1490	0.22	0 °C a 120 °C	601	2.5	50	125
III	632.8	0.3	-50 °C a 150 °C	2001	0.3	9	40

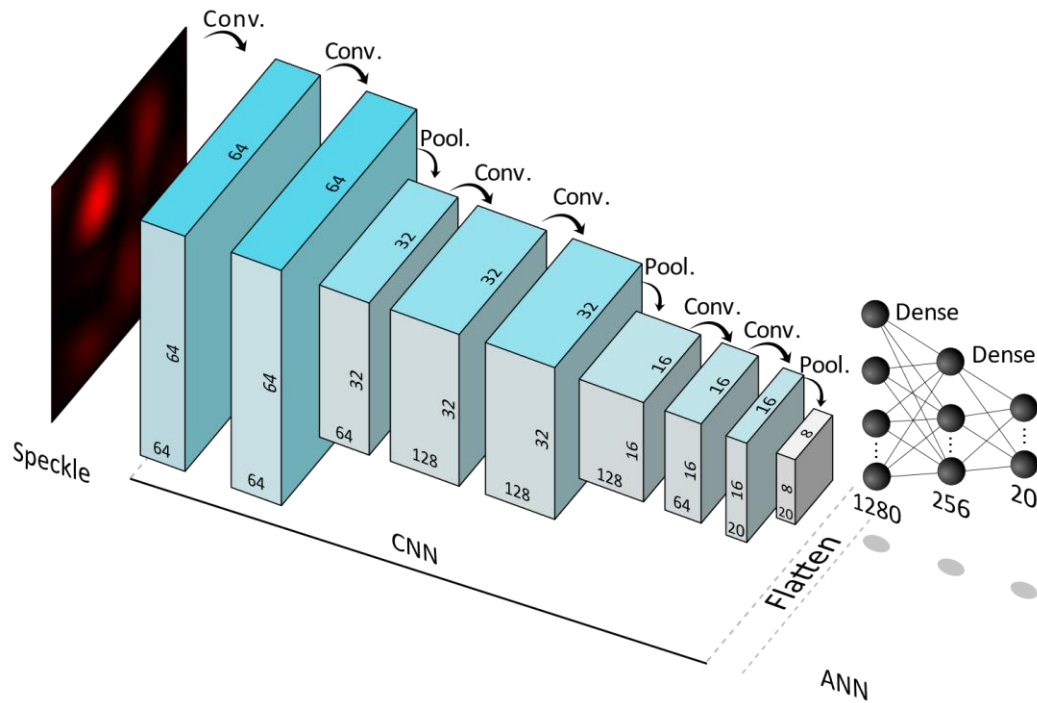
Para realizar los primeros entrenamientos, nos basamos en la arquitectura usada en (Liu et al., 2020). Allí se estudió un problema cercano al nuestro, obteniendo clasificaciones de 21 flexiones (21 clases) de una fibra MMF por medio de una red CNN. A su vez, usaron una arquitectura VGG (Simonyan & Zisserman, 2014) que adopta una estructura de bloques conv-RELU → conv-RELU → MaxPooling. Así, con esta estructura como base, realizando algunas modificaciones, convertimos la extracción de características a la salida de la CNN en vector, vector que se ingresa en una red densa que añadimos. Algunos de los entrenamientos que hemos realizado son:

4.1. Prueba exploratoria: Algoritmo de clasificación

En esta prueba inicial se implementó una arquitectura de clasificación que nos sirviera para guiar el resto del trabajo. En esta prueba se clasificaron specklegramas de 20 grupos de temperaturas. La arquitectura usada la denominamos A0 (Tabla 4-2). El conjunto de datos usado, dataset I (Tabla 4-2), se simuló en un rango de 0 °C a 100 °C en pasos de 0.1 °C, es decir, en total se obtuvieron 1001 specklegramas. Dado este rango y las 20 clases a predecir, cada clase cubría un rango de 5 °C. En esta arquitectura usamos una CNN (que por cada dos capas de convolución tenía una capa de *maxpooling* de 2x2 píxeles) y con la operación *flatten* ingresamos estas características a una ANN. Esta ANN consiste en una capa de entrada, una capa oculta (con función de activación *ReLU*) y una capa de salida (con función de activación *softmax*). Establecimos 20 neuronas para la capa de salida, correspondientes a las 20 clases a predecir, como se puede ver con más detalles en la Figura 4-1.

Para entrenar esta arquitectura se divide el dataset en dos grupos (separados de manera aleatoria): entrenamiento (801 specklegramas) y prueba (200 specklegramas). Posteriormente del set de entrenamiento se separan 160 specklegramas para validación en las iteraciones de entrenamiento. Esto se implementó mediante el lenguaje de programación Python con las librerías de *keras* y *tensorflow*.

Figura 4-1: Arquitectura CNN usada para la clasificación de temperaturas con specklegramas de entrada. Fuente: Autor.



4.1.1. Desempeño de pruebas exploratoria con CNN para clasificación con dataset I

Para este algoritmo exploratorio de clasificación entrenado con la arquitectura A0 se obtuvo 99.5% de precisión con los datos de prueba del dataset I. La Figura 4-2 muestra la matriz de confusión de esta clasificación. Es importante resaltar que dado que el dataset contiene un rango de temperaturas entre 0°C y 100°C y está dividido en 20 clases, cada clase cubre un rango de 5°C, por lo que cada clase tiene un error intrínseco de 5°C. Esta prueba de clasificación inicial guía fue aplicada exclusivamente sobre esta base de datos, dataset I, porque con esta prueba se esperaba vislumbrar el panorama de uso de estas técnicas. A pesar de estas condiciones, esta prueba nos mostró que el análisis de specklegramas con este tipo de arquitecturas sí era una opción viable.

Figura 4-2: Matriz de confusión para el algoritmo de clasificación con el dataset I.

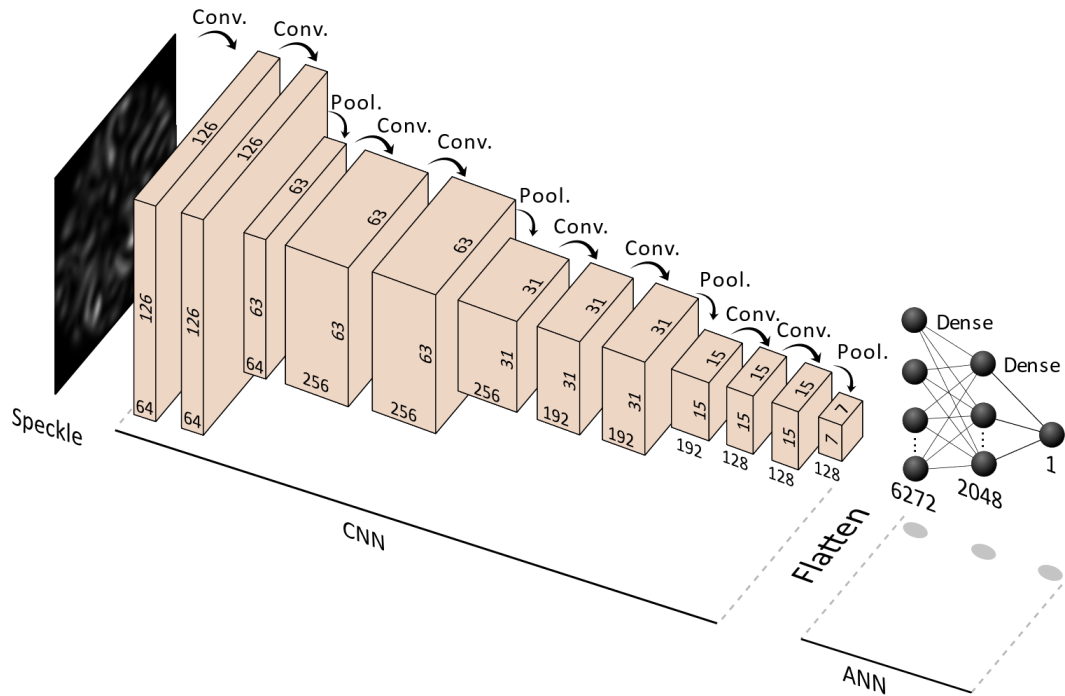
1	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	1	9	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0	0
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
	Clase estimada																			

4.2. Algoritmo de regresión

Este algoritmo toma como base la arquitectura usada en el algoritmo de clasificación anterior. Para este, se hicieron modificaciones en las capas convolucionales y se aumentó las neuronas en la capa oculta de la ANN. Además, se definió solo una neurona de salida, ya que el algoritmo se encargará de predecir un solo valor continuo. Este esquema de regresión es una solución más adecuada para nuestro problema debido a que la naturaleza de la magnitud de la perturbación que se quiere medir, en este caso temperatura, es continua. Para evaluar el resultado usando regresión en la predicción de esta variable, se crearon distintas arquitecturas. La Figura 4-3 muestra como ejemplo la que llamamos arquitectura C.

Es importante resaltar que la regresión es una representación más fiel a este problema en específico de una variable de naturaleza continua como la temperatura. Esto es novedoso en el estado del arte para este tipo de sensores, pues generalmente se implementan otras técnicas de *machine learning*, y en los casos que se usan CNN, se implementa clasificación. Si usamos regresión en lugar de clasificación, el error final será solo el proporcionado por la predicción del algoritmo directamente, y no el ocasionado en la división del dataset en clases.

Figura 4-3: Arquitectura C usada para regresión de temperaturas con specklegramas de entrada. Fuente: Autor.

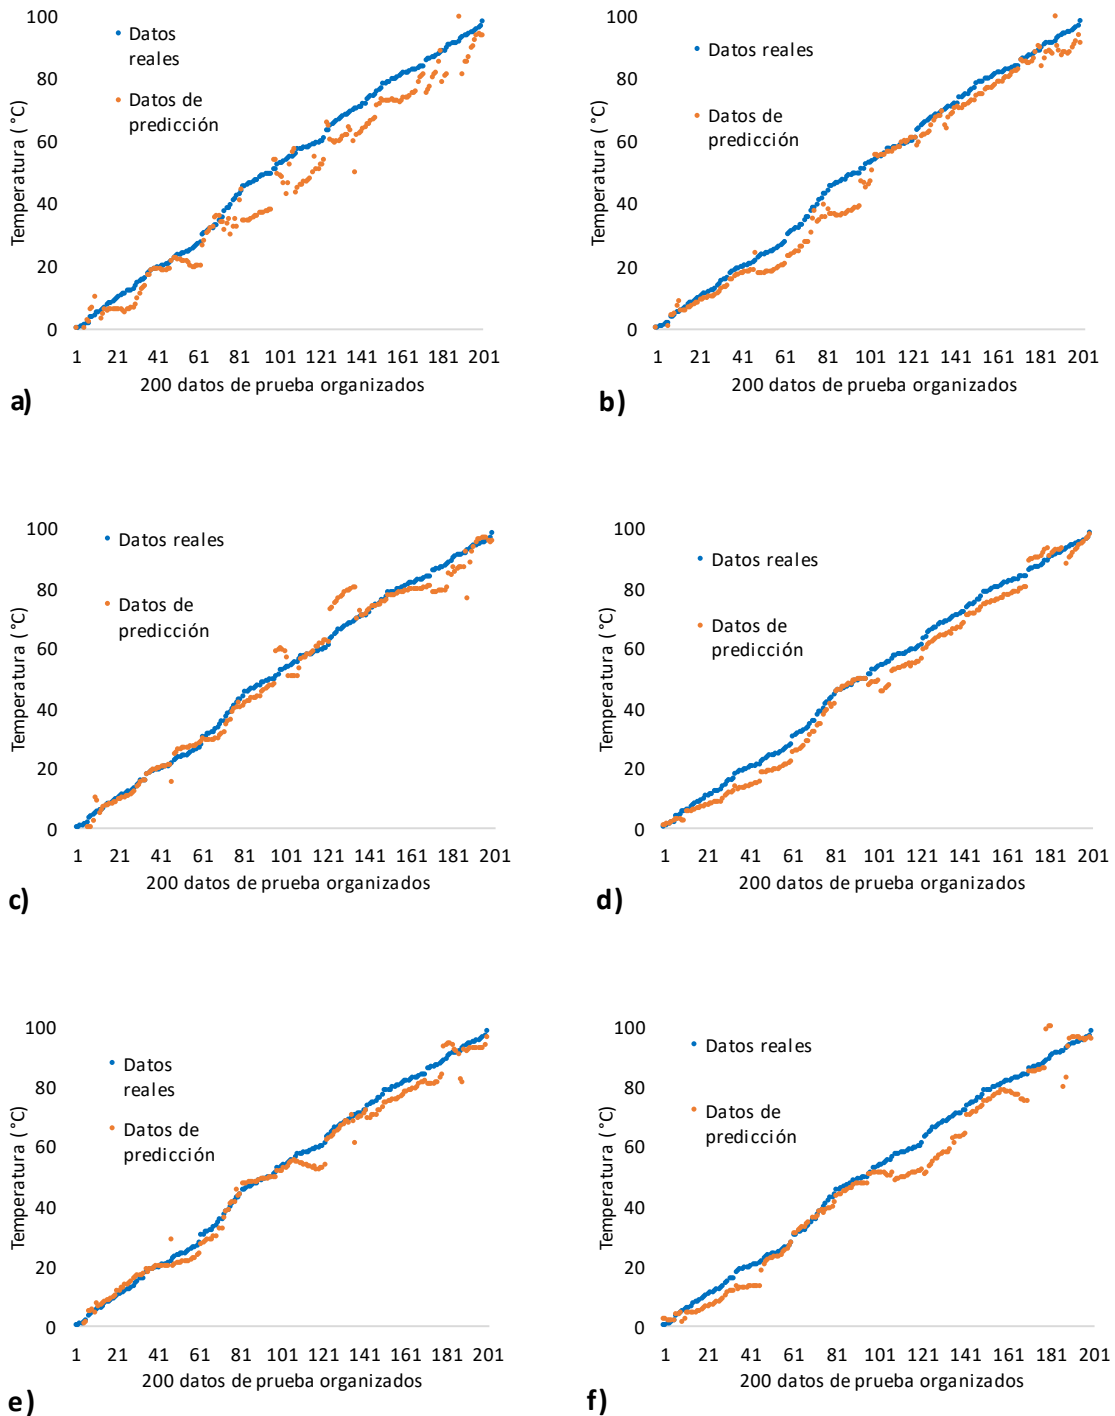


4.2.1. Desempeño de pruebas con CNN para regresión con dataset I.

En base a los resultados de predicción con el algoritmo de clasificación, como se mencionó, se hicieron distintas modificaciones en la arquitectura para que funcionara como una regresión. En la Figura 4-4 se puede apreciar la influencia que tienen estos cambios en la predicción final sobre el dataset I.

Los comportamientos de predicción para los datos de prueba de la arquitectura A, cambiando la tasa de aprendizaje y épocas de entrenamiento, se muestran en la figura 4-4 a), b) y c). Los errores raíz del error cuadrático medio (RMSE, por sus siglas en inglés - *Root Mean Squared Error*) en esos casos fueron, respectivamente: 7.29 °C, 4.76 °C y 4.11 °C. Para el caso de la figura 4-4 c) se determinó una tasa de aprendizaje de 8×10^{-5} y 300 épocas con la que se obtuvo el menor error para esta arquitectura A. Por esto, estos mismos valores se utilizan en las pruebas posteriores de las arquitecturas B, C y D, cuyos resultados se muestran en la figura 4-4 d), e) y f), respectivamente.

Figura 4-4: Predicción con el dataset I en datos de prueba de: a) arquitectura A con ratio de aprendizaje de 4×10^{-5} y 100 épocas. B) arquitectura A con ratio de aprendizaje de 4×10^{-5} y 300 épocas, c) arquitectura A con ratio de aprendizaje de 8×10^{-5} y 300 épocas, d) arquitectura B con ratio de aprendizaje de 8×10^{-5} y 300 épocas, e) arquitectura C con ratio de aprendizaje de 8×10^{-5} y 300 épocas, d) arquitectura D con ratio de aprendizaje de 8×10^{-5} y 300 épocas.



Para estas arquitecturas los RMSE fueron, respectivamente: 4.03 °C, 3.13 °C y 5.48 °C. Esto quiere decir que la arquitectura que mejor desempeño tuvo fue la C. Según la tabla 4-1, mostrada anteriormente, se puede ver que, entre las arquitecturas B, C y D, tiene más influencia positiva en la predicción añadir neuronas en las capas ocultas de la ANN, que añadir bloques de convolución y *pooling* en la CNN (que también tiene influencia solo que menor). Por ello nuestro trabajo se centró, a partir de allí, en la arquitectura C, con 300 épocas y ratio de aprendizaje de 8×10^{-5} . Las pruebas y los análisis de esta comparación entre la arquitectura de clasificación y regresión para specklegramas fue publicado en (Arango, Aristizabal, et al., 2021).

4.2.2. Comparación de desempeño entre los métodos de análisis convencionales y la arquitectura CNN-C para regresión con dataset II.

A partir de las pruebas anteriores donde se pudo observar el comportamiento más adecuado de la arquitectura C con regresión, se crea un nuevo dataset II con variación en los parámetros de simulación de manera que se obtuviera un rango un poco mayor y con más alto número de modos involucrados en la interferencia modal, pero más cercanos a lo posiblemente encontrado en un caso experimental. Esto implicó un costo computacional mucho más alto en la simulación. Sin embargo, este dataset II es valioso porque el patrón de speckle tiene variaciones de intensidad más rápidas, lo que ayuda a validar el desempeño de la arquitectura CNN también en este escenario.

En la Figura 4-5 se muestran las gráficas de caracterización para los métodos convencionales de correlación, potencia y momentos radiales, sobre los datos simulados del dataset II. Estas reducen la información del specklegrama a un solo valor escalar para su posterior predicción. En contraste con el algoritmo de CNN que toma muchas características de la imagen para realizar una posterior predicción.

Se puede ver en la Figura 4-5 b que, usando la potencia óptica como método de interrogación no se puede tomar el rango de 0 °C a 120 °C debido a la poca linealidad de su respuesta. Así que no se incluye esta para ser comparada con los otros métodos que si cubren el rango completo. El método de correlación presenta una curva con un comportamiento cercano a una línea recta, con algunos puntos que se apartan. Para el caso de los momentos lineales primero y segundo también se cubre

el rango total del dataset, pero su comportamiento presenta variaciones mayores alrededor de lo que sería una línea recta de comportamiento.

En la Figura 4-6 se puede observar la predicción de temperatura para el dataset II de la arquitectura C, mostrando un comportamiento bastante cercano en las predicciones para ambos conjuntos (el de entrenamiento y el de prueba). Esto es visible cualitativamente a través de la cercanía de los puntos estimados a la curva ideal de pendiente unitaria. La Tabla 4-3 muestra la comparación cuantitativa para estos métodos usando las métricas RMSE, Error promedio absoluto (MAE, por sus siglas en inglés - *Mean Absolute Error*), Error Máximo y R^2 . Lo que muestra que la aproximación con la arquitectura C basada en CNN tiene un desempeño mejor bajo todas las métricas propuestas.

Figura 4-5: Caracterización del FSS por el método de análisis: a) correlación entre imágenes, b) medición puntual de potencia, c) primer momento radial, d) segundo momento radial.

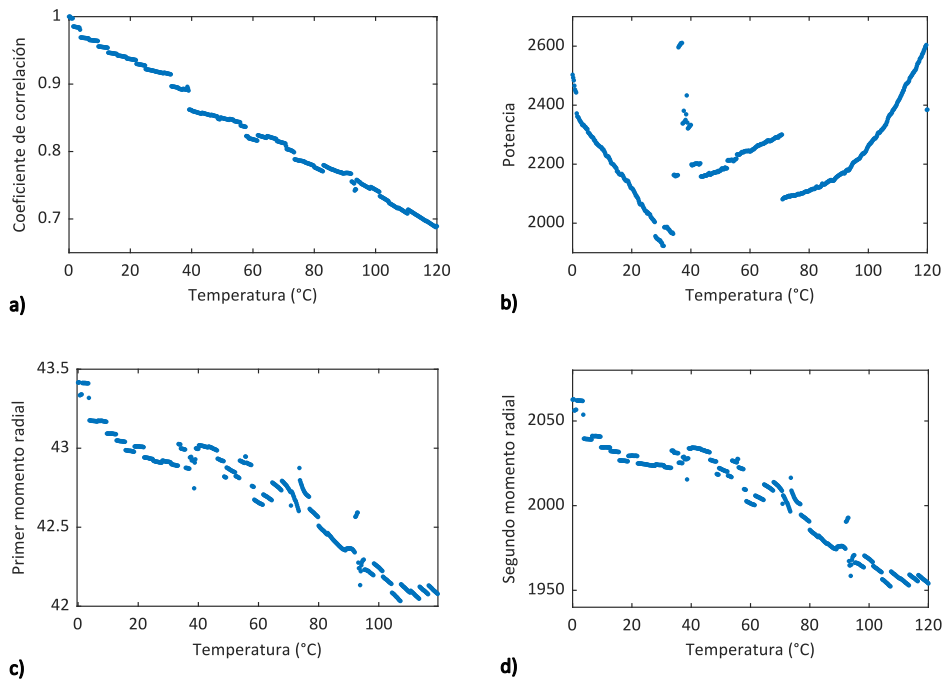


Figura 4-6: Temperatura real vs temperatura estimada por algoritmo de regresión con CNN (arquitectura C) entrenado con dataset II.

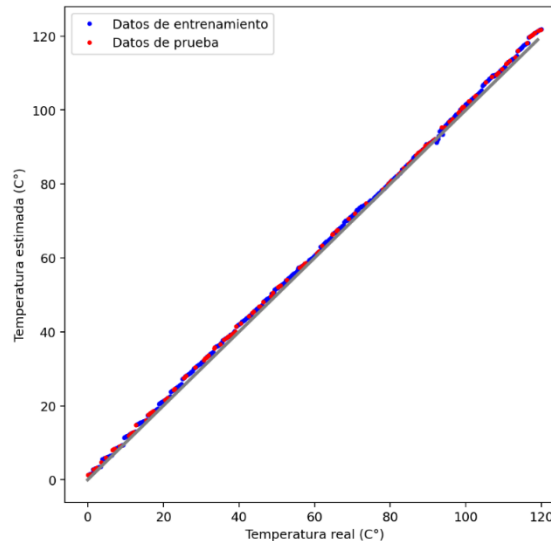


Tabla 4-3: Comparación de desempeño en la predicción con los datos de prueba del dataset II con el algoritmo de regresión CNN y los métodos convencionales.

Método	RMSE (°C)	MAE (°C)	Error máximo (°C)	R ² score
Primer momento radial	10,26	8,81	31,74	0,920
Segundo momento radial	10,97	9,62	28,21	0,909
Coefficiente de correlación	3,21	2,45	9,08	0,992
CNN (Arquitectura C)	1,42	1,31	2,85	0,998

4.3. Entrenamiento con transfer learning


En esta prueba usamos un dataset simulado con un rango mucho más amplio, -50°C a 150°C , el dataset III (Tabla 4-2, Datasets). Esta prueba tenía como objetivo evaluar la arquitectura C y compararla con la arquitectura VGG16-reg, esta es una modificación que realizamos a la red VGG16 (Simonyan & Zisserman, 2014), que es una red robusta para reconocimiento de imágenes (Tabla 4-1, Arquitecturas). En esta arquitectura se aplicó la técnica *transfer learning*, usando los pesos en la etapa convolucional del modelo VGG16 entrenado con la base de datos abierta *Imagenet* (Deng et al., 2009). El transfer learning es una técnica que consiste en transferir el aprendizaje (pesos aprendidos), de una red a otra. Esta técnica es muy útil para ahorrar tiempo de entrenamiento, y, además, en muchas ocasiones, se transfiere el aprendizaje desde una red entrenada en equipos de muy buena capacidad computacional. De esta manera, el transfer learning no solo ahorra tiempo

de entrenamiento, sino que además suele tener mejor desempeño que entrenar desde cero en equipos de menor rendimiento.


Después de transferir el valor de los pesos en la etapa convolucional, se creó una etapa densa específica para nuestra tarea. Esta etapa densa se construyó de dos capas ocultas de 2048 neuronas cada una y una única neurona de salida con activación lineal. La función de pérdida usada fue el error cuadrático medio o MSE (por sus siglas en inglés *Mean Squared Error*). La comparación de desempeño entre la arquitectura C y la VGG16-reg para el dataset III se puede observar en la Figura 4-7. Es claro de estas figuras el buen ajuste de las predicciones con respecto a las temperaturas reales, para ambos conjuntos (de entrenamiento y de prueba), en ambas arquitecturas. Sin embargo, también es visible que la arquitectura C se aleja un poco más de la línea ideal que la VGG16-reg propuesta. Esto lo confirman de manera cuantitativa los errores RMSE obtenidos para todo el dataset. Estos fueron, para la arquitectura C, 1.77 °C, y para la arquitectura VGG16-reg, 0.6 °C.

Para nuestro caso transferir el aprendizaje y el uso de esta arquitectura tuvo mejor desempeño sobre el conjunto de datos simulado III. El modelo VGG16-reg es capaz de representar de mejor manera la interferencia modal. También es importante aclarar que la cantidad de parámetros de este modelo es significativamente mayor. Esto puede optimizarse exhaustivamente para casos de implementación donde se tenga poca memoria o baja capacidad de cómputo, como lo pueden ser el uso de sistemas embebidos. Para el caso de esta tesis, esta arquitectura, en principio se muestra como adecuada para evaluar specklegramas de un montaje experimental. Estas pruebas y resultados están de acuerdo con cumplimiento de los objetivos específicos 2 y 3 de esta tesis. Todo el trabajo de estas últimas secciones está en proceso de revisión por pares en una revista indexada.

Figura 4-7: Temperatura real vs temperatura del dataset III predicha por: a) Arquitectura C, b) Arquitectura VGG16-reg.



a)



b)

5. Montaje experimental: specklegramas experimentales

Aunque este trabajo no tenía como objetivo inicial la prueba de estas metodologías sobre datos experimentales, se decidió superar el alcance de esta al incluir el desarrollo de un montaje físico de un FSS para medición de temperaturas. Así, este montaje tenía como objetivo adquirir conjuntos de datos de specklegramas de un sistema experimental, y, posteriormente probar diferentes métodos de una red convolucional para la predicción de temperatura. Algunas características de este montaje físico son las siguientes:

- Diámetro del núcleo de la fibra: 62.5 μm .
- Diámetro del revestimiento de la fibra: 125 μm .
- Láser de longitud de onda de 633 nm.
- Apertura numérica: 0.14.
- Longitud de zona sensora (Explicada en la *Sección 1.4.3*): 20 mm.
- Sistema calefactor controlado (El desarrollo de este se explica a continuación).
- Cámara Thorlabs DCU224C RGB.
- Plataformas XYZ.
- Objetivo microscopio 20X Olimpux.
- Estructura, tornillería y otros elementos ópticos necesarios para el montaje.

5.1. Sistema calefactor

Para entrenar una CNN se necesitan tomar múltiples specklegramas a distintas temperaturas de perturbación. En la primera fase, en simulación, es fácil asegurar una temperatura específica para la adquisición de cada speckle, pero experimentalmente se necesita un sistema controlado. Por esta razón se desarrolló un sistema calefactor con un control PID, que puede controlar la temperatura sobre una porción de la fibra óptica desde 25 °C hasta 210 °C.


Este sistema fue fundamental para poder automatizar la adquisición de specklegramas experimentales. Además, tiene distintas longitudes para perturbar la fibra (4 mm, 8 mm, 12 mm, 16 mm, 20 mm), y asegurarse con una cinta de cobre.

Este sistema se compone de (Figura 5-1):

- 1 bloque de aluminio, este permite distintas longitudes de perturbación en la fibra (o distintas longitudes de zona sensora).

- 1 termistor NTC 100K, sensor de temperatura.
- 1 tubo calefactor de 12 V 40W.
- 1 Arduino Mega 2560.
- Fuente de 12 V.
- Tarjeta RAMPS 1.4 para el control de potencia.
- Estructura, tornillería y otros implementos necesarios para el ensamble.

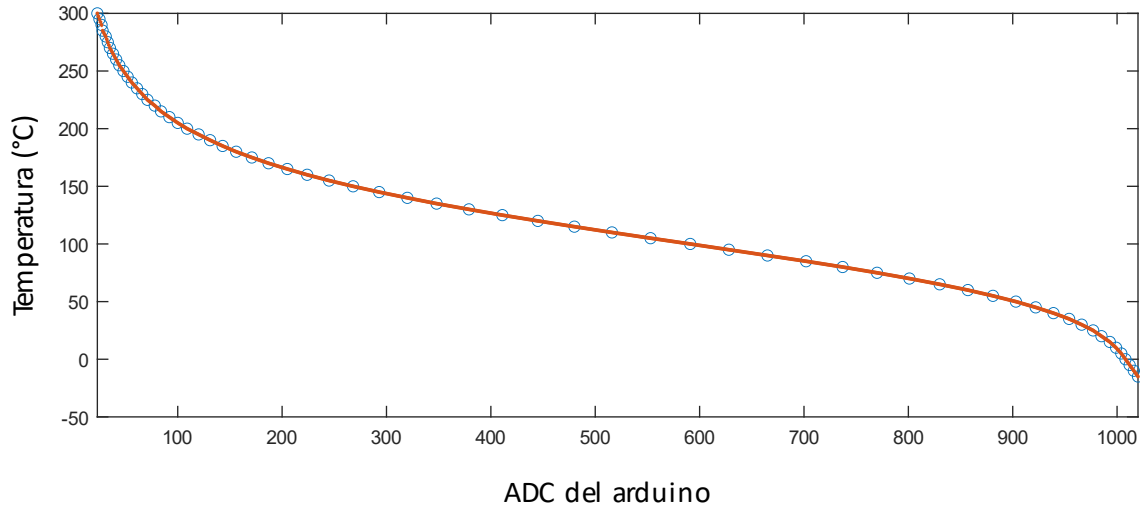
Figura 5-1: Sistema calefactor de distintas longitudes de zona sensora para perturbaciones térmicas en la fibra óptica multimodo.



5.1.1. Acondicionamiento del termistor

Para obtener la medida de temperatura en tiempo real, se acondicionó el termistor, ya que su respuesta con respecto al cambio de temperatura no es lineal. Este acondicionamiento se logró por medio de una tabla de la página de MARLIN (<https://marlinfw.org/>), que es un firmware de impresión 3D en el que se ha muestreado este tipo de sensores a distintas temperaturas. Esta tabla nos presenta una caracterización de valores de temperatura en °C con respecto a los valores obtenidos por el ADC (convertor análogo digital) del Arduino Mega 2560. Así, mediante una interpolación lineal fina (ya que la tabla muestrea cada 5 °C desde -50 °C hasta 300 °C), podemos conocer el valor de la temperatura del sensor (Figura 5-2). Luego de tener el sensor acondicionado se procedió al ajuste del control PID.

Figura 5-2: Acondicionamiento del termistor de NTC 100 K mediante interpolaciones lineales. Los puntos azules son las muestras caracterizadas de *Marlin*, y los naranjados el resultado de interpolaciones entre las muestras. Fuente: Autor.



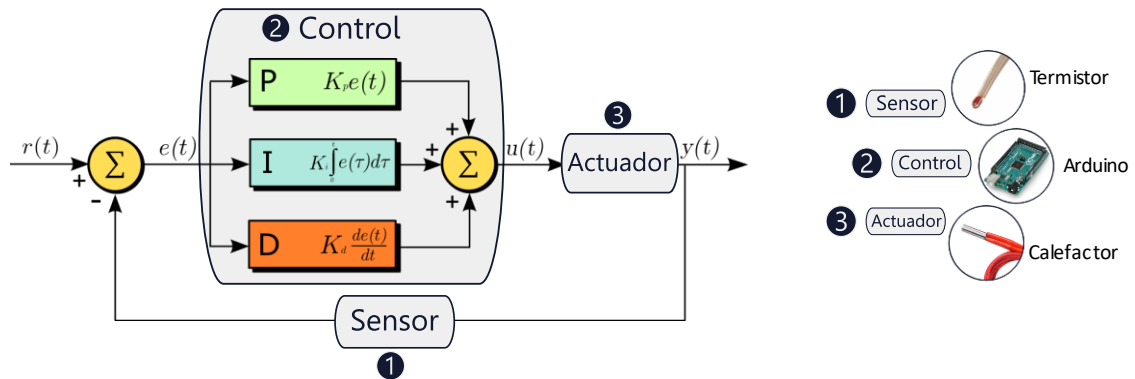
5.1.2. Control PID

En la ingeniería de control, los tres elementos básicos necesarios para tener un sistema de control a lazo cerrado son: sensor, controlador y actuador. En este caso, el sensor es el termistor, el controlador es el Arduino, y el actuador el tubo calefactor. En términos generales, para controlar un sistema necesitamos determinar un *setpoint*, que se refiere al valor deseado de cierta variable, en este caso la variable a controlar es la temperatura. Teniendo un valor deseado y una medida real (lectura del termistor) podemos conocer la diferencia entre estos (lo que llamamos error). Conocer el error es el fundamento para controlar un sistema, pues sin la medición de error no hay una posibilidad de mejora. El mérito del controlador (que en este caso es control digital por medio del Arduino), es ajustar correctamente al actuador con respecto al valor deseado (Figura 5-3).

Para este caso se ajustó un control PID, que, con respecto al error, toma una acción de control proporcional, integral y derivativa. Esto, en las proporciones adecuadas que son ajustadas por medio de las ganancias K_p , K_i y K_d (constantes proporcional, integral y derivativa). El ajuste de estas constantes se realizó por tres métodos: identificación de planta con PID Tuner de MATLAB, PID *autotune* de MARLIN y tanteo. Los mejores resultados fueron por medio del PID *autotune* de MARLIN y tanteo para realizar un ajuste fino.

Además de esto se desarrolló todo el código en Arduino para realizar la interpolación del termistor, el control PID, y la lectura del *setpoint* a través del puerto serial con el usuario, para posteriormente conectar el puerto serial con Matlab y automatizar la captura de specklegramas. El código del arduino con la interpolación del transistor y el control PID se incluye en el Anexo I.

Figura 5-3: Sistema calefactor con control a lazo cerrado. Fuente: Autor.



$u(t)$ = Variable de control PID

$e(t)$ = Valor de error

$r(t)$ = Setpoint

K_p = Ganancia proporcional

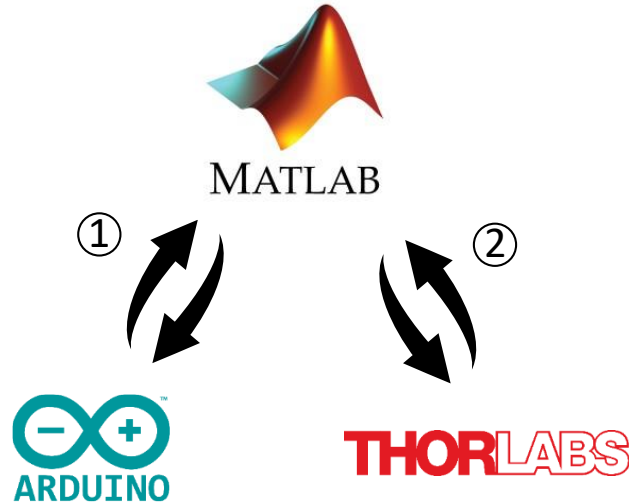
K_i = Ganancia integral

K_d = Ganancia derivativa

5.2. Automatización de la adquisición de specklegramas

Una vez desarrollado el sistema calefactor con control PID ya se podía asegurar una temperatura de perturbación sobre la fibra. Así, se procedió a unir las partes de la cámara, el sistema calefactor (con el Arduino) y el código principal para automatizar la adquisición en Matlab. Nótese que el montaje experimental con la fibra se unió al sistema calefactor como se mostró en la Figura 5-1. El código principal de Matlab tenía una comunicación bidireccional con la cámara, al igual que con el Arduino del sistema calefactor (Figura 5-4). Cada vez que el código principal se estableciera un nuevo *setpoint* de temperatura, se comunicaba con el Arduino, que retornaba la medida real de temperatura.

Figura 5-4: Proceso de adquisición. 1) Matlab envía setpoint al arduino y recibe constantemente la temperatura real, hasta alcanzar el valor deseado. 2) Matlab envía la orden de capturar la imagen a la cámara Thorlabs y la almacena. Fuente: Autor



Al alcanzar el valor deseado, el script de Matlab establece comunicación con la cámara para capturar el specklegrama y guardarlo con su respectiva temperatura. Así el sistema recorre un rango de temperaturas requerido. En la Tabla 5-1 se muestran los parámetros que puede escoger el usuario en el script de Matlab para la toma de specklegramas, en este caso, la tabla muestra los parámetros para el dataset adquirido para esta tesis, del cual se habla con más detalle en la siguiente sección (*Sección 5.3*). La *temperatura inicial* y *final* establecen el rango de temperaturas que se aplicarán a la fibra. El *paso de temperatura* indica el intervalo entre cada captura del specklegrama, es decir, cada cuántos grados se tomará una nueva medición. Por otro lado, la *longitud de onda* y la *longitud de zona sensora* (*Sección 1.5.3*) son parámetros determinados por el hardware, pero se incluyen en el presente estudio debido a que el script de Matlab los utiliza en la nomenclatura de cada captura, lo que ayuda al usuario a mantener una organización adecuada de los datos.

El usuario también tiene la opción de seleccionar un *tiempo de estabilización*, el cual se utiliza para asegurar que el cubo de calefacción alcance una temperatura uniforme, incluyendo la porción de fibra bajo estudio. El *umbral de temperatura aceptable* se define como el valor límite en el que se permite realizar la captura del specklegrama alrededor de la temperatura deseada. Es importante

destacar que, al momento de capturar el specklegrama, este se guarda con la temperatura medida en ese instante por el termistor. Por lo tanto, el *umbral de temperatura* no afecta la precisión de la medida, sino que se utiliza para garantizar que la captura se realice lo más cercana posible a la temperatura deseada. El código de la automatización en Matlab se incluye en el Anexo J.

Tabla 5-1: Parámetros usados en el sistema automatizado con control PID para la toma del dataset experimental de specklegramas. Estos parámetros son modificables según se requiera.

Parámetro	Valor
Temperatura inicial (°C)	25
Temperatura final (°C)	200
Paso de temperatura (°C)	0.175
Longitud de onda (nm)	633
Longitud de zona sensora (mm)	20
Tiempo de estabilización (seg)	20
Umbral de temperatura aceptable (°C)	0.5

5.3. Dataset experimental

Con el sistema de adquisición automatizado, se procedió a la toma de datos con los implementos mencionados. El rango de temperatura que se trabajó para perturbar la fibra fue de 25 °C a 200 °C. Esto se intentó llevar a cabo, hasta donde fuera posible, con un paso de 0.175 °C, pues el comportamiento natural del termistor no es lineal (ver Figura 5-2). En la zona central, la resolución alcanza los 0.15 °C, mientras que en los extremos del rango es de 0.45 °C. De esta forma, al exigirle al sistema un paso de 0.175 °C lo obtendrá cuando se pueda y cuando no obtendrá la más cercana dentro de un umbral (ver Tabla 5-1). Así, se capturaron 1001 specklegramas experimentales etiquetados con sus respectivas temperaturas, que se guardaron en imágenes con extensión “.TIFF” de 16 bits. La nomenclatura para cada archivo se puede observar en la Figura 5-5. Posteriormente este dataset fue preprocesado para adecuarlo al entrenamiento de la CNN. En la Figura 5-6 se muestran algunos specklegramas preprocesados.

Figura 5-5: Nomenclatura de cada specklegrama capturado. Nótese que los elementos en rojo son los únicos que cambian en el dataset.





Figura 5-6: Specklegramas experimentales capturados por el sistema automatizado con control PID.



Con este sistema se obtuvo un dataset para proceder con las pruebas de redes neuronales aplicadas a specklegramas experimentales. Las especificaciones del dataset adquirido son las siguientes:

- Longitud de onda: 633 nm
- Rango de temperatura: 25 °C a 200 °C
- Número de specklegramas: 1001
- Longitud de zona sensora: 20 mm
- Diámetro del núcleo: 62.5 μm
- Diámetro del revestimiento: 125 μm

6. Arquitecturas de redes neuronales adaptadas para regresión de valores de temperatura de specklegramas experimentales

6.1. Arquitecturas adaptadas

En la parte experimental de esta tesis se adaptaron distintas arquitecturas desde redes neuronales clásicas (ANN), redes neuronales convolucionales (CNN) y Transformers de visión. Con cada una de ellas se llevó a cabo una transferencia de aprendizaje en la que se aprovechó los pesos preentrenados que tenían para la clasificación de 1000 imágenes del dataset Imagenet (Deng et al., 2009). Con todas se llevó a cabo un procedimiento similar, en donde se toma cada arquitectura con los pesos de Imagenet sin la parte de clasificación, se agregan 3 capas densas, se agrega un *dropout* (Sección 1.6), se agrega una capa final de regresión y se entrena con el dataset de specklegramas experimentales adquirido. Los códigos de cada arquitectura se adjuntan como anexos a esta tesis, así, de requerirse, se puede seguir en detalle el procedimiento llevado en cada uno.

6.1.1. VGG16-reg

La arquitectura VGG16-reg es nuestra adaptación para regresión de la VGG16 desarrollada por el grupo Visual Geometry Group (VGG) en la Universidad de Oxford (Simonyan & Zisserman, 2014). Esta se destaca por su simplicidad y eficacia en la extracción de características de imágenes complejas. Tiene 16 capas convolucionales y completamente conectadas. VGG16 utiliza filtros pequeños y profundos para capturar detalles finos y patrones relevantes en las imágenes. Con respecto al experimento de la Sección 4.3, se modificaron las capas densas. Ya no corresponden a 2 capas ocultas de 2048 neuronas cada una, sino 3 capas ocultas de 1024. Esto, no solo presentó mejores resultados, sino que redujo el número total de parámetros (Anexo K).

6.1.2. MNet-reg

La MNet-reg es nuestra adaptación para regresión de la MobileNet (Howard et al., 2017). La MobileNet es una arquitectura de redes convolucionales reconocida en visión por computadora. Esta es ligera y eficiente, utiliza capas convolucionales separables en profundidad para reducir los recursos computacionales necesarios. Se diseñó de esta manera para ser usada fácilmente en dispositivos móviles manteniendo muy buen rendimiento en tareas como clasificación y detección

de objetos. A esta se le añadió una capa de *GlobalAveragePooling2D*, 3 capas densas de 1024 neuronas, una capa de dropout, y una capa de salida de una neurona para regresión (*Anexo L*).

6.1.3. ENet-reg

La ENet-reg es nuestra adaptación para regresión de la EfficientNetV2B0 (Tan & Le, 2021). La EfficientNetV2 es una arquitectura convolucional eficiente y de alto rendimiento en visión por computadora. Ha demostrado un excelente desempeño en tareas como clasificación y detección de objetos, superando a otras arquitecturas clásicas, además de tener requisitos computacionales reducidos. Específicamente la que adaptamos (EfficientNetV2B0) es la versión más pequeña de la EfficientNetV2. A esta se le añadió una capa de *GlobalAveragePooling2D*, 3 capas densas de 1024 neuronas, una capa de dropout, y una capa de salida de una neurona para regresión (*Anexo M*).

6.1.4. ANN-reg

La ANN-reg es una arquitectura que creamos, que consta solo de capas densas, es un perceptrón multicapa. Este es el modelo más ligero en términos de respuesta, pero a pesar de solo tener 4 capas ocultas de 256 neuronas, no es el modelo con menos parámetros. Esto se debe a que al aplanar directamente la imagen para ingresarla a la red no se reducen datos como se haría normalmente con *convolución-pooling*. Además de esto se le agregó un *dropout* y una capa de salida de una neurona para regresión (*Anexo N*).

6.1.5. ViT-reg

En los últimos años los Transformers, que son un tipo de red neuronal, han sido disruptivos en el mundo del machine learning. Su uso principal ha sido el procesamiento del lenguaje natural, pero gracias a los *mecanismos de atención* han obtenido muy buenos resultados y se han llevado a otras áreas de ciencia computacional (Vaswani et al., 2017). Por esta razón la comunidad científica no se tardó en implementar Transformers adaptados para la tarea de visión por computador. Entre ellos se encuentra el ViT (*Vision Transformer*)(Dosovitskiy et al., 2020). ViT-reg es nuestra adaptación de ViT para regresión, en esta añadimos una operación *flatten*, 3 capas densas de 1024 neuronas, un *dropout* y una capa de salida de una neurona para regresión (*Anexo Ñ*).

Para entrenar cada una de estas arquitecturas se usó el optimizador *Adam* (Kingma & Ba, 2014). El conjunto de datos experimentales se dividió en 90% y 10% para los datos de entrenamiento y prueba respectivamente. Luego, de los datos de entrenamiento se tomó un 20% para validación, que sería usado para validar el entrenamiento de cada modelo. Todas estas divisiones se realizaron con los datos organizados de manera aleatoria, ya que esto ayuda a que el entrenamiento no tenga sesgos y que los modelos puedan generalizar correctamente. La optimización de hiperparámetros se explica en la *Sección 6.3*.

6.2. Aumento de datos

El aumento de datos es una técnica que se suele usar para añadir más variabilidad a los datos y tener un dataset de mayor tamaño para un entrenamiento más robusto de la red y para que pueda generalizar mejor. Para llevarlo a cabo se suelen hacer transformaciones en las imágenes originales, y generar nuevas instancias ligeramente modificadas. A pesar de esto hay que tener en cuenta que este aumento se debe hacer con cuidado, siempre se debe tener en cuenta la *aplicación final*. Ya que si no se hace de esta manera en el mejor de los casos se puede estar realizando trabajo de más, sin utilidad, y en el peor de los casos entrenando mal el modelo. En ese sentido, para el aumento de datos que se mostrará en esta sección se asume una *aplicación final* de un sistema más portátil y un poco más susceptible a perturbaciones que el sistema actual en un laboratorio de óptica controlado. Este aumento de datos está presente en el código de cada arquitectura (del *Anexo K al Ñ*). Lamentablemente, por razones de computación actual y de tiempo no se llevó a cabo en las pruebas del *Capítulo 7*. Aun así, este aumento se ajustó y se plantea utilizar en futuros avances de este proyecto. Por esta razón, se presenta esta sección con los siguientes aumentos en base a la aplicación final que asumimos:

Rotaciones

Dado que en la aplicación final se asume un sistema portátil, este tendrá que ser adaptado a un sistema de láser cilíndrico en el que la fibra tendrá toda clase de rotaciones, por esta razón el aumento aleatorio de rotaciones va desde los 0 a los 360 °C.

Escalas

La escala se refiere al aumento o reducción de la imagen para crear una nueva instancia. Para el caso de nuestra aplicación final tenemos una escala aleatoria entre 0.95 y 1.05 con respecto a la imagen. Además, esta escala se realiza independiente en cada eje, lo que significa que la imagen tendrá un poco de deformación como podría ocurrir en la aplicación final, pero solo un poco. Estos valores fueron elegidos experimentalmente como los más apropiados.

Traslaciones

De igual manera, para las traslaciones se establecieron valores de traslaciones aleatorias que se apropiadas experimentalmente, con respecto a la aplicación final que se asumió, en cada eje: una proporción máxima de 0.008. Es decir, aleatoriamente varía traslaciones horizontales y verticales entre -0.008 y 0.008 con respecto a la proporción total de la imagen.

Contraste


También se tuvieron en cuenta algunas posibles fluctuaciones de luz que hubiera en la aplicación final. Me refiero a fluctuaciones en la intensidad de luz, mas no en la longitud de onda, ya que su aplicación final se haría con un láser monocromático. Así que se estableció experimentalmente un contraste aleatorio entre 0.8 y 1.2 con respecto a la intensidad normal de la imagen.

Ruido

Para tener en cuenta un posible ruido de cámara, se aplicó un ruido gaussiano aleatorio con desviación entre 0.0 y 0.5 y con una media de 0.0. Estos parámetros también fueron ajustados experimentalmente.

La Figura 6-1 ilustra cada tipo de aumento considerado anteriormente, cabe aclarar que esta ilustración se realiza principalmente para dar una idea al lector de su funcionamiento, por esta razón en la figura algunos parámetros tienen proporciones más altas que las antes mencionadas. La función que genera estos aumentos recibe una imagen, aplica los 5 aumentos de manera aleatoria, y retorna una nueva instancia de la imagen. Esto se puede ver en más detalle en los códigos del *Anexo M*.

Figura 6-1: Ilustración de técnicas de aumento de datos aplicadas a specklegramas experimentales: rotación, contraste, escalado, traslación y adición de ruido.




6.3. Optimización de hiperparámetros

Cómo se explicó brevemente en el *Capítulo 1*, la *optimización* es el proceso que busca la mejor combinación de parámetros. Así, los parámetros de la red son ajustados con el proceso de optimización, pero los parámetros del optimizador ¿cómo se ajustan? Por decirlo de alguna manera, lo que se quiere es *optimizar el proceso de optimización*. A esto se le conoce como *optimización de hiperparámetros*. Hay varias maneras en las que se puede hacer: manualmente, con librerías de optimización automática de hiperparámetros (Akiba et al., 2019; Bergstra et al., 2015) y recientemente, se han desarrollado algunos algoritmos basados en redes neuronales, que no necesitan optimizar hiperparámetros para tener resultados óptimos (Metz et al., 2022), entre otros. En este trabajo se implementó principalmente *Optuna* (Akiba et al., 2019) para la optimización de hiperparámetros. Esta es una librería abierta de Python para esta finalidad.

En la Figura 6-2 se muestra parte de la optimización con *Optuna*, en este caso para la optimización de hiperparámetros para la MNet-reg. En esta Optuna prueba con 50 intentos o *trials* distintas combinaciones de hiperparámetros durante 100 épocas cada una, para así encontrar la mejor. Para el caso de la MNet-reg, estos hiperparámetros corresponden a *Ratio de aprendizaje*, y el número de capas entrenables de la red (ya que se podían tomar los pesos de la transferencia de aprendizaje en toda la parte de extracción de características, o se pueden reentrenar algunas capas según se tengan mejores resultados).

Figura 6-2: Ejemplo de algunos intentos (*trials*) de Optuna en la optimización de hiperparámetros para la arquitectura MNet-reg y su efecto en el entrenamiento.




De esta manera, se encontraron parámetros óptimos para el entrenamiento de cada una de las arquitecturas propuestas, teniendo en cuenta los tiempos de procesamiento necesarios o los costos computacionales implicados.

7. Resultados de arquitecturas de redes neuronales adaptadas sobre specklegramas experimentales

En esta sección se presentan los resultados del entrenamiento de las arquitecturas discutidas en el *Capítulo 6* para el conjunto de specklegramas experimentales adquiridos. Además, se muestra también la comparación con los métodos convencionales de correlación entre imágenes, medición de potencia y momentos radiales.

En la Figura 7-1a se muestra la curva del coeficiente de correlación entre imágenes con la temperatura. Es evidente que para todo el rango de temperaturas del dataset el comportamiento de este coeficiente tiene los problemas que se mencionaron como justificación de la búsqueda de alternativas de análisis: no linealidad, cambios abruptos, sensibilidades variables. Esto impide usar este coeficiente para caracterizar el sensor para todo el rango de temperatura. De esta manera se hace necesario acotar este rango a la sección donde el sensor tiene un comportamiento estable y lo más lineal posible. La Figura 7-1b muestra la reducción de este rango dinámico a la sección entre 25 °C hasta 40 °C. En este rango el coeficiente de correlación tiene un buen desempeño, pero el rango terminó reduciéndose en un 91%, lo que disminuye drásticamente la capacidad del sensor.


Figura 7-1: Curva de respuesta del coeficiente de correlación entre specklegramas con el cambio en temperatura. a) Curva para el rango completo de datos experimentales; b) reducción del rango a zona lineal entre 25 °C y 40°C.



De manera similar al coeficiente de correlación, para el segundo momento radial no se puede aprovechar todo el rango (Figura 7-2a), por lo que su rango también se acota a la zona de 25°C a

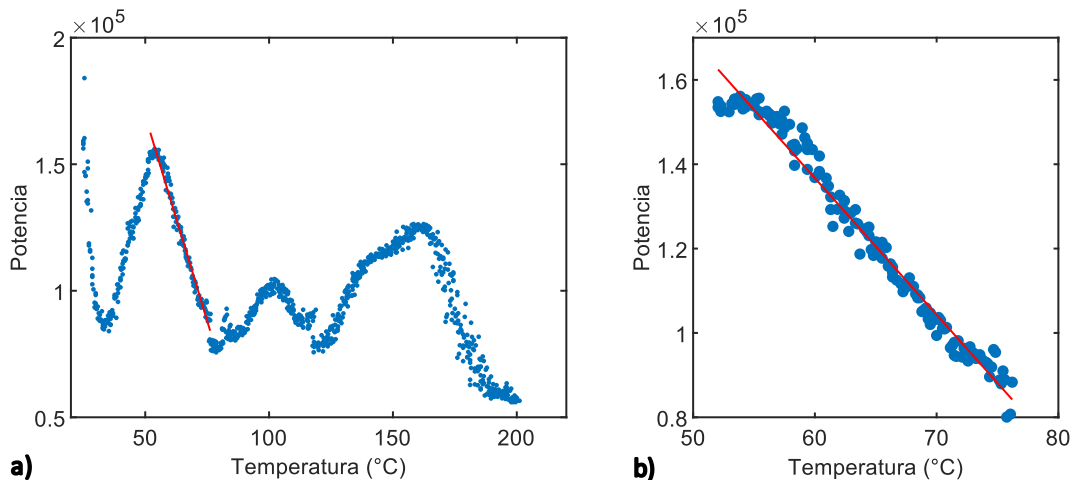
40°C (Figura 7-2b). No se muestra el resultado para el primer momento radial por ser similar en comportamiento a este último, y, por tanto, no aportar nada nuevo en la comparación.

Figura 7-2: Curva de comportamiento del segundo momento radial con el cambio en temperatura para el dataset experimental. a) Curva para el rango completo de datos experimentales; b) reducción del rango a zona lineal entre 25°C y 40°C.



La Figura 7-3a muestra el comportamiento de la medición de potencia en una zona de los specklegramas con el cambio en temperatura. Precisamente, como se había mencionado, esta curva tiene un comportamiento inestable. En la Figura 7-3b se muestra la reducción a un rango más corto para asegurar que se mantiene un comportamiento lineal de la curva de respuesta del sensor.

Figura 7-3: Curva de comportamiento de la medición de potencia con el cambio en temperatura para el dataset experimental. a) Curva para el rango completo de datos experimentales; b) reducción del rango a zona lineal entre 52°C y 76°C.



Todos estos métodos de análisis de specklegramas usados convencionalmente, como se muestra de nuevo en este capítulo al usarlos sobre specklegramas experimentales, presentan los inconvenientes ya mencionados que dieron lugar a la búsqueda de alternativas de análisis para specklegramas.

La Figura 7-4 muestra las curvas de temperatura real vs temperatura estimada para las arquitecturas MNet-reg, Enet-reg, VGG16-reg, ANN-reg y ViT-reg. En estas gráficas se pueden observar los buenos comportamientos de estos modelos, para el rango completo de 25 °C a 200 °C de los datos experimentales usados en el entrenamiento. Aun así, al comparar las curvas, también es posible observar que la arquitectura donde el ajuste de las predicciones a la línea ideal es más alto, es en la curva correspondiente a la arquitectura MNet-reg (Figura 7-4a). Cualitativamente se podría decir que este ajuste va disminuyendo sucesivamente en las curvas subsecuentes (en realidad este criterio de mayor a menor ajuste cualitativo fue el que se usó para ordenar estas gráficas).

La Tabla 7-1 muestra las métricas RMSE, MAE y Error máximo para evaluar de manera cuantitativa el desempeño de las arquitecturas entrenadas, además de evaluar también el desempeño de los métodos convencionales sobre el conjunto de specklegramas experimentales. Los errores RMSE y MAE son similares con respecto a lo que describen como métrica, sin embargo, el RMSE penaliza de manera más drástica los valores de error más altos y de manera más leve valores de error más bajos. Por su parte, el error absoluto medio (MAE) es el promedio de todos los errores absolutos. De esta manera, el MAE (en °C) nos da información del comportamiento del modelo para representar los datos en general, y el RMSE nos da información no solo de los datos en general sino también de errores atípicos en la predicción.

Figura 7-4: Temperatura real vs temperatura estimada sobre los specklegramas experimentales por las arquitecturas: a) MNet-reg, b) ENet-reg, c) VGG16-reg, d) ANN-reg y e) ViT-reg.

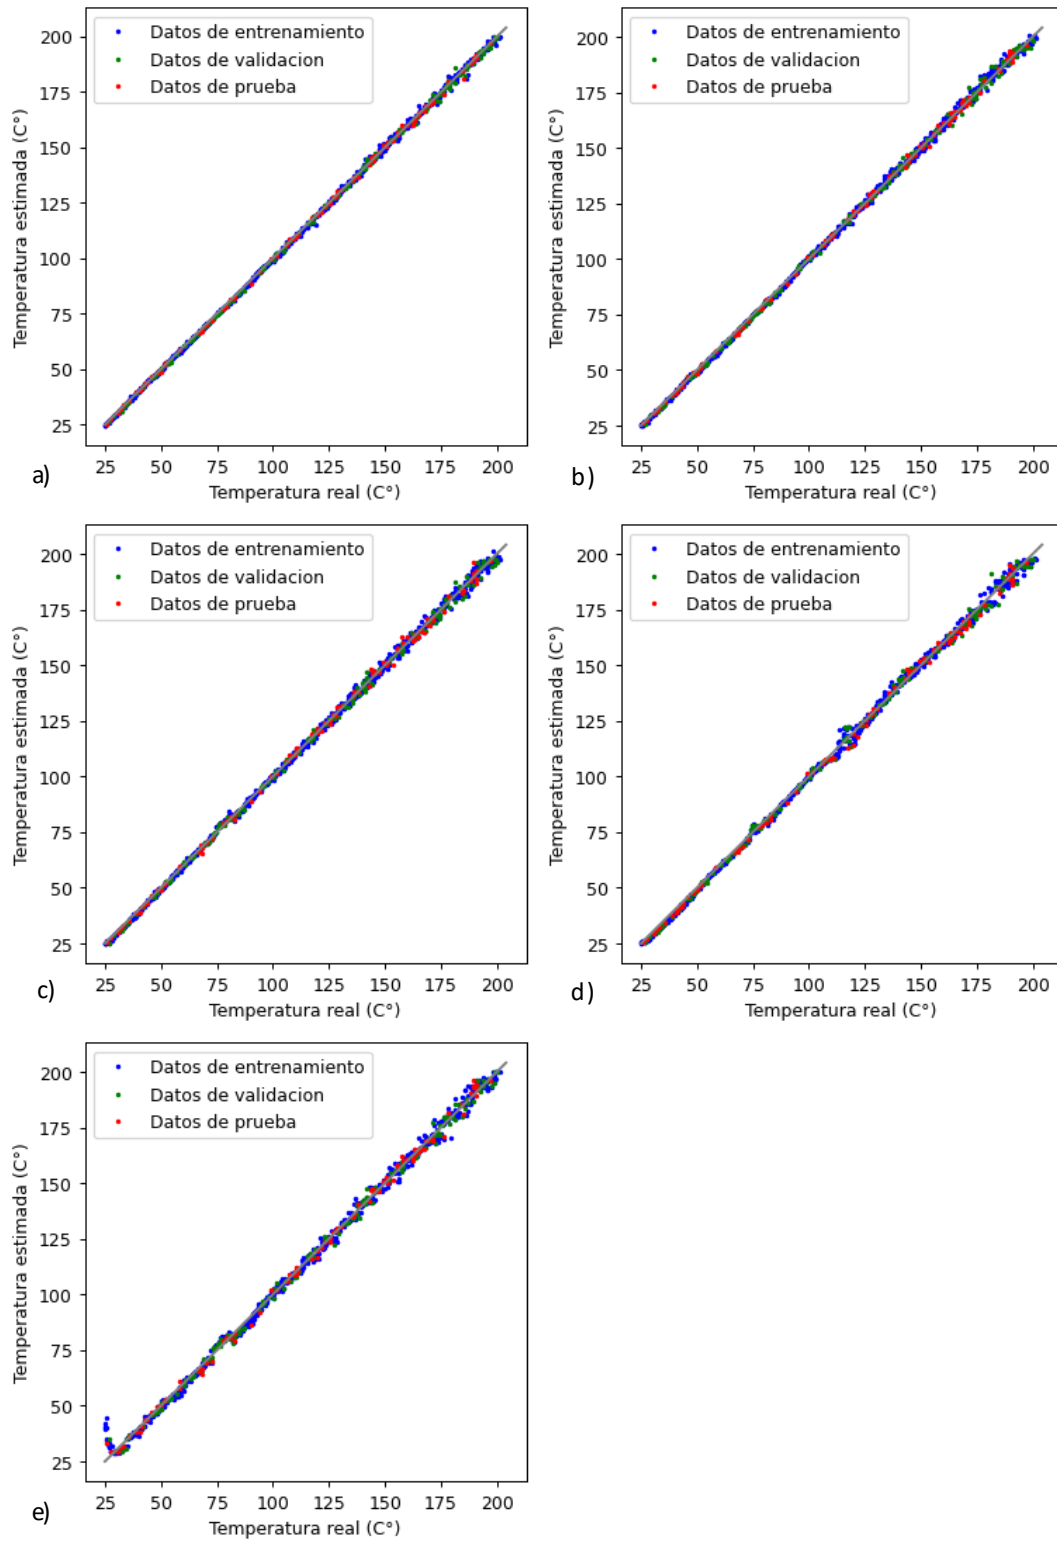


Tabla 7-1: Métricas de predicción con el dataset experimental para las arquitecturas entrenadas y para los métodos convencionales.

Método	RMSE (°C)	MAE (°C)	Error máximo (°C)	Rango dinámico
MNet-reg	0.943	0.699	3.770	25 °C a 200 °C
ENet-reg	1.339	1.034	3.748	25 °C a 200 °C
VGG16-reg	1.726	1.317	6.417	25 °C a 200 °C
ANN-reg	1.929	1.526	5.572	25 °C a 200 °C
ViT-reg	2.166	1.631	8.018	25 °C a 200 °C
Potencia	1.063	0.824	2.851	52 °C a 76 °C
Correlación	0.856	0.721	2.139	25 °C a 40 °C
Segundo momento radial	2.043	1.615	5.928	25 °C a 40 °C
Primer momento radial	2.779	2.138	8.353	25 °C a 40 °C

En la Tabla 7-1, las métricas de las arquitecturas entrenadas se obtuvieron para predicciones sobre el conjunto de prueba cubriendo el rango de temperaturas de 25 °C a 200 °C, el cual es el rango completo del experimento. Mientras que, para los métodos convencionales, estas métricas se calcularon para los rangos acotados donde se tenía una buena linealidad en las curvas de respuesta. Se podría decir que los resultados de las técnicas convencionales son aceptables, pero esto es así solo por el acotamiento de los rangos. Es decir, las arquitecturas adaptadas y entrenadas predicen valores térmicos en un **rango casi 12 veces** mayor a los métodos convencionales y con desempeños similares o mejores aun cubriendo todo el rango, como es el resultado de la MNet-reg. En general, se puede decir que se demuestra la robustez y superioridad tanto de la ANN, como de las CNN, como del Transformer de Visión en cuanto a su capacidad de predicción.

Las métricas de las arquitecturas propuestas se obtuvieron a partir de las predicciones de los datos de **prueba**, es decir, datos desconocidos para estas arquitecturas, lo que demuestra su capacidad de *generalizar*. Esta capacidad de *generalizar*, como es sabido, se refiere a que el modelo es capaz de predecir con precisión usando specklegramas que no usó en la fase de entrenamiento. En contraste al *overfitting* o sobre aprendizaje que sucede cuando un modelo tiene muy buen desempeño con los datos que se entrenó, pero no se desempeña correctamente con los datos de

prueba. Es decir, para estas arquitecturas probadas se obtuvo una buena capacidad de generalización.

Por otro lado, la Tabla 7-2 contiene varias características importantes desde el punto de vista de desempeño computacional para las arquitecturas entrenadas. Estos resultados fueron obtenidos usando una GPU NVIDIA RTX 3060. En esta tabla se puede apreciar la característica del número de parámetros *N Param.*, que corresponde a la cantidad de parámetros que la red optimiza durante el entrenamiento, se aclara que este es el número total de cada modelo, ya que en el proceso de transferencia de aprendizaje se aprovechan los valores de la mayoría de los parámetros, y se optimizan unos pocos en comparación. Los *FLOPs* (el número de operaciones de punto flotante realizadas por el modelo durante la predicción), se utilizan para medir la carga computacional y la eficiencia de cada modelo. Un menor número de *FLOPs* puede indicar un modelo más eficiente en términos de uso de recursos computacionales. El *tiempo de inferencia* indica el tiempo que tarda cada modelo en realizar predicción. En este caso se muestra en segundos, y corresponde a la predicción de un batch (conjunto) de 32 imágenes. En esta misma Tabla 7-2 también se vuelven a listar los errores RMSE, MAE y Error Máximo para facilitar la comparación de desempeño computacional con desempeño de predicción.

Tabla 7-2: Características de los modelos propuestos usando una GPU NVIDIA RTX 3060 para la predicción del conjunto de prueba de specklegramas experimentales. Las unidades del tiempo de inferencia están en segundos para un batch de 32 imágenes. Las unidades del RMSE, del MAE y del error máximo en °C.

Modelo	N Param.	FLOPs	Tiempo de inferencia	Errores		
				RMSE	MAE	Error máximo
MNet-reg	6378689	1151930497	0.0556	0.943	0.699	3.770
ENet-reg	9331281	1462136372	0.0704	1.339	1.034	3.748
VGG16-reg	42506049	30768509953	0.1188	1.726	1.317	6.417
ANN-reg	38733057	77465089	0.0371	1.929	1.526	5.572
ViT-reg	88686337	35248801816	0.2358	2.166	1.631	8.018

En la Tabla 7-2 se puede ver que la arquitectura que tiene un mejor desempeño desde el punto de vista de predicción es la MNet-reg, mientras que desde el punto de vista computacional la ANN-reg tiene unos requerimientos en FLOPs y tiempos de inferencia menores, aunque no es la arquitectura con menor número de parámetros. También es de notar que los tiempos de inferencia se pueden

considerar bajos para todas las arquitecturas, ya que los datos dados en la tabla, en la inferencia para 32 imágenes, están en el orden de las centésimas o décimas de segundo. Así, se puede decir que la arquitectura MNet-reg, que como se mencionó fue diseñada para dispositivos móviles, presenta un equilibrio superior entre requerimientos computacionales y desempeño de predicción.

Por su parte, el transformer de visión no obtiene los mejores resultados en este caso, a pesar de su desempeño superior en la literatura sobre algunas arquitecturas convolucionales para clasificación de imágenes, esto se puede deber a las siguientes consideraciones:

- Los ViTs tienen muy buena capacidad para adquirir los componentes de baja frecuencia en una imagen, pero debido a su funcionamiento, las convolucionales tienen mayor capacidad que los ViTs para adquirir componentes de alta frecuencia (Bai et al., 2022). Esto puede ser particularmente determinante en nuestra aplicación de regresión a partir de specklegramas. Ya que los cambios de temperatura ocasionan cambios muy específicos de la imagen, es decir, componentes de alta frecuencia.
- Los ViTs requieren una cantidad de datos de entrenamiento mucho mayor a los de las CNNs (Dosovitskiy et al., 2020).
- El entrenamiento de los ViTs es mucho más costoso computacionalmente que las otras arquitecturas, y ya que se hace más difícil y demorada la elección de parámetros e hiperparámetros, puede haber una combinación más apropiada que la que se consiguió.

En esta Tabla 7-2, también se puede ver como las arquitecturas ENet-reg y VGG16-reg tienen un buen desempeño de predicción, aunque superadas por la MNet-reg, tanto en requerimientos computacionales como desempeño de predicción. En cuanto a la arquitectura VGG16-reg, que había mostrado un muy buen desempeño sobre los datos simulados, tiene un menor desempeño sobre este conjunto de datos experimentales. Además, este desempeño es superado por las redes MNet-reg y ENet-reg que adicionalmente tienen menor costo computacional. Esto muestra que, ante el avance tan rápido en el área del aprendizaje de máquinas, la mejor red encontrada puede ser superada por nuevas arquitecturas, lo que también sugiere la posibilidad de seguir explorando alternativas con mejoras para el análisis propuesto. Aun así, en términos generales, a partir de nuestras pruebas, la arquitectura que hemos encontrado como más adecuada para nuestro problema es la MNet-reg.

8. Conclusiones y recomendaciones

8.1. Conclusiones

A lo largo de los capítulos anteriores hemos expuesto y analizado los procedimientos que se han usado y los resultados que se han obtenido para la solución del problema y los objetivos planteados. En este capítulo presentamos las conclusiones más significativas de este desarrollo:

- **Generación de specklegramas sintéticos**

Se desarrolló una metodología para la generación de los patrones de interferencia modal o specklegramas, atendiendo a lo propuesto como objetivo específico 1. Estos specklegramas se obtuvieron por medio del método de elementos finitos (FEM) en la plataforma Comsol enlazada con Matlab. En este desarrollo se observó la influencia de factores como apertura numérica de la fibra óptica, longitud de onda en la cantidad de modos propagantes, y por tanto, en la conformación del patrón de speckle. Estas simulaciones mostraron efectivamente la posibilidad de acercarse computacionalmente a los patrones producidos por un sensor de specklegramas de fibra óptica real. Los conjuntos de datos generados con esta metodología están disponibles abiertamente para que la comunidad científica haga uso de ellos en sus investigaciones (Arango et al., 2022).

El uso de las simulaciones permitió evaluar metodologías de análisis de specklegramas como los que llamamos métodos convencionales. Estos fueron los métodos de coeficiente de correlación, de momentos radiales y de medición de potencia. Además de también haber permitido evaluar otras estrategias auxiliares como uso de ROIs en el análisis. Así se puede decir que, entre estos métodos, el que generalmente ofrece mayor desempeño es el método de coeficiente de correlación, seguido de los momentos radiales y por último el método de potencia. Sin embargo, todos estos métodos muestran variabilidades altas en su curva de respuesta, aun usando la estrategia de ROI que al seleccionarla adecuadamente es de ayuda para mejorar esta variabilidad, los rangos de medida útil siguen siendo limitados.

Se mostró, a partir de las simulaciones, la influencia de la longitud de la zona sensora, o zona del sensor expuesta a la perturbación térmica, en el comportamiento del sensor. Al analizar estos sensores con los métodos convencionales, se mostró que, la longitud sensora es

determinante en la sensibilidad y rango de medida alcanzado por el sensor. A mayor longitud sensora, mayor sensibilidad, pero menor rango útil de medición (Arango, Vélez, et al., 2021).

- **Implementación de redes neuronales para el análisis de specklegramas sintéticos**

Atendiendo al uso reconocido en el estado del arte de las redes CNN en la clasificación de imágenes, inicialmente se implementó una red CNN en clasificación para la predicción de temperaturas en specklegramas. Esta evaluación mostró la factibilidad del análisis de specklegramas de fibra óptica con este tipo de redes. En este caso se obtuvo una clasificación para 20 clases de temperatura dentro de un rango de 0 a 100°C, con una precisión de 99.5%. A pesar de esta precisión en este caso existió un error intrínseco de 5°C debido a la división por clases del rango de temperaturas.

Basados en la arquitectura CNN de clasificación, se desarrollaron varios modelos de redes convolucionales con cambios de parámetros como cantidad de capas convolucionales o capas ocultas, adaptándolos adicionalmente para que el tipo de predicción fuera un valor continuo por regresión y no un valor discretizado por clases. Con estos modelos se obtuvo un desempeño de predicción con ajuste alto de los valores de temperatura para los conjuntos de datos simulados sobre todo su rango. Por ejemplo, el error RMSE y el error máximo fueron de 1,42 y 2.85, respectivamente, para la arquitectura que denominamos CNN-C usada sobre el conjunto de datos II con rango de 0 a 120°C. Estos resultados usando esquemas de clasificación y regresión se publicaron en (Arango, Aristizabal, et al., 2021).

Se implementó y adaptó la arquitectura de clasificación de imágenes VGG16 para el análisis de los conjuntos de datos de specklegramas simulados usando regresión y no clasificación. Adicionalmente, se aplicó la técnica de transferencia de aprendizaje del modelo preentrenado con el conjunto de datos público Imagenet. La arquitectura obtenida la denominamos VGG16-reg. Esta estrategia mostró resultados que superaron en desempeño las arquitecturas CNN propuestas. El valor RMSE para la arquitectura VGG16-reg fue de 0.6°C, en contraste con un RMSE de 1.77°C para la arquitectura CNN-C, sobre el conjunto de datos III. Estas evaluaciones de diferentes arquitecturas de redes dieron alcance al objetivo específico 2 de esta propuesta.

- **Comparación de métodos convencionales y redes neuronales para el análisis de specklegramas sintéticos**

Las redes CNN implementadas y la VGG16-reg fueron comparadas entre sí y con los métodos tradicionales alcanzando el objetivo específico 3 de esta tesis. Los resultados mostraron como el desempeño del análisis de specklegramas de fibra óptica por medio de redes neuronales es superior a los métodos convencionales. Estas pruebas ponen de manifiesto la robustez de las redes convolucionales para predecir temperatura a partir de las imágenes sobre rangos amplios y para diferentes condiciones de los conjuntos de datos. Parte de este trabajo de comparación se presentó en el XVII ENO/XIII CANCOA 2021 y en el XXIX Congreso Nacional de Física 2022. Adicionalmente, el trabajo completo de comparación de pruebas de CNNs, VGG16-reg y transferencia de aprendizaje se encuentra en revisión por pares para publicación en la revista indexada Photonic Sensors.

Se puede concluir que la razón más importante para la superioridad de las arquitecturas planteadas sobre los métodos convencionales es la *extracción de características*. Los métodos convencionales reducen la información de toda la imagen a un solo valor escalar: la correlación extrae un coeficiente de correlación entre imágenes, la medición de potencia extrae un valor de intensidad, etc. Esto hace que la descripción de los specklegramas con el cambio de temperatura esté limitada a esa característica específica dejando de usar otros posibles descriptores que también sean de valor para modelar esa relación. Por otro lado, las arquitecturas propuestas basadas en redes neuronales extraen múltiples características y, posteriormente, encuentran la mejor manera de representar a través de estas características la correspondencia entre el specklegrama y su temperatura específica. Esto permite, como se observa en los resultados al adaptarlos para regresión, modelar más adecuadamente las curvas de respuesta mejorando el rango de medición y la precisión en las mediciones.

- **Desarrollo de un FSS automatizado para medición de temperatura, implementación de redes neurales adaptadas para regresión y comparación con métodos convencionales de análisis.**

Superando los alcances y objetivos propuestos en este trabajo de maestría, se implementó un sistema experimental de FSS para medición de temperatura. Este es un sistema automatizado

basado en control PID que adquiere specklegramas reales del sensor con su correspondiente etiqueta de temperatura. Debido a las características del termistor usado como medidor de temperatura de referencia, la resolución de este sistema varía a lo largo del rango de temperaturas, siendo más precisa en el punto medio que en los extremos. En la zona central, la resolución alcanza los 0.15 °C, mientras que en los extremos del rango es de 0.45 °C. Debido a esta variación, concluimos que la resolución final del sistema es de 0.45 °C. Con este sistema se obtuvo un conjunto experimental de 1001 specklegramas en un rango de temperaturas de 25 °C a 200 °C. Esta base de datos se está preparando para publicación y así permitir acceso a toda la comunidad interesada.

También extendiendo el alcance inicial propuesto para este proyecto, y al haber demostrado la pertinencia del uso de redes neuronales para el análisis de los specklegramas, se implementaron otras distintas arquitecturas desde redes neuronales (ANN), redes convolucionales (CNN), hasta Transformers de visión para analizar los datos experimentales. Adicionalmente, se aplicó herramientas del aprendizaje de máquinas como es la transferencia de aprendizaje, aumento de datos y el uso de optimizadores de hiperparámetros como los provistos por la librería abierta *Optuna*. También se modificó todas estas arquitecturas para su uso en predicción por regresión. Este trabajo muestra la madurez adquirida en el uso de estas herramientas y su adaptación para el problema propuesto en esta tesis.

Las redes neuronales usadas en el análisis de los specklegramas experimentales mostraron que mejoran el rango y la sensibilidad asociadas con el sensor FSS, con respecto a cuando se usan los métodos convencionales en este análisis. Este hecho se hace evidente en los resultados de los métodos convencionales que para tener un desempeño aceptable en predicción se tuvo que reducir drásticamente su rango. En las pruebas hechas, este rango se redujo aproximadamente 12 veces con respecto al rango completo de los datos (25 °C a 200 °C), que, por el contrario, sí fue alcanzado con las arquitecturas propuestas.

La comparación de las arquitecturas propuestas para el análisis de los specklegramas experimentales con respecto a su desempeño en la predicción y su costo computacional mostró que, la arquitectura MNet-reg es superior en desempeño y tiene un bajo requerimiento de recursos computacionales. La MNet-reg es nuestra adaptación para

regresión del modelo MobileNet, que fue creado para ser eficiente en dispositivos móviles. La MNet-reg tuvo un error RMSE de 0.943 °C, un tiempo de inferencia de 0.0556 segundos por cada *batch* de 32 imágenes, en una GPU NVIDIA RTX 3060, y un número total de parámetros de 6378689.

8.2. Recomendaciones y trabajo futuro

Dentro de las hipótesis de mejora y trabajo futuro que creemos vale la pena explorar por su posible aporte significativo, es la manera de preprocesar los specklegramas. Hasta el momento el procedimiento se lleva a cabo entrenando la red para un dataset específico, en el que la red es capaz de aprender algunas características de cada specklegrama según su temperatura y generalizar este aprendizaje para datos nuevos dentro del mismo sistema. Esto es preciso dentro de un sistema controlado, pero en sistemas no controlados, o no encapsulados con posibles perturbaciones adicionales, las predicciones de la red ya no serían tan adecuadas. Esto es debido precisamente a que el patrón de speckle responde a todos estos cambios. Una posible propuesta es preprocesar los specklegramas para entrenar la red para aprender más que cada specklegrama, el *comportamiento* entre ellos. En este caso una opción es entrenar la red no con los specklegramas, sino con la diferencia entre. Es posible que esto sea una solución para entrenar una red para que aprenda el *comportamiento* de un FSS con parámetros específicos.

En el sentido del posible trabajo anterior, también se espera explorar el análisis de specklegramas producidos por diferentes perturbaciones simultáneas y en diferentes posiciones de un FSS extendido.

En trabajos futuros, se espera explorar la mejora de los Transformers de visión con pruebas más exhaustivas para el procesamiento de specklegramas y la predicción de la variable de perturbación. En este sentido, también se plantea explorar otras alternativas como arquitecturas híbridas entre redes convolucionales y Transformers.

Otro aspecto para explorar en trabajos futuros es el uso de redes generativas adversarias (GANs) para la generación de specklegramas sintéticos valiéndose del entrenamiento con conjunto de datos de specklegramas experimentales.

Anexos:

Los siguientes anexos se entregan en archivos independientes en adición a esta tesis:

- Anexo A Artículo Q1 publicado: *Numerical study using finite element method for the thermal response of fiber specklegram sensors with changes in the length of the sensing zone.*
- Anexo B Artículo Homologación B publindex publicado: *Deep learning classification and regression models for temperature values on a simulated fibre specklegram sensor.*
- Anexo C Artículo Q2 en revisión: *Use of a convolutional neural network to predict temperature values in a simulated fiber specklegram sensor and comparison with conventional methods of analysis.*
- Anexo D Artículo Q2 publicado: *Synthetic dataset of speckle images for fiber optic temperature sensor.*
- Anexo E Certificado de ponencia internacional: *Comparison of deep learning architectures in regression and classification models for prediction of temperature values in a simulated fiber specklegram sensor.*
- Anexo F Certificado de ponencia nacional: *Using a Convolutional Neural Network to Predict Temperature Values in a Simulated Fiber Specklegram Sensor and its Comparison with Conventional Interrogation Methods.*
- Anexo G Certificado de ponencia nacional: *Redes neuronales convolucionales en sensores de specklegrama de fibra óptica y su comparación con otros métodos de análisis convencionales.*
- Anexo H Certificado de ponencia internacional: *Detección automática de temperatura a partir de la distribución modal de sensores basados en redes de periodo largo: enfoque basado en el aprendizaje profundo.*
- Anexo I Código de arduino de lectura e interpolación de temperatura y control PID.
- Anexo J Código de Matlab para la automatización de la adquisición de specklegramas con cambios de temperatura.
- Anexo K Código de entrenamiento con transfer learning para la VGG16-reg con el dataset de specklegramas experimentales.

- Anexo L Código de entrenamiento con transfer learning para la MNet-reg con el dataset de specklegramas experimentales.
- Anexo M Código de entrenamiento con transfer learning para la ENet-reg con el dataset de specklegramas experimentales.
- Anexo N Código de entrenamiento con transfer learning para la ANN-reg con el dataset de specklegramas experimentales.
- Anexo Ñ Código de entrenamiento con transfer learning para la ViT-reg con el dataset de specklegramas experimentales.
- Anexo O Código de predicción de las arquitecturas
- Anexo P Enlace de pesos y modelos en archivos *.hdf5*

Bibliografía

- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). *Optuna: A Next-generation Hyperparameter Optimization Framework*. <https://doi.org/10.48550/arXiv.1907.10902>
- Arango, J. D., Aristizabal, V. H., Carrasquilla, J. F., Gomez, J. A., Quijano, J. C., Velez, F. J., & Herrera-Ramirez, J. (2021). Deep learning classification and regression models for temperature values on a simulated fibre specklegram sensor. *Journal of Physics: Conference Series*, 2139(1), 012001. <https://doi.org/10.1088/1742-6596/2139/1/012001>
- Arango, J. D., Aristizabal, V. H., Carrasquilla, J. F., Gomez, J. A., Quijano, J. C., Velez, F. J., & Herrera-Ramirez, J. (2022). *Synthetic dataset of fiber specklegram sensor with changes of temperature*. OSF Registries. <https://doi.org/10.17605/OSF.IO/ZFMP5>
- Arango, J. D., Aristizabal, V., Vélez, F., Carrasquilla, J., Gomez, J., Quijano, J., & Herrera-Ramirez, J. (2023). Synthetic dataset of speckle images for fiber optic temperature sensor. *Data in Brief*, 48, 109134. <https://doi.org/10.1016/j.dib.2023.109134>
- Arango, J. D., Vélez, Y. A., Aristizabal, V. H., Vélez, F. J., Gómez, J. A., Quijano, J. C., & Herrera-Ramirez, J. (2021). Numerical study using finite element method for the thermal response of fiber specklegram sensors with changes in the length of the sensing zone. *Computer Optics*, 45(4), 534–540. <https://doi.org/10.18287/2412-6179-CO-852>
- Aristizabal, V. H., Vélez, F. J., Rueda, E., Gómez, N. D., & Gómez, J. A. (2016). Numerical modeling of fiber specklegram sensors by using finite element method (FEM). *Optics Express*, 24(24), 27225. <https://doi.org/10.1364/oe.24.027225>
- Aristizabal, V. H., Vélez, F. J., & Torres, P. (2006). Analysis of photonic crystal fibers: Scalar solution and polarization correction. *Optics Express*, 14(24). <https://doi.org/10.1364/OE.14.011848>
- Bai, J., Yuan, L., Xia, S.-T., Yan, S., Li, Z., & Liu, W. (2022). *Improving Vision Transformers by Revisiting High-frequency Components*. <http://arxiv.org/abs/2204.00993>
- Bergstra, J., Komer, B., Eliasmith, C., Yamins, D., & Cox, D. D. (2015). Hyperopt: a Python library for model selection and hyperparameter optimization. *Computational Science & Discovery*, 8(1), 014008. <https://doi.org/10.1088/1749-4699/8/1/014008>
- Carleo, G., & Troyer, M. (2017). Solving the quantum many-body problem with artificial neural networks. *Science*, 355(6325), 602–606. <https://doi.org/10.1126/science.aag2302>
- Castaño, L. F., Gutierrez, L. C., Quijano, J. C., Herrera-Ramírez, J. A., Hoyos, A., Vélez, F. J., Aristizabal, V. H., Da Silva-Nunez, L. C., & Gómez, J. A. (2018). Temperature measurement by means of fiber specklegram sensors (FSS). *Optica Pura y Aplicada*, 51(3), 1–7. <https://doi.org/10.7149/OPA.51.3.50306>
- Chen, J., Liu, B., & Zhang, H. (2011). Review of fiber Bragg grating sensor technology. *Frontiers of Optoelectronics in China*, 4(2), 204–212. <https://doi.org/10.1007/s12200-011-0130-4>
- Chollet, F. (2021). Deep Learning with Python, Second Edition. In *Deep Learning with Python*.

<https://www.manning.com/books/deep-learning-with-python-second-edition>

- Cuevas, A. R., Fontana, M., Rodriguez-Cobo, L., Lomer, M., & Lopez-Higuera, J. M. (2018). Machine Learning for Turning Optical Fiber Specklegram Sensor into a Spatially-Resolved Sensing System. Proof of Concept. *Journal of Lightwave Technology*, 36(17), 3733–3738. <https://doi.org/10.1109/JLT.2018.2850801>
- Deng, J., Dong, W., Socher, R., Li, L.-J., Kai Li, & Li Fei-Fei. (2009). ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2020). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. <http://arxiv.org/abs/2010.11929>
- Efendioglu, H. S. (2017). A Review of Fiber-Optic Modal Modulated Sensors: Specklegram and Modal Power Distribution Sensing. *IEEE Sensors Journal*, 17(7), 2055–2064. <https://doi.org/10.1109/JSEN.2017.2658683>
- Efendioglu, H. S., Esen, M. E., Toker, O., & Fidanboylu, K. (2011). Optimal design of MPD based fiber optic strain sensors and comparison of power-meter and CCD camera measurements. *Optical Fiber Technology*, 17(2), 91–97. <https://doi.org/10.1016/j.yofte.2010.10.006>
- Efendioglu, H. S., Yildirim, T., Toker, O., & Fidanboylu, K. (2013). New statistical features for the design of fiber optic statistical mode sensors. *Optical Fiber Technology*, 19(4), 279–284. <https://doi.org/10.1016/j.yofte.2013.02.009>
- Farahi, F. (2015). *Handbook of Optical Sensors* (J. L. Santos & F. Farahi (eds.)). CRC Press, Inc.
- Feng, F., Chen, W., Chen, D., Lin, W., & Chen, S.-C. (2018). In-situ ultrasensitive label-free DNA hybridization detection using optical fiber specklegram. *Sensors and Actuators B: Chemical*, 272, 160–165. <https://doi.org/10.1016/j.snb.2018.05.099>
- Fu, D., Walker, K. A., Sung, K., Boone, C. D., Soucy, M.-A., & Bernath, P. F. (2007). The portable atmospheric research interferometric spectrometer for the infrared, PARIS-IR. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 103(2), 362–370. <https://doi.org/10.1016/J.JQSRT.2006.05.006>
- Fujiwara, E., Da Silva, L. E., Cabral, T. D., De Freitas, H. E., Wu, Y. T., & Cordeiro, C. M. D. B. (2019). Optical fiber specklegram chemical sensor based on a concatenated multimode fiber structure. *Journal of Lightwave Technology*, 37(19), 5041–5047. <https://doi.org/10.1109/JLT.2019.2927332>
- Fujiwara, E., Paula, F. D., Wu, Y. T., Santos, M. F. M., Schenkel, E. A., & Suzuki, C. K. (2017). Optical fiber tactile sensor based on fiber specklegram analysis. In Y. Chung, W. Jin, B. Lee, J. Canning, K. Nakamura, & L. Yuan (Eds.), *25th International Conference on Optical Fiber Sensors* (Vol. 10323, p. 103232N). SPIE. <https://doi.org/10.1117/12.2263454>
- Fujiwara, E., Ri, Y., Wu, Y. T., Fujimoto, H., & Suzuki, C. K. (2018). Evaluation of image matching techniques for optical fiber specklegram sensor analysis. *Applied Optics*, 57(33), 9845.

- <https://doi.org/10.1364/ao.57.009845>
- Fujiwara, E., Silva, L. E. da, Cabral, T. D., Freitas, H. E. de, Wu, Y. T., & Cordeiro, C. M. B. (2019). Optical Fiber Specklegram Chemical Sensor Based on a Concatenated Multimode Fiber Structure. *Journal of Lightwave Technology*, 1. <https://doi.org/10.1109/JLT.2019.2927332>
- Fujiwara, E., Wu, Y. T., Santos, M. F. M., Schenkel, E. A., & Suzuki, C. K. (2017). Optical Fiber Specklegram Sensor for Measurement of Force Myography Signals. *IEEE Sensors Journal*, 17(4), 951–958. <https://doi.org/10.1109/JSEN.2016.2638831>
- Gåsvik, K. J. (2002). *Optical metrology*. J. Wiley & Sons.
- Genty, G., Salmela, L., Dudley, J. M., Brunner, D., Kokhanovskiy, A., Kobtsev, S., & Turitsyn, S. K. (2021). Machine learning and applications in ultrafast photonics. *Nature Photonics*, 15(2), 91–101. <https://doi.org/10.1038/s41566-020-00716-4>
- Geron, A. (2017). Hands-On Machine Learning With Scikit-Learn & Tensor Flow. In *Hands-on Machine Learning with Scikit-Learn and TensorFlow*. O'Reilly Media. <http://arxiv.org/abs/1412.3919>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2013). Rich feature hierarchies for accurate object detection and semantic segmentation. <https://doi.org/10.48550/arXiv.1311.2524>
- Gómez, C., Neira, M., Hernández Hoyos, M., Arbeláez, P., & Forero-Romero, J. E. (2020). Classifying image sequences of astronomical transients with deep neural networks. *Monthly Notices of the Royal Astronomical Society*, 499(3), 3130–3138. <https://doi.org/10.1093/mnras/staa2973>
- Grattan, K. T. V., & Sun, T. (2000). Fiber optic sensor technology: an overview. *Sensors and Actuators A: Physical*, 82(1–3), 40–61. [https://doi.org/10.1016/S0924-4247\(99\)00368-4](https://doi.org/10.1016/S0924-4247(99)00368-4)
- Gresty, J. L. (1979). Optical Shop Testing. *Optica Acta: International Journal of Optics*, 26(7), 836–836. <https://doi.org/10.1080/716099479>
- Gubarev, F., Li, L., Klenovskii, M., & Glotov, A. (2016). Speckle pattern processing by digital image correlation. *MATEC Web of Conferences*, 48, 04003. <https://doi.org/10.1051/mateconf/20164804003>
- Hamory, P. J., Parker, A. R., & Jr. (2016). *Wavelet-based processing for fiber optic sensing systems* (Patent No. US 9.444.548 B1).
- Haus, J. (2010). *Optical Sensors*. Wiley. <https://doi.org/10.1002/9783527629435>
- Herrera-Ramirez, J., Gutierrez, L. C., Castaño, L. F., Gómez, J. A., Quijano, J. C., Da Silva Nunez, L. C., Vélez, F. J., & Aristizabal, V. H. (2018). Modeling Temperature Response of a Fiber Specklegram Sensor by Using Finite Element Method. *Latin America Optics and Photonics Conference*, Tu4A.36. <https://doi.org/10.1364/LAOP.2018.Tu4A.36>
- Hill, K. O., Tremblay, Y., & Kawasaki, B. S. (1980). Modal noise in multimode fiber links: theory and experiment. *Optics Letters*, 5(6), 270. <https://doi.org/10.1364/OL.5.000270>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., &

- Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. <http://arxiv.org/abs/1704.04861>
- Hoyos, A., Gómez, N. D., & Gómez, J. A. (2013). *Fiber specklegram sensors (FSS) for measuring high frequency mechanical perturbations* (M. F. P. C. Martins Costa (ed.); p. 8785BH). <https://doi.org/10.1117/12.2026075>
- Hu, S., Liu, H., Liu, B., Lin, W., Zhang, H., Song, B., & Wu, J. (2022). Self-temperature compensation approach for fiber specklegram magnetic field sensor based on polarization specklegram analysis. *27th International Conference on Optical Fiber Sensors*, F1.5. <https://doi.org/10.1364/OFS.2022.F1.5>
- Iafolla, L., Filipozzi, M., Freund, S., Zam, A., Rauter, G., & Cattin, P. C. (2021). Machine learning-based method for linearization and error compensation of a novel absolute rotary encoder. *Measurement*, 169, 108547. <https://doi.org/10.1016/j.measurement.2020.108547>
- Islam, T., & Mukhopadhyay, S. C. (2019). Linearization of the sensors characteristics: a review. *International Journal on Smart Sensing and Intelligent Systems*, 12(1), 1–21. <https://doi.org/10.21307/ijssis-2019-007>
- Kajenski, P. J., Fuhr, P. L., & Huston, D. R. (1992). Mode Coupling and Phase Modulation in Vibrating Waveguides. In *JOURNAL OF LIGHTWAVE TECHNOLOGY* (Vol. 10, Issue 9).
- Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). *Progressive Growing of GANs for Improved Quality, Stability, and Variation*. <http://arxiv.org/abs/1710.10196>
- Kinet, D., Mégret, P., Goossen, K., Qiu, L., Heider, D., & Caucheteur, C. (2014). Fiber Bragg Grating Sensors toward Structural Health Monitoring in Composite Materials: Challenges and Solutions. *Sensors*, 14(4), 7394–7419. <https://doi.org/10.3390/s140407394>
- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization*. <https://doi.org/https://doi.org/10.48550/arXiv.1412.6980>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Krohn, D. A., MacDougall, T., & Mendez, A. (2015). Fiber optic sensors: Fundamentals and applications: Fourth edition. In *Fiber Optic Sensors: Fundamentals and Applications: Fourth Edition* (4th ed.). SPIE Press. <https://doi.org/10.1117/3.100291>
- Leal-Junior, A. G., Frizzera, A., Marques, C., & Pontes, M. J. (2020). Optical Fiber Specklegram Sensors for Mechanical Measurements: A Review. In *IEEE Sensors Journal* (Vol. 20, Issue 2, pp. 569–576). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/JSEN.2019.2944906>
- Leal-Junior, A. G., Frizzera, A., Vargas-Valencia, L., dos Santos, W. M., Bo, A. P. L., Siqueira, A. A. G., & Pontes, M. J. (2018). Polymer Optical Fiber Sensors in Wearable Devices: Toward Novel Instrumentation Approaches for Gait Assistance Devices. *IEEE Sensors Journal*, 18(17), 7085–7092. <https://doi.org/10.1109/JSEN.2018.2852363>

- Leal-Junior, A. G., Marques, C., Frizera, A., & Pontes, M. J. (2018). Multi-interface level in oil tanks and applications of optical fiber sensors. *Optical Fiber Technology*, 40, 82–92. <https://doi.org/10.1016/j.yofte.2017.11.006>
- Lee, Y., Lee, S., Yoo, J., & Kwon, S. (2021). Efficient Single-Shot Multi-Object Tracking for Vehicles in Traffic Scenarios. *Sensors*, 21(19), 6358. <https://doi.org/10.3390/s21196358>
- Li, G., Liu, Y., Qin, Q., Zou, X., Wang, M., & Ren, W. (2022). Feature Extraction Enabled Deep Learning From Specklegram for Optical Fiber Curvature Sensing. *IEEE Sensors Journal*, 22(16), 15974–15984. <https://doi.org/10.1109/JSEN.2022.3188694>
- Li, Z., Zhang, Y.-X., Zhang, W.-G., Kong, L.-X., Yue, Y., & Yan, T.-Y. (2020). Parallelized fiber Michelson interferometers with advanced curvature sensitivity plus abated temperature crosstalk. *Optics Letters*, 45(18), 4996. <https://doi.org/10.1364/OL.401556>
- Liu, Y., Li, G., Qin, Q., Tan, Z., Wang, M., & Yan, F. (2020). Bending recognition based on the analysis of fiber specklegrams using deep learning. *Optics and Laser Technology*, 131. <https://doi.org/10.1016/j.optlastec.2020.106424>
- Long, J., Shelhamer, E., & Darrell, T. (2014). *Fully Convolutional Networks for Semantic Segmentation*. <http://arxiv.org/abs/1411.4038>
- Ma, W., Cheng, F., Xu, Y., Wen, Q., & Liu, Y. (2019). Probabilistic Representation and Inverse Design of Metamaterials Based on a Deep Generative Model with Semi-Supervised Learning Strategy. *Advanced Materials*, 31(35), 1901111. <https://doi.org/10.1002/adma.201901111>
- Ma, W., Liu, Z., Kudyshev, Z. A., Boltasseva, A., Cai, W., & Liu, Y. (2021). Deep learning for the design of photonic structures. *Nature Photonics*, 15(2), 77–90. <https://doi.org/10.1038/s41566-020-0685-y>
- Matias, I. R. (2017). *Fiber Optic Sensors* (I. R. Matias, S. Ikezawa, & J. Corres (eds.); Vol. 21). Springer International Publishing. <https://doi.org/10.1007/978-3-319-42625-9>
- Metz, L., Harrison, J., Freeman, C. D., Merchant, A., Beyer, L., Bradbury, J., Agrawal, N., Poole, B., Mordatch, I., Roberts, A., & Sohl-Dickstein, J. (2022). *VeLO: Training Versatile Learned Optimizers by Scaling Up*. <http://arxiv.org/abs/2211.09760>
- Mishra, V., Singh, N., Tiwari, U., & Kapur, P. (2011). Fiber grating sensors in medicine: Current and emerging applications. *Sensors and Actuators A: Physical*, 167(2), 279–290. <https://doi.org/10.1016/j.sna.2011.02.045>
- O’Shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks*. <http://arxiv.org/abs/1511.08458>
- Oldfrey, B., Jackson, R., Smitham, P., & Miodownik, M. (2019). A Deep Learning Approach to Non-linearity in Wearable Stretch Sensors. *Frontiers in Robotics and AI*, 6. <https://doi.org/10.3389/frobt.2019.00027>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., Shpanskaya, K., Lungren, M. P., & Ng, A. Y. (2017). *CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning*. <http://arxiv.org/abs/1711.05225>

- Reis, F. M., Da Costa Antunes, P. F., Mendes Maia, N. M., Carvalho, A. R., & De Brito Andre, P. S. (2017). Structural Health Monitoring Suitable for Airborne Components Using the Speckle Pattern in Plastic Optical Fibers. *IEEE Sensors Journal*, 17(15), 4791–4796. <https://doi.org/10.1109/JSEN.2017.2715258>
- Reyes-Gonzalez, L., Rodriguez-Cobo, L., & Lopez-Higuera, J.-M. (2022). Comparison of Ballistocardiogram Processing Methods Based on Fiber Specklegram Sensors. *IEEE Sensors Journal*, 22(21), 20524–20530. <https://doi.org/10.1109/JSEN.2022.3208318>
- Reyes-Vera, E., Cordeiro, C. M. B., & Torres, P. (2017). Highly sensitive temperature sensor using a Sagnac loop interferometer based on a side-hole photonic crystal fiber filled with metal. *Applied Optics*, 56(2), 156. <https://doi.org/10.1364/AO.56.000156>
- Rodriguez-Cobo, L., Lomer, M., & Lopez-Higuera, J.-M. (2015a). Fiber Specklegram-Multiplexed Sensor. *Journal of Lightwave Technology*, 33(12), 2591–2597. <https://doi.org/10.1109/JLT.2014.2364318>
- Rodriguez-Cobo, L., Lomer, M., & Lopez-Higuera, J. M. (2015b). Fiber specklegram sensors sensitivities at high temperatures. *24th International Conference on Optical Fibre Sensors*, 9634, 96347J. <https://doi.org/10.1117/12.2194288>
- Rosenbusch, H., Soldner, F., Evans, A. M., & Zeelenberg, M. (2021). Supervised machine learning methods in psychology: A practical introduction with annotated R code. *Social and Personality Psychology Compass*, 15(2). <https://doi.org/10.1111/spc3.12579>
- Rupp, M., Tkatchenko, A., Müller, K.-R., & von Lilienfeld, O. A. (2012). Fast and Accurate Modeling of Molecular Atomization Energies with Machine Learning. *Physical Review Letters*, 108(5), 058301. <https://doi.org/10.1103/PhysRevLett.108.058301>
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. <http://arxiv.org/abs/1409.1556>
- Spillman, W. B., Kline, B. R., Maurice, L. B., & Fuhr, P. L. (1989). Statistical-mode sensor for fiber optic vibration sensing uses. *Applied Optics*, 28(15), 3166. <https://doi.org/10.1364/AO.28.003166>
- Tan, M., & Le, Q. V. (2021). *EfficientNetV2: Smaller Models and Faster Training*. <http://arxiv.org/abs/2104.00298>
- Tarallo, E., Akabane, G. K., Shimabukuro, C. I., Mello, J., & Amancio, D. (2019). Machine Learning in Predicting Demand for Fast-Moving Consumer Goods: An Exploratory Research. *IFAC-PapersOnLine*, 52(13), 737–742. <https://doi.org/10.1016/j.ifacol.2019.11.203>
- Tian, K., Xin, Y., Yang, W., Geng, T., Ren, J., Fan, Y.-X., Farrell, G., Lewis, E., & Wang, P. (2017). A Curvature Sensor Based on Twisted Single-Mode–Multimode–Single-Mode Hybrid Optical Fiber Structure. *Journal of Lightwave Technology*, 35(9), 1725–1731. <https://doi.org/10.1109/JLT.2017.2650941>
- Torres, P., Aristizábal, V. H., & Andrés, M. V. (2011). Modeling of photonic crystal fibers from the scalar wave equation with a purely transverse linearly polarized vector potential. *Journal of*

- the Optical Society of America B: Optical Physics*, 28(4), 787–791.
<https://doi.org/10.1364/JOSAB.28.000787>
- Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A., & Jégou, H. (2020). *Training data-efficient image transformers & distillation through attention*.
<http://arxiv.org/abs/2012.12877>
- Vangety, N., Dey, K., Ghosh, S. K., & Roy, S. (2022). Analyzing specklegrams of plastic optical fiber using convolutional neural network for weight recognition. *Optical Engineering*, 61(12).
<https://doi.org/10.1117/1.OE.61.12.126112>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need*. <http://arxiv.org/abs/1706.03762>
- Vilarinho, D., Theodosiou, A., Leitão, C., Leal-Junior, A., Domingues, M., Kalli, K., André, P., Antunes, P., & Marques, C. (2017). POFBG-Embedded Cork Insole for Plantar Pressure Monitoring. *Sensors*, 17(12), 2924. <https://doi.org/10.3390/s17122924>
- Wang, S., Shan, C., Jiang, J., Liu, K., Zhang, X., Han, Q., Lei, J., Xiao, H., & Liu, T. (2019). Temperature-insensitive curvature sensor based on anti-resonant reflection guidance and Mach–Zehnder interferometer hybrid mechanism. *Applied Physics Express*, 12(10), 106503.
<https://doi.org/10.7567/1882-0786/ab3e56>
- Webster, J. G., & Eren, H. (2014). *Measurement, Instrumentation, and Sensors Handbook*.
- Wei, Y., Jiang, T., Liu, C., Zhao, X., Li, L., Wang, R., Shi, C., & Liu, C. (2022). Sawtooth Fiber MZ Vector Bending Sensor Available for Multi Parameter Measurement. *Journal of Lightwave Technology*, 40(17), 6037–6044. <https://doi.org/10.1109/JLT.2022.3186345>
- Wu, S., Yin, S., & Yu, F. T. S. (1991). Sensing with fiber specklegrams. *Applied Optics*, 30(31), 4468.
<https://doi.org/10.1364/AO.30.004468>
- Xia, S. L., Wang, J. L., Wang, R. G., & Zhao, L. (2016). A temperature compensation algorithm based on curve fitting and spline interpolation. *Chemical Engineering Transactions*, 51, 1345–1350. <https://doi.org/10.3303/CET1651225>
- Yin, S., Purwosumarto, P., & Yu, F. (1999). Application of fiber specklegram sensor to fine angular alignment. *Optics Communications - OPT COMMUN*, 170, 15–21.
[https://doi.org/10.1016/S0030-4018\(99\)00405-8](https://doi.org/10.1016/S0030-4018(99)00405-8)
- Yu, F. T. S., Yin, S., Zhang, J., & Guo, R. (1994). Application of a fiber-speckle hologram to fiber sensing. *Applied Optics*, 33(22), 5202. <https://doi.org/10.1364/AO.33.005202>
- Zhang, Y., Peng, H., Qian, X., Zhang, Y., An, G., & Zhao, Y. (2017). Recent advancements in optical fiber hydrogen sensors. *Sensors and Actuators B: Chemical*, 244, 393–416.
<https://doi.org/10.1016/j.snb.2017.01.004>
- Zhang, Z., & Ansari, F. (2006). Fiber-optic laser speckle-intensity crack sensor for embedment in concrete. *Sensors and Actuators, A: Physical*, 126(1), 107–111.
<https://doi.org/10.1016/j.sna.2005.10.002>

- Zhao, Yong, Cai, L., & Li, X. (2017). In-fiber modal interferometer for simultaneous measurement of curvature and temperature based on hollow core fiber. *Optics & Laser Technology*, *92*, 138–141. <https://doi.org/10.1016/j.optlastec.2017.01.024>
- Zhao, Yujia, Zhou, A., Guo, H., Zheng, Z., Xu, Y., Zhou, C., & Yuan, L. (2018). An Integrated Fiber Michelson Interferometer Based on Twin-Core and Side-Hole Fibers for Multiparameter Sensing. *Journal of Lightwave Technology*, *36*(4), 993–997. <https://doi.org/10.1109/JLT.2017.2753256>