



UNIVERSIDAD DE GUANAJUATO

---

---

CAMPUS IRAPUATO - SALAMANCA  
DIVISIÓN DE INGENIERÍAS

*“Estudio de técnicas modernas de aprendizaje automático  
para detección de curvatura mediante fibra óptica  
y su aplicación en biomecánica”*

**TESIS**

QUE PARA OBTENER EL GRADO DE:

**MAESTRÍA EN INGENIERÍA ELÉCTRICA**

PRESENTA:

*Ing. Keyla Carolina Ospino Manjarres*

DIRECTORES:

**Dr. Daniel Jáuregui Vázquez**

**M.I Daniel Fernando Zambrano Gutiérrez**

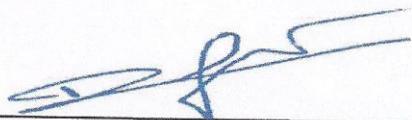
Salamanca Gto., a 17 de noviembre del 2023

**M. en I. HERIBERTO GUTIÉRREZ MARTIN**  
**COORDINADOR DE ASUNTOS ESCOLARES**  
**PRESENTE.-**

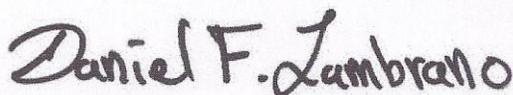
Por medio de la presente, se otorga autorización para proceder a los trámites de impresión, empastado de tesis y titulación al alumno(a) **Keyla Carolina Ospino Manjarres** del Programa de Maestría en **Ingeniería Eléctrica (Instrumentación Y Sistemas Digitales)** y cuyo número de NUA es: **148143** del cual soy director. El título de la tesis es: **"Estudio de técnicas modernas de aprendizaje automático para detección de curvatura mediante fibra óptica y su aplicación en biomecánica"**

Hago constar que he revisado dicho trabajo y he tenido comunicación con los sinodales asignados para la revisión de la tesis, por lo que no hay impedimento alguno para fijar la fecha de examen de titulación.

**ATENTAMENTE**



Dr. Daniel Jáuregui Vázquez  
**DIRECTOR DE TESIS**  
**SECRETARIO**



M.I. Daniel Fernando Zambrano Gutiérrez  
**DIRECTOR DE TESIS**



Dr. Juan Manuel Sierra Hernández  
**PRESIDENTE**



Dr. Juan Carlos Gómez Carranza  
**VOCAL**

---

## Dedicatoria

---

*A mis padres Ramiro y Mer.*

---

## Agradecimientos

---

*A mi familia por su apoyo incondicional y creer en mí.*

*Al Dr. Daniel Jauregui y él M.I Daniel Zambrano por su confianza, apoyo y amistad durante el desarrollo de este trabajo.*

*Al cuerpo académico de Telecomunicaciones y Fotónica, especialmente al Dr. Julián Estudillo y el Dr. Roberto Rojas, por la ayuda que me brindaron.*

*A mis compañeros durante la maestría, quienes fueron mi apoyo y familia.*

---

## Agradecimientos Institucionales

---

*Expreso mi más sincera gratitud hacia la Universidad de Guanajuato, especialmente a la División de Ingenierías del Campus Irapuato-Salamanca (DICIS) por la formación académica y por el apoyo financiero que he recibido durante mis estudios en esta institución.*



*Este trabajo de tesis fue realizado gracias al apoyo invaluable recibido a través del Consejo Nacional de Humanidades Ciencias y Tecnología CONAHCYT de México, bajo el número de becario CVU 1161054.*



---

## Índice General

---

<b>Dedicatoria</b>	<b>ii</b>
<b>Agradecimientos</b>	<b>iii</b>
<b>Agradecimientos institucionales</b>	<b>iv</b>
<b>Índice de Figuras</b>	<b>ix</b>
<b>Índice de Tablas</b>	<b>xiii</b>
<b>Resumen</b>	<b>xv</b>
<b>1 Introducción</b>	<b>1</b>
1.1 Introducción . . . . .	1
1.2 Antecedentes . . . . .	3
1.3 Justificación . . . . .	5

1.4	Objetivos . . . . .	5
1.4.1	Objetivo general . . . . .	5
1.4.2	Objetivos específicos . . . . .	5
1.5	Planteamiento general del problema . . . . .	6
1.6	Organización de la tesis . . . . .	7
	<b>Abstract</b>	<b>1</b>
<b>2</b>	<b>Marco Teórico</b>	<b>8</b>
2.1	Biomecánica de la mano . . . . .	9
2.1.1	Anatomía de la mano . . . . .	9
2.1.2	Cinemática de la mano . . . . .	10
2.1.3	Cinemática en manos robóticas . . . . .	11
2.2	Conceptos ópticos básicos . . . . .	13
2.2.1	Fibras ópticas . . . . .	14
2.2.2	Sensor óptico . . . . .	20
2.2.3	Características estáticas de un sensor . . . . .	21
2.3	Parámetros del sistema . . . . .	21
2.3.1	Curvatura . . . . .	21
2.4	Conceptos básicos del procesamiento de imágenes . . . . .	23
2.4.1	Imagen digital . . . . .	23
2.4.2	Procesamiento de imágenes en color . . . . .	24
2.4.3	Procesamiento de histogramas . . . . .	29

<b>3</b>	<b>Aprendizaje Automático</b>	<b>33</b>
3.1	Modelos de aprendizaje automático . . . . .	34
3.1.1	Análisis discriminante . . . . .	34
3.1.2	Bayesiano ingenuo . . . . .	35
3.1.3	Árboles de decisión . . . . .	36
3.1.4	Máquinas de soporte vectorial . . . . .	37
3.1.5	$K$ Vecinos más próximos . . . . .	38
3.2	Evaluación de los modelos de clasificación . . . . .	39
3.3	Algoritmos de selección de características . . . . .	41
3.3.1	Relieff . . . . .	41
3.3.2	Análisis de Componentes del Vecindario . . . . .	42
3.3.3	Mínima Redundancia Máxima Relevancia . . . . .	43
<b>4</b>	<b>Metodología</b>	<b>45</b>
4.1	Dispositivo óptico . . . . .	46
4.1.1	Configuración experimental . . . . .	46
4.1.2	Principio de operación . . . . .	50
4.2	Aplicación del sistema para monitorizar curvatura . . . . .	55
4.2.1	Adquisición de datos . . . . .	57
4.2.2	Procesamiento de imágenes . . . . .	59
4.2.3	Base de datos . . . . .	64
4.2.4	Visualización de los datos . . . . .	66

4.2.5	Diagrama propuesto de detección de curvatura . . . . .	68
<b>5</b>	<b>Resultados</b>	<b>72</b>
5.1	Análisis de resultados . . . . .	73
5.1.1	Prueba 1 . . . . .	73
5.1.2	Prueba 2 . . . . .	75
5.1.3	Prueba 3 . . . . .	79
<b>6</b>	<b>Conclusiones</b>	<b>91</b>
	<b>Referencias</b>	<b>94</b>

---

## Índice de Figuras

---

2.1	Articulaciones y huesos de la mano [1]. . . . .	9
2.2	Convenciones anatómicas de la mano. Las orientaciones se describen en referencia a los ejes radial-ulnar, dorsal-palmar o proximal-distal [2]. . . . .	10
2.3	Manos robóticas [3] ©. . . . .	12
2.4	Reflexión y refracción de un rayo de luz en la frontera de un material. . . . .	13
2.5	Esquema de una estructura convencional de fibra de sílice. Un núcleo sólido circular de índice de refracción $n_1$ está rodeado por un revestimiento con un índice de refracción $n_2 < n_1$ . Un buffer exterior de plástico elástico encapsula la fibra. . . . .	14
2.6	Estructura de una fibra de perfil de índice escalonado. [4]. . . . .	15
2.7	Comparación de fibras ópticas monomodo y multimodo convencionales de índice escalonado. [5]. . . . .	15
2.8	Pérdidas en una sección de fibra óptica por flexión. . . . .	19
2.9	Clasificación de los sensores de fibra óptica [6]. . . . .	20

2.10	(a) Curvatura de una curva plana en un punto P, (b) Tangentes TP y QT en dos puntos, P y Q, de una curva plana [7]. . . . .	22
2.11	Esquema de medición de curvatura en una sección de fibra óptica. . . . .	22
2.12	Representaciones de una imagen digital como una función bidimensional $f(x, y)$ [8].	24
2.13	Vista del espectro al pasar luz blanca a través de un prisma [8]. . . . .	25
2.14	Absorción de la luz por los conos del ojo humano en función de la longitud de onda (rojos, verdes y azules) [8]. . . . .	25
2.15	Representación del espacio de color RGB [8]. . . . .	26
2.16	Generación de la imagen RGB [8]. . . . .	27
2.17	Representación del espacio de color HSV [8]. . . . .	28
2.18	Representación del espacio de color CIEL*a*b* [9]. . . . .	29
2.19	Histograma de una imagen digital RGB. . . . .	30
2.20	Comparación del histograma de una imagen digital y el resultado al hacer la transformación de ecualización. La imagen de entrada 2.20a proviene de la descomposición en el plano $\mathbf{G}$ , de la imagen RGB en la Figura 2.19a . . . . .	31
2.21	Histograma de una imagen digital obtenido mediante el método CLAHE. La imagen de entrada 2.21a proviene de la descomposición en el plano $\mathbf{G}$ , de la imagen RGB en la Figura 2.19a . . . . .	32
3.1	Estructura básica de un árbol de decisión. . . . .	37
3.2	Ilustración gráfica de la técnica de validación cruzada $k$ -fold. . . . .	40
3.3	Matriz de confusión . . . . .	40
4.1	Montaje experimental del dispositivo de fibra óptica para medir curvatura. . .	48
4.2	Variación de la longitud de onda con respecto a la curvatura. . . . .	49

4.3	Imagen del perfil de salida de la SMF leída por la cámara CCD y sus respectivos histogramas en el espacio de color RGB. . . . .	51
4.4	Estadísticas resultantes de los parámetros RGB para diferentes variaciones de curvatura. . . . .	53
4.5	Rango dinámico de curvatura en el análisis estadístico de la banda G. . . . .	54
4.6	Sistema de adquisición de imágenes para monitorizar el ángulo del dedo índice en un sistema robótico. . . . .	56
4.7	Montaje experimental del sistema robótico de adquisición de imágenes. . . . .	58
4.8	Imagen resultante al aplicar la ventana $a \times b$ con mayor intensidad. . . . .	59
4.9	Esquema del procesamiento de imágenes. . . . .	60
4.10	Proyección t-SNE de los datos en el rango de $0^\circ - 85^\circ$ . . . . .	67
4.11	Proyección t-SNE de los datos en el rango de $20^\circ - 65^\circ$ . . . . .	68
4.12	Diagrama de flujo del desarrollo y aplicación de aprendizaje automático para la detección de curvatura. . . . .	69
5.1	Matriz de confusión del modelo DT. . . . .	74
5.2	Matriz de confusión del modelo DT. . . . .	77
5.3	Gráfico de cajas para cada modelo: Análisis Discriminante (DA), Bayesiano Ingenuo (NB), Árbol de Decisión (DT), Máquinas de Soporte Vectorial (SVM) y K-Vecinos más Próximos (KNN); para un número de repeticiones de 50. . . . .	78
5.4	ReliefF. . . . .	80
5.5	Matriz de confusión del modelo SVM con las características de ReliefF. . . . .	81
5.6	NCA. . . . .	82
5.7	Matriz de confusión del modelo KNN con las características de NCA. . . . .	84
5.8	mRMR. . . . .	85

---

5.9	Matriz de confusión del modelo DT con las características de mRMR. . . . .	87
5.10	Gráfico de cajas para cada modelo: Análisis Discriminante (DA), Bayesiano Ingenuo (NB), Árbol de Decisión (DT), Máquinas de Soporte Vectorial (SVM) y K-Vecinos más Próximos (KNN); para un número de repeticiones de 50. . . .	89

---

## Índice de Tablas

---

4.1	Características del LED MBB1F1 (datos tomados de la hoja de datos del fabricante [10]) . . . . .	47
4.2	Características geométricas y ópticas de la SMF 630HP (datos tomados de la hoja de datos del fabricante [11]) . . . . .	47
4.3	Características del espectrómetro USB2000 (datos tomados de la hoja de datos del fabricante [12]) . . . . .	47
4.4	Características de la cámara CCD (datos tomados de la hoja de datos del fabricante [13]) . . . . .	48
4.5	Total de imágenes capturadas con el primer montaje propuesto. . . . .	52
4.6	Total de imágenes capturadas con el montaje robótico propuesto y las posiciones de curvatura equivalentes. . . . .	57
4.7	Características de color . . . . .	61
4.8	Características en el dominio del tiempo . . . . .	62
4.9	Características en el dominio del tiempo-frecuencia . . . . .	63

4.10	Descripción de las diferentes características extraídas de la banda G . . . . .	64
4.11	Descripción de las diferentes características extraídas de la banda H . . . . .	65
4.12	Descripción de las diferentes características extraídas de la banda a* . . . . .	65
5.1	Comparación del rendimiento de los algoritmos de aprendizaje automático. . .	74
5.2	Comparación del rendimiento de los algoritmos de aprendizaje automático. . .	76
5.3	Valores $K$ para algoritmo ReliefF. . . . .	79
5.4	Comparación del rendimiento de los algoritmos de aprendizaje automático con las características seleccionadas por el algoritmo ReliefF. . . . .	80
5.5	Características seleccionadas por ReliefF usadas en el modelo SVM. . . . .	81
5.6	Valores de umbral $th$ para algoritmo NCA. . . . .	82
5.7	Comparación del rendimiento de los algoritmos de aprendizaje automático con las características seleccionadas por el algoritmo NCA. . . . .	83
5.8	Características seleccionadas por NCA usadas en el modelo KNN. . . . .	84
5.9	Características seleccionadas por mRMR usadas en el modelo DT. . . . .	85
5.10	Comparación del rendimiento de los algoritmos de aprendizaje automático con las características seleccionadas por el algoritmo mRMR. . . . .	86

---

## List of Algoritmos

---

1	Análisis estadístico en las imágenes . . . . .	55
2	Procesamiento de las imágenes. . . . .	63
3	Construcción de la base de datos. . . . .	66

---

## Resumen

---

Este trabajo muestra el estudio, desarrollo e implementación de un sistema óptico que integra algoritmos de aprendizaje automático, para la detección de la posición angular en un brazo robótico. Su aplicación expone de forma sencilla el análisis del movimiento y la evaluación de la postura del dedo índice, con el uso de una fibra óptica monomodo para el rango visible. Este montaje se fundamenta en el procesamiento de imágenes obtenidas a partir del perfil de salida de la fibra cuando se somete a curvatura, lo cual genera pérdidas en la región multimodal de esta y provoca cambios en la intensidad del color verde. Un total de 3240 imágenes son capturas por la cámara CCD, las cuales corresponden al movimiento de curvatura del dedo índice en un rango de  $0^\circ$  -  $85^\circ$ . A partir del procesamiento de imágenes en tres diferentes espacios de color, se realiza la extracción de características estadísticas a cada imagen para crear una base de datos, que combina 180 características de color y del dominio tiempo–frecuencia. Se propone estudiar la base de datos, por medio de técnicas clásicas de clasificación conocidas como, Análisis Discriminante (DA), Bayesiano Ingenuo (NB), Árbol de Decisión (DT), Máquinas de Soporte Vectorial (SVM) y  $K$  Vecinos más Próximos (KNN). Asimismo, se evalúa tres algoritmos de selección de características, los cuales generan un nuevo espacio de datos reducido en el que se descartan los datos irrelevantes y consecuentemente mejora el desempeño de clasificación de los modelos. Se obtiene con el modelo de clasificación de KNN 92.88 % de precisión al detectar la posición angular del dedo índice robótico.

### 1.1. Introducción

El desarrollo de la biomecánica abarca diversas ramas de estudio, desde las ciencias biomédicas, mecánica, ingeniería, anatomía y fisiología. El objetivo es analizar y describir el movimiento del cuerpo humano, por lo que su desarrollo es extremadamente complejo [1, 14]. Comprender y medir la cinemática de la mano es una de las áreas de interés en ámbitos de investigación médica [2, 15]; debido a temas relacionados con la rehabilitación, robótica, predicción de enfermedades y diversos padecimientos [16, 17, 18].

Las aplicaciones con exoesqueleto y sensores de fibra óptica son algunos de los métodos utilizados como asistencia médica y para monitorear el movimiento de la mano. Así pues, el exoesqueleto involucra un sistema exterior de tipo estructura que se usa sobre la extremidad y es útil en rehabilitación para replicar los movimientos naturales, adaptándose a las dimensiones antropométricas de un individuo [19, 20]. Por su parte, los dispositivos ópticos tienen la habilidad de seguir el movimiento de la mano con una tecnología de detección de múltiples ventajas, como una gran precisión de medición y un buen rendimiento en la medición en tiempo real [21].

El monitoreo del movimiento de los dedos de la mano puede resultar complicado usando dispositivos de detección convencional, ya que requiere una gran cantidad de estos y una compleja red de cables externos para decodificar dichos movimientos [22]. Debido a esto, los sensores de fibra óptica poseen un potencial significativo al ser capaces de preservar la biomecánica natural de las estructuras corporales y proporcionar una respuesta rápida. Son inmunes a las interferencias electromagnéticas y no conducen electricidad, son resistentes a altas temperaturas, tienen dimensiones físicas reducidas y son compatibles mecánicamente con una amplia gama de entornos operativos [6, 23]. Se usan ampliamente en aplicaciones que requieren la medición de varios parámetros físicos; como tensión, temperatura y curvatura, entre otros [6, 24, 25].

A pesar de las numerosas ventajas que ofrecen los dispositivos ópticos, su comercialización puede verse limitada por desafíos relacionados con el costo y la falta de practicidad en cuanto a la movilidad de los equipos necesarios. Además, la repetibilidad de un sistema con la misma respuesta de caracterización puede resultar desafiante y el volumen significativo de datos desaprovechados limita la mejora del rendimiento y el alcance de aplicación de dichos dispositivos [26]. En respuesta a estos desafíos, la implementación de algoritmos de aprendizaje automático adaptados a sistemas ópticos ha adquirido relevancia en la actualidad. Estos algoritmos tienen la capacidad de identificar o predecir patrones a partir de datos captados por el sistema óptico, ya sea en forma de señales o imágenes, en respuesta a las variaciones de diversos parámetros físicos. Esta integración estratégica de aprendizaje automático no solo mejora la precisión en la respuesta de un sensor de fibra óptica, sino que también optimiza el rendimiento del sistema, adapta el sensor a condiciones ambientales cambiantes, reduce la pérdida de datos y agiliza el procesamiento de información en tiempo real [26]. En consecuencia, estos avances no solo abordan las limitaciones existentes, sino que también fortalecen la eficacia, eficiencia y adaptabilidad del sistema, contribuyendo a su aceptación y aplicación más amplia en diversas situaciones [27, 28, 29].

El principal objetivo de este trabajo es proporcionar una solución innovadora para la detección del movimiento de flexión que provoca curvatura en una sección del dedo índice. Se sugiere utilizar un sistema de fibra óptica conectado a un brazo robótico para estudiar el movimiento del dedo índice capturando imágenes del perfil de salida de la fibra. A partir del procesamiento de las imágenes se extraen diversas características estadísticas, las cuales son usadas para entrenar algoritmos clásicos de aprendizaje automático, con el fin de identificar patrones en los datos que permitan la detección del grado de curvatura. Para lograr este objetivo se requiere de un método de estudio multidisciplinario, que permita aplicar conocimientos tanto del área de la óptica, procesamiento de imágenes y ciencias de la computación.

## 1.2. Antecedentes

A partir del siglo pasado, se han registrado avances en la investigación y desarrollo de dispositivos que ayudan a los movimientos del cuerpo humano, particularmente los de las manos [30, 31]. Este enfoque enfatiza los sistemas conocidos como exoesqueletos y guantes, ambos con sensores que capturan el movimiento.

En el tema de los exoesqueletos, hay un sistema que se sujeta con piezas inferiores debajo de las articulaciones de la mano y bandas elásticas que fijan la estructura, el cual tiene sensores Hall lineales para medir el movimiento tridimensional de la mano [20]. Otra aplicación registrada consiste en un sensor óptico que se adhiere en una impresión 3D de dos ejes sobre el dedo índice y su funcionamiento se basa en la ley de Malus. Registra con éxito movimientos de flexión/extensión, abducción/aducción y circunducción del dedo índice [32].

Entre las aplicaciones desarrolladas en forma de guante, son conocidas las implementadas con sensores de resistividad eléctrica como el guante llamado GloveMAP [22]. Este permite el seguimiento de deformación de la yema de los dedos, empleando un microcontrolador Arduino que recibe las señales eléctricas e interconecta con el ordenador [22]. Es ideal para aplicaciones portátiles, pero la robustez del montaje es su principal desventaja. Otra característica que no logra enfrentar este tipo de sensores es la inexactitud, seguido de la sensibilidad al ruido electromagnético y temperatura.

Los sensores de fibra óptica se han destacado en diversas aplicaciones de monitorización del movimiento humano y el modelado biomecánico [27]. En la vanguardia de los avances en dispositivos ópticos, estos sensores son ampliamente utilizados para la detección y monitorización multiparamétrica, logrando una alta precisión y resistiendo condiciones ambientales desafiantes [26]. Ahora bien, uno de los parámetros medidos que cuenta con diversos estudios, de los cuales se demuestra buena sensibilidad es la curvatura [33, 34]. La curvatura, desde el ámbito geométrico se define como el grado de desviación continuo de la línea respecto de una recta, o lo que una superficie curva se desvía de un plano [7]. La medición de la curvatura ejerce un papel importante en aplicaciones biomecánicas, robóticas y médicas [33, 35, 36]

Los sensores de fibra óptica con esquemas para macro y micro-curvatura utilizados en aplicaciones biomecánicas, han estado en desarrollo desde la década de 1960 [37]. De aquí, se ha derivado la investigación de las pérdidas por macro-curvatura en una fibra óptica aplicado a monitorizar funciones respiratorias, específicamente a través de una técnica

no invasiva de pletismografía respiratoria por fibra óptica (FORP - *fiber optic respiratory plethysmography*) [38]. Incluso, la creación de guantes para evaluar el movimiento de manos y dedos e interactuar con entornos virtuales [37]; esto bajo el mismo principio de operación. Un ejemplo es el guante desarrollado por Fifth Dimension Technologies (5DT, Irvine, CA), que utiliza fibras ópticas para detectar el movimiento de los dedos [39].

Es importante señalar que el desarrollo de estos sistemas ópticos, tienen un costo de producción elevado a pesar de su exactitud. Otra de las desventajas radica en el área del procesamiento y análisis de los datos generados por los sensores de fibra óptica, ya que dependen de la aplicación o *hardware* específico que los procesan. Esto desencadena una baja velocidad de procesamiento, sensibilidad cruzada de medición y degradación de la relación señal/ruido a lo largo de la longitud de la fibra [26]. Por lo tanto, estos desafíos logran superarse mediante la implementación de diversas técnicas de aprendizaje automático, las cuales optimizan el procesamiento de datos, mejorando la velocidad de respuesta del sensor y la precisión en la detección; además, reducen la sensibilidad cruzada, permitiendo así una mayor eficiencia en la utilización de los sensores de fibra óptica en diversas aplicaciones [26].

En la actualidad hay muy pocos sistemas de fibra óptica que trabajan con algoritmos de aprendizaje automático para detección de movimiento. Uno de ellos usa el algoritmo llamado *árbol de decisión* para reconocer 5 patrones asociados al proceso de masticación de un ternero, obteniendo una precisión de clasificación del 94 %. Los datos se obtienen por medio de sensores de fibra FBG fijados a la mandíbula del animal, midiendo la tensión biomecánica de la mandíbula durante el movimiento [40]. Otro trabajo propone unos pantalones inteligentes con integración de fibra óptica para análisis biomecánico y clasificación de la actividad. Se fijan los sensores a unos pantalones y se realizan 7 ejercicios distintos para la parte inferior del cuerpo. Con una *red neuronal* se clasifican estas actividades utilizando los datos de entrada de los sensores, y se consigue una precisión del 100 % en el reconocimiento de actividades [41].

Por lo tanto, es de suma importancia desarrollar una metodología que integre los algoritmos de aprendizaje automático a los sensores de fibra óptica, para la detección del movimiento de curvatura. De esta forma mejorar no solo el desarrollo de los sensores, sino que se amplía la aplicabilidad en el área de la biomecánica.

### 1.3. Justificación

Hoy en día, la detección y seguimiento de los movimientos del cuerpo humano a pequeña y gran escala mediante sensores [42], pretende ser aplicado en temas médicos, de rehabilitación y robótica. Es por ello que un gran número de investigadores han centrado su atención a la fabricación de dispositivos basados en fibra óptica, debido a la amplia variedad de aplicaciones y las ventajas que tienen ante los sistemas de detección convencionales [43].

Los sensores de fibra óptica permiten la medición, en su mayoría no invasiva, de parámetros como vibración, temperatura, curvatura, entre otros [6, 24, 25]; no se ven afectados por el ruido electromagnético, tienen alta sensibilidad y respuesta rápida. A pesar de sus múltiples ventajas, se está explorando diversos métodos de detección que buscan aprovechar las capacidades de la inteligencia artificial para mejorar la velocidad de respuesta de estos sistemas y ampliar su aplicabilidad [26].

Debido a lo anterior, se aprecia la posibilidad de explorar la capacidad que tienen los algoritmos de aprendizaje automático para mejorar el desempeño de detección en sensores de fibra óptica, con el fin de monitorizar eficientemente los movimientos del cuerpo humano. Más concretamente, determinar la posición angular de la curvatura del dedo índice durante el movimiento de flexión a través de un montaje accesible y de fácil implementación.

### 1.4. Objetivos

#### 1.4.1. Objetivo general

Desarrollar una metodología que emplee algoritmos de aprendizaje automático para detectar curvatura utilizando un sistema de fibra óptica.

#### 1.4.2. Objetivos específicos

1. Realizar una revisión bibliográfica con el fin de explorar la implementación de aprendizaje automático en dispositivos ópticos.
2. Implementación de un sistema de fibra óptica que permita estudiar la posición angular de

la curvatura en diferentes escenarios.

3. Realizar pruebas experimentales que permitan verificar la correcta integración de la fibra óptica y el sistema robótico.
4. Recopilar la suficiente información que permita realizar una base de datos para su posterior estudio.
5. Analizar los resultados obtenidos mediante diversos algoritmos de aprendizaje automático.
6. Verificar y proponer técnicas de mejora utilizando los algoritmos de aprendizaje automático.
7. Determinar la metodología más efectiva para conocer la curvatura por medio del procesamiento de imágenes e inteligencia artificial.

## 1.5. Planteamiento general del problema

Cuando se trata de sistemas ópticos como los sensores de fibra óptica, es fundamental destacar su tamaño compacto y peso ligero y la inmunidad a la interferencia electromagnética [6]. Estos sistemas también ofrecen un amplio ancho de banda de transmisión y una alta sensibilidad, entre otras ventajas. Por estas razones, son capaces de competir exitosamente con dispositivos convencionales basados en tecnologías de medición estándar.

Se han revisado los sensores de fibra óptica que trabajan bajo la modulación de intensidad, ya que estos presentan una alta sensibilidad para detectar macro y micro-curvatura [37]. Además, ofrecen una solución innovadora en el campo de la biomecánica, ya que permiten la monitorización respiratoria y de modelos cinemáticos de forma precisa y eficiente. La principal desventaja de estos sensores radica en su alto costo de implementación y dificultad para lograr una repetibilidad consistente en el sistema.

La metodología planteada en esta investigación, aprovecha los avances en el campo de la inteligencia artificial y el procesamiento de datos, para analizar las señales ópticas capturadas por la fibra e identificar patrones que indiquen la presencia de curvatura. Mediante el entrenamiento de los algoritmos de aprendizaje automático con datos de curvaturas conocidas, el sistema puede adquirir la capacidad de reconocer y clasificar diferentes niveles de curvatura (posición angular). Así, se consigue una detección precisa y eficiente de la curvatura mediante la combinación de tecnología de fibra óptica, procesamiento de imágenes y técnicas de aprendizaje automático; en un sistema de implementación sencilla.

## 1.6. Organización de la tesis

Este trabajo de tesis está organizado en 6 capítulos, los cuales se describen brevemente a continuación:

Capítulo 1: Presenta la introducción y los objetivos de la presente investigación.

Capítulo 2: Describe los conceptos básicos del modelo cinemático de la mano y sus movimientos, los dispositivos ópticos y el procesamiento de imágenes.

Capítulo 3: Describe los conceptos básicos de los algoritmos de aprendizaje automático, algoritmos de selección de características y métodos de validación.

Capítulo 4: Formula la metodología ante el montaje del dispositivo de fibra óptica para detectar curvatura, el procedimiento de la adquisición y construcción de la base de datos y la evaluación de técnicas de aprendizaje automático.

Capítulo 5: Presenta los resultados obtenidos.

Capítulo 6: Exposición de las conclusiones.

## CAPÍTULO 2

---

### Marco Teórico

---

---

<b>2.1</b>	<b>Biomecánica de la mano</b>	<b>9</b>
2.1.1	Anatomía de la mano	9
2.1.2	Cinemática de la mano	10
2.1.3	Cinemática en manos robóticas	11
<b>2.2</b>	<b>Conceptos ópticos básicos</b>	<b>13</b>
2.2.1	Fibras ópticas	14
2.2.2	Sensor óptico	20
2.2.3	Características estáticas de un sensor	21
<b>2.3</b>	<b>Parámetros del sistema</b>	<b>21</b>
2.3.1	Curvatura	21
<b>2.4</b>	<b>Conceptos básicos del procesamiento de imágenes</b>	<b>23</b>
2.4.1	Imagen digital	23
2.4.2	Procesamiento de imágenes en color	24
2.4.3	Procesamiento de histogramas	29

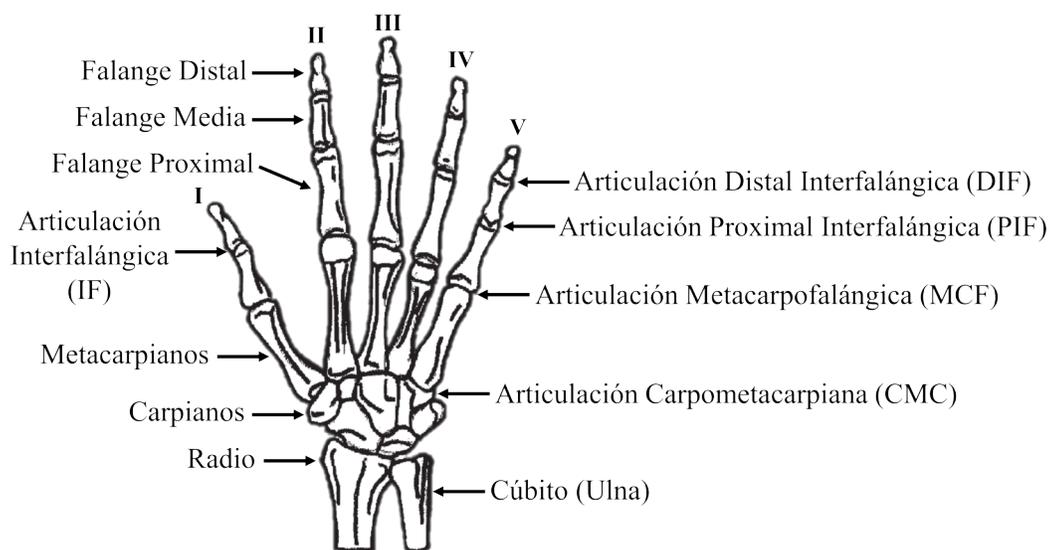
---

En el presente apartado, se lleva a cabo una revisión teórica de los fundamentos básicos en biomecánica de la mano, dispositivos ópticos y procesamiento de imágenes. El objetivo es comprender las articulaciones en los dedos y la posición a la que se va a sujetar el dispositivo óptico de detección. Esto involucra la complejidad de los movimientos y como varía la cinemática entre individuos. Además, el principio de operación del sensor sugerido y los diferentes fenómenos ópticos involucrados. De igual forma, el sistema propuesto involucra el procesamiento de imágenes en diferentes espacios de color y algunas técnicas como el análisis de histogramas.

## 2.1. Biomecánica de la mano

### 2.1.1. Anatomía de la mano

La mano está compuesta por un total de 27 huesos incluidos los de la muñeca: 14 falanges en los dedos, 5 metacarpianos y 8 carpianos [1]. Estos huesos forman los 4 grupos principales de articulaciones de la mano conocidas como: Articulación Distal Interfalángica (DIF), Proximal Interfalángica (PIF), Metacarpofalángica (MCF) y Carpometacarpiana (CMC) [1]. Cada dedo tiene tres falanges: falange distal, media y proximal, mientras que el dedo pulgar solo cuenta con falange distal y proximal.

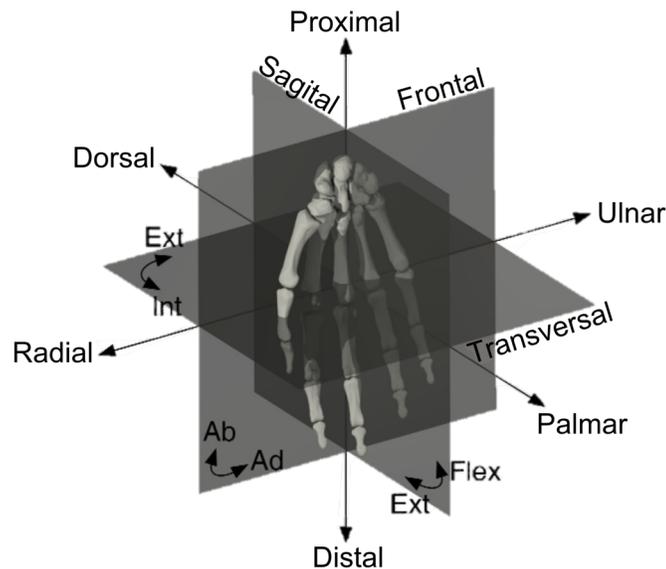


**Figura 2.1.** Articulaciones y huesos de la mano [1].

La longitud de las falanges aumenta a medida que se acercan a los metacarpianos, es decir, la falange distal es más corta que la falange media, y esta última es más corta que la falange proximal, que es la más larga de las tres.

### 2.1.2. Cinemática de la mano

La mano es un órgano altamente móvil, capaz de coordinar una amplia variedad de movimientos relacionados con cada uno de sus componentes. Esta notable movilidad se debe a la estructura de las articulaciones, la disposición de los huesos entre sí y las acciones de un complejo sistema muscular [2].



**Figura 2.2.** Convenciones anatómicas de la mano. Las orientaciones se describen en referencia a los ejes radial-ulnar, dorsal-palmar o proximal-distal [2].

**Definición 2.1.1 (Rango de movimiento digital).** Las distintas formas de las articulaciones CMC, MCF e interfalángicas (IF) del pulgar y los dedos determinan las diferencias en los grados de libertad de estas articulaciones. En los cuatro dedos, las articulaciones MCF posibilitan el movimiento en tres planos: flexión-extensión (plano sagital), abducción-aducción (plano frontal) y una ligera pronación-supinación (plano transversal), que se combina con el movimiento de abducción-aducción [18].

El movimiento de los dedos se mide en términos del grado máximo de flexión hasta el grado máximo de extensión [14].

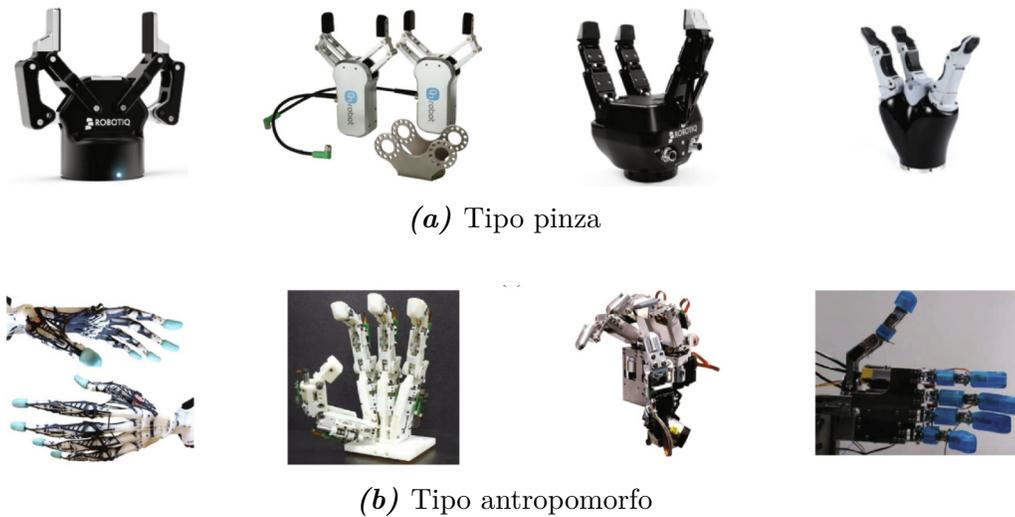
1. Articulación metacarpofalángica (MCF): Las articulaciones MCF tienen dos grados de libertad que permiten movimientos de flexión-extensión y abducción-aducción. El rango de flexión es de aproximadamente  $90^\circ$  a partir de la posición inicial, pero aumenta progresivamente en los demás dedos; el quinto dedo muestra la mayor flexión alcanzando aproximadamente  $95^\circ$ , mientras que el segundo dedo (índice) alcanza aproximadamente  $70^\circ$  [14, 44]. La extensión más allá de la posición inicial también varía considerablemente y depende de la laxitud articular, puede ser de hasta  $[-30/-40]^\circ$ ; mientras que la extensión pasiva puede alcanzar  $-90^\circ$  en algunos individuos [44]. El rango para los movimientos de abducción y aducción del segundo dedo es aproximadamente de  $60^\circ$ ,  $45^\circ$  para el tercer dedo y  $50^\circ$  para el quinto dedo [14]. Las articulaciones MCP también muestran una pequeña rotación axial pasiva.
2. Articulaciones interfalángicas proximales (PIF) y distales (DIF): Las articulaciones PIF y DIF de los cuatro dedos son articulaciones de bisagra, lo que significa que solo permiten el movimiento en un plano (un grado de libertad) y son congruentes en todo el rango de flexión y extensión [1]. La flexión se mide desde la posición inicial, con el dedo en el plano de la mano. La articulación PIF presenta la mayor amplitud de flexión, alcanzando  $110^\circ$  o más, mientras que en la articulación DIP se logra una flexión de aproximadamente  $90^\circ$  [14, 44]. La extensión más allá de la posición inicial, conocida como hiperextensión o extensión pasiva, es una característica común en las articulaciones DIF y PIF, pero su alcance depende en gran medida de la laxitud de los ligamentos; en ocasiones especialmente en la articulación PIF [14]. Estas articulaciones solo presentan ligero movimiento pasivo de lado a lado, especialmente en la articulación DIF.

### 2.1.3. Cinemática en manos robóticas

Una configuración de implementación robótica se define como una cadena cinemática que consiste en una serie de elementos rígidos unidos mediante articulaciones [17]. Estas articulaciones poseen ciertos grados de libertad (DoF) y movimientos permitidos correspondientes a las articulaciones anatómicas del ser humano. Se integra la cinemática directa e inversa en los modelos para lograr replicar los movimientos del cuerpo humano y, al mismo tiempo, evaluar las fuerzas que actúan en las articulaciones.

Las manos robóticas tienen 2 tipos de diseños: el tipo pinza [45] y el tipo antropomorfo (varios dedos) [46]. La forma más básica de configuración es el tipo pinza, que es ampliamente utilizado en el campo industrial (Figura 2.3a); sin embargo, solo puede realizar tareas

básicas, como recoger un objeto, y tiene limitaciones cuando es necesario realizar tareas que requieren una operación precisa [3]. El tipo antropomorfo imita la mano humana, ya que tiene la apariencia de una configuración de varios dedos (Figura 2.3b). Como resultado, es más apto para aplicaciones más amplias que el tipo simple con pinza [3]. Sin embargo, es necesario garantizar una gran cantidad de DoF para este diseño, lo que requiere una cantidad correspondiente de actuadores, mecanismos complejos y algoritmos de control.



**Figura 2.3.** Manos robóticas [3] ©.

Los modelos cinemáticos que se fundamentan en la biomecánica de la mano son provechosos en áreas como la cirugía, la rehabilitación y la ergonomía de la mano. Asimismo, resultan aplicables para evaluar los desafíos ergonómicos de dispositivos existentes o para el diseño de productos futuros [2]. Por ejemplo, un modelo cinemático de fuerza de los dedos podría emplearse para analizar los movimientos de estos. De igual manera, un prototipo de mano antropomorfo puede emplearse para anticipar y visualizar los potenciales agarres asociados con una aplicación innovadora, reduciendo así la necesidad de numerosas pruebas de usuario en las primeras etapas del diseño [47]. Tal es el caso de la prótesis robótica con sensación háptica, capaz de realizar una manipulación diestra y de imitar las funciones de una mano real [48].

La detección informática o robótica de los movimientos de la mano despliega un extenso espectro de oportunidades para las aplicaciones de Interacción Persona-Computadora (IPC/HCI) e Interacción Persona-Robot (IPR/HRI) y posibilita el progreso venidero de entornos virtuales avanzados o sistemas de realidad aumentada [2].

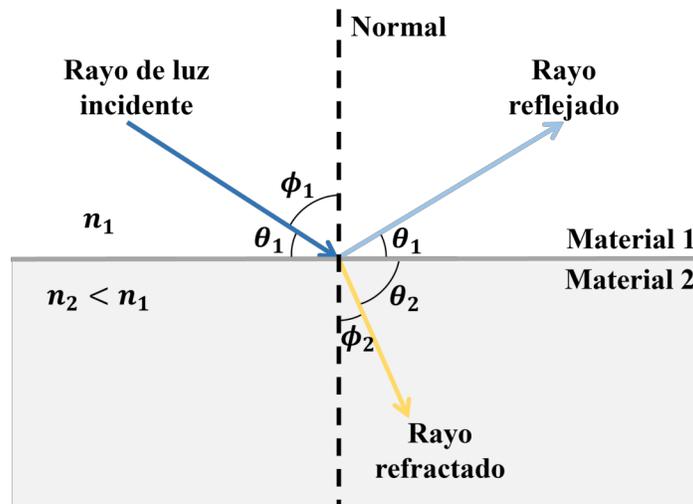
## 2.2. Conceptos ópticos básicos

En esta sección, se aborda diversas definiciones básicas y algunas de las leyes de la óptica que son relevantes para la tecnología de transmisión por fibra óptica.

**Definición 2.2.1 (Índice de refracción).** La velocidad con la que viaja la luz ( $c$ ), está relacionada con la frecuencia  $\nu$  y la longitud de onda  $\lambda$ , tal que  $c = \nu\lambda$  [5]. La velocidad a la que viaja una onda luminosa en un espacio libre es de  $c = 3 \times 10^8 \text{ m/s}$ . Cuando esta entra en un medio no conductor (dieléctrico), la velocidad con la que viaja ( $s$ ) es menor que  $c$ ; debido a las características del material [5]. A la relación entre la velocidad de la luz en el vacío y en la materia, se le conoce como índice de refracción ( $n$ ) del material y viene dada por:

$$n = \frac{c}{s} \quad (2.1)$$

**Definición 2.2.2 (Reflexión y Refracción).** Cuando un rayo de luz incidente encuentra una interfaz que separa dos medios distintos, una parte del rayo se refleja en el primer medio, mientras que el resto se dobla (refracta) al entrar en el segundo material [5].



*Figura 2.4.* Reflexión y refracción de un rayo de luz en la frontera de un material.

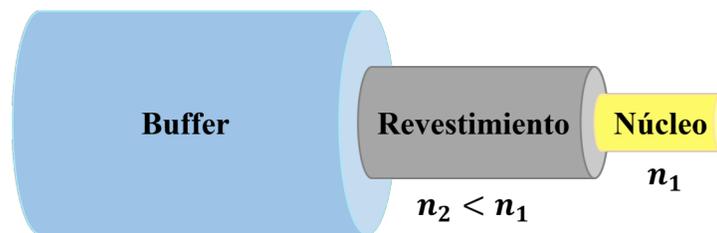
La luz se refracta como resultado de que ambos medios tienen índices de refracción diferentes, lo que provoca que cambie la velocidad con la que viaja la luz. En vista de este efecto, la ley de Snell es utilizada para calcular el ángulo de refracción de la luz al atravesar la superficie de separación entre dos medios de propagación con índice de refracción distinto [49].

$$\begin{aligned} n_1 \cos \theta_1 &= n_2 \cos \theta_2 \\ n_1 \sin \phi_1 &= n_2 \sin \phi_2 \end{aligned} \tag{2.2}$$

Cuando la luz que viaja en un determinado medio se refleja en la superficie de un material con un índice de refracción más alto, el proceso se denomina *reflexión externa*; por el contrario, la reflexión de la luz en un material con un índice de refracción menor, se denomina *reflexión interna* [49].

### 2.2.1. Fibras ópticas

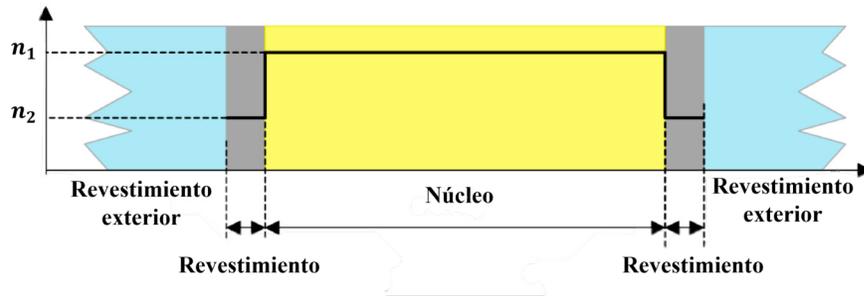
Una fibra óptica es una guía de ondas dieléctrica utilizada para transmitir frecuencias ópticas [5]. Su tamaño es tan fino como hebras, de material de vidrio o plástico, lo suficientemente flexibles como para enrollarse alrededor de un dedo. Por lo general tiene una forma cilíndrica que confina la energía electromagnética en forma de luz dentro de sus superficies, guiando la luz en una dirección paralela a su eje [5]. La estructura define la capacidad de transmisión de información de la fibra y también influye en cómo la guía de ondas responde a las perturbaciones ambientales [5].



**Figura 2.5.** Esquema de una estructura convencional de fibra de sílice. Un núcleo sólido circular de índice de refracción  $n_1$  está rodeado por un revestimiento con un índice de refracción  $n_2 < n_1$ . Un buffer exterior de plástico elástico encapsula la fibra.

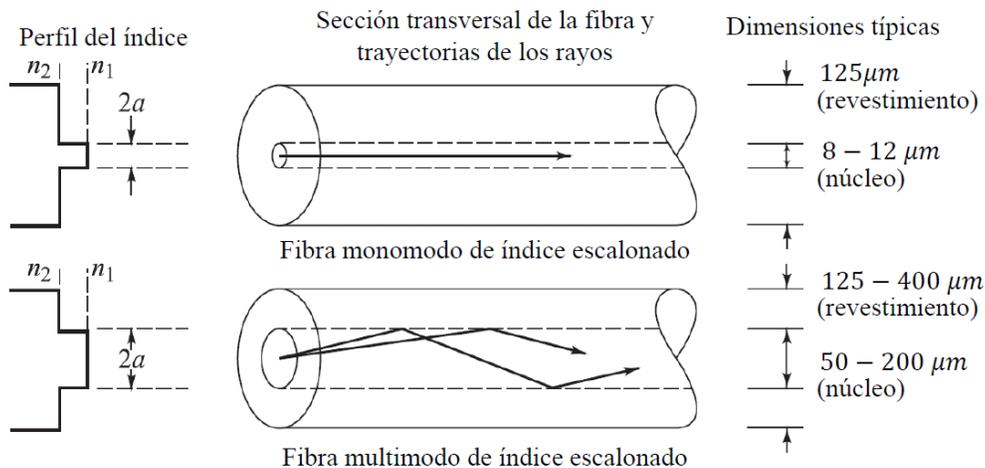
Cada fibra consta de un núcleo el cual es la parte central y un revestimiento dieléctrico sólido lo rodea. El revestimiento en la fibra óptica actúa como un elemento protector y funcional al reducir la pérdida por dispersión ocasionada por las discontinuidades dieléctricas en la superficie del núcleo [5]. Además, confiere una mayor resistencia mecánica a la fibra y previene la absorción de contaminantes superficiales que puedan afectar el rendimiento del núcleo en caso de entrar en contacto con ellos [5].

**Definición 2.2.3 (Fibra óptica de índice escalonado).** Es un tipo de fibra óptica en la que el núcleo tiene un índice de refracción constante en toda su sección transversal. El núcleo está rodeado por un revestimiento, que tiene un índice de refracción más bajo. La diferencia de índice de refracción entre el núcleo y el revestimiento crea una interfaz abrupta, que da lugar a una guía de ondas que permite la propagación de la luz a lo largo de la fibra mediante *reflexión interna total* [49]. La Figura 2.6 representa la curva del índice de refracción.



**Figura 2.6.** Estructura de una fibra de perfil de índice escalonado. [4].

Cuando el grosor del núcleo de la fibra óptica es reducido (normalmente de unos pocos micrómetros de diámetro), únicamente admite un único modo y se conoce como fibra monomodo (SMF, *single-mode fiber*). Este tamaño del núcleo limita el número de modos que pueden propagarse en la fibra, lo que permite un mayor ancho de banda y distancias de transmisión más largas [6]. Por el contrario, mientras que el núcleo de la fibra tenga un diámetro grande (aproximadamente mayor a  $50\mu\text{m}$ ) son denominadas fibras multimodo (MMF, *multimode fiber*).



**Figura 2.7.** Comparación de fibras ópticas monomodo y multimodo convencionales de índice escalonado. [5].

En la Figura 2.7 se presenta las dimensiones características de fibras monomodo y multimodo, lo cual proporciona una referencia sobre la escala dimensional asociada a estos y ejemplifica como se propaga la luz a lo largo de la fibra. En este caso,  $a$  representa el diámetro del núcleo y  $n_1$  su índice de refracción,  $n_2$  es el índice de refracción del revestimiento.

**Definición 2.2.4 (Modos en una fibra óptica de índice escalonado).** La propagación de la luz a lo largo de una fibra óptica se puede describir en términos de un conjunto de ondas electromagnéticas guiadas llamadas modos. Un modo de propagación óptica se define como una solución específica de la ecuación de onda, la cual satisface las condiciones de contorno en la superficie de la guía de onda y exhibe la propiedad de ser espacialmente constante durante su propagación [49]. Cada modo guiado es un patrón de distribuciones de campo eléctrico y magnético que se repite a lo largo de la fibra a intervalos iguales [5]. Solo un cierto número discreto de modos son capaces de propagarse a lo largo de la guía.

Como con cualquier fenómeno electromagnético, la propagación de los campos ópticos en fibras se encuentra gobernada por las ecuaciones de Maxwell. Por lo tanto, en un medio no conductor sin cargas libres, estas ecuaciones adoptan la forma [49]:

$$\begin{aligned}\nabla \times \mathbf{E} &= -\frac{\partial \mathbf{B}}{\partial t}, \\ \nabla \times \mathbf{H} &= \frac{\partial \mathbf{D}}{\partial t}, \\ \nabla \cdot \mathbf{D} &= 0, \\ \nabla \cdot \mathbf{B} &= 0,\end{aligned}\tag{2.3}$$

donde  $\mathbf{E}$  y  $\mathbf{H}$  son los vectores de campo eléctrico y magnético respectivamente, mientras que  $\mathbf{D}$  y  $\mathbf{B}$  son las densidades de flujo correspondientes. Las densidades de flujo se relacionan con los vectores de campo tal como se muestra en las ecuaciones 2.4, en las que  $\varepsilon_0$  es la permitividad del vacío y  $\mu_0$  corresponde a la permeabilidad del vacío [49].

$$\mathbf{D} = \varepsilon_0 \mathbf{E} \quad \text{y} \quad \mathbf{B} = \mu_0 \mathbf{H}\tag{2.4}$$

Las ecuaciones 2.3 y 2.4 proporcionan un formalismo general para estudiar la propagación de ondas en fibras ópticas. En la práctica, es conveniente utilizar una sola

variable de campo ( $\mathbf{E}$ ) [49]. Por ende, para que el vector de campo eléctrico cumpla las ecuaciones de Maxwell, un requisito previo es que sus componentes satisfagan la ecuación de onda (ecuación 2.5); donde  $c$  es la velocidad con la que viaja la luz en el vacío.

$$\nabla^2 \mathbf{E}(r, t) - \frac{1}{c^2} \frac{\partial^2 \mathbf{E}(r, t)}{\partial t^2} = 0 \quad (2.5)$$

Cuando se aplica la transformada de Fourier a la ecuación de onda, esta puede expresarse en términos del número de onda del espacio libre ( $k_0$ ) tal que:

$$\nabla^2 \mathbf{E}(\omega, t) + k_0^2 n^2 \mathbf{E}(\omega, t) = 0, \quad (2.6)$$

donde  $k_0 = \frac{\omega}{c} = \frac{2\pi}{\lambda}$ ,  $\lambda$  es la longitud de onda en el vacío del campo óptico que oscila a la frecuencia  $\omega$ . Al resolver ecuación 2.6 se obtienen los modos ópticos de las fibras de índice escalonado [49]. Por consiguiente, al hacer uso de la simetría cilíndrica, la ecuación 2.6 se formula en términos de coordenadas cilíndricas ( $\rho$ ,  $\phi$  y  $z$ ) y se procede a encontrar su solución (ecuación 2.9).

$$\frac{\partial^2 E_z}{\partial \rho^2} + \frac{1}{\rho} \frac{\partial E_z}{\partial \rho} + \frac{1}{\rho^2} \frac{\partial^2 E_z}{\partial \phi^2} + \frac{\partial^2 E_z}{\partial z^2} + k_0^2 n^2 E_z = 0, \quad (2.7)$$

donde para una fibra de índice escalonado con núcleo de radio  $a$ , el índice de refracción  $n$  tiene la forma:

$$n = \begin{cases} n_1 & \rho \leq a \\ n_2 & \rho > a \end{cases}, \quad (2.8)$$

$$E_z(\rho, \phi, z) = F(\rho)\Phi(\phi)Z(z) \quad (2.9)$$

Utilizando las ecuaciones 2.7 y 2.8, se obtienen tres ecuaciones diferenciales ordinarias:

$$\frac{\partial^2 Z}{\partial z^2} + \beta^2 Z = 0, \quad (2.10)$$

$$\frac{\partial^2 \Phi}{\partial \phi^2} + m^2 \Phi = 0, \quad (2.11)$$

$$\frac{\partial^2 F}{\partial \rho^2} + \frac{1}{\rho} \frac{\partial F}{\partial \rho} + (k_0^2 n^2 - \beta^2 - \frac{m^2}{\rho^2}) F = 0 \quad (2.12)$$

Para la ecuación 2.10 se tiene una solución  $Z = e^{i\beta z}$  en la que  $\beta$  tiene el significado físico de la constante de propagación. Del mismo modo, la solución para la ecuación 2.11 es  $\Phi = e^{im\phi}$

donde la constante  $m$  está limitada a tomar solo valores enteros, ya que el campo debe ser periódico en  $\phi$  con un periodo de  $2\pi$  [49]. Ahora bien, Las funciones de Bessel satisfacen la ecuación 2.12. En este caso, la solución general de las regiones del núcleo y el revestimiento puede escribirse como:

$$E_z = \begin{cases} AJ_m(p\rho) + A'Y_m(p\rho) & \rho \leq a \\ CK_m(q\rho) + C'I_m(q\rho) & \rho > a, \end{cases} \quad (2.13)$$

donde  $A$ ,  $A'$ ,  $C$  y  $C'$  son constantes y  $J_m$ ,  $Y_m$ ,  $K_m$  e  $I_m$  son diferentes tipos de funciones de Bessel. Posteriormente, observando el comportamiento de la intensidad del campo electromagnético dentro de la fibra, la solución general de la ecuación 2.9 viene dada por:

$$E_z = \begin{cases} AJ_m(p\rho)e^{im\phi}e^{i\beta z} & \rho \leq a \\ CK_m(q\rho)e^{im\phi}e^{i\beta z} & \rho > a \end{cases} \quad (2.14)$$

Se puede emplear el mismo procedimiento para obtener la solución general de  $H_z$  y, los otros cuatro componentes se pueden expresar en términos de  $E_z$  y  $H_z$  mediante la utilización de las ecuaciones de Maxwell.

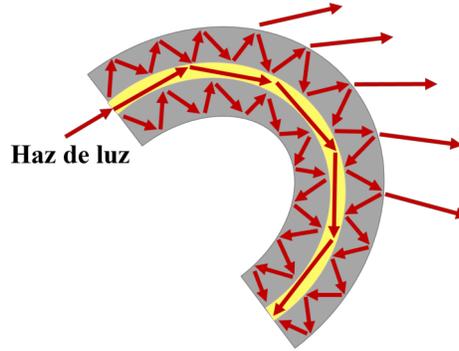
Adicionalmente, un parámetro que desempeña un papel importante en la determinación de la condición de corte (*cutoff*) se conoce como frecuencia normalizada o solo parámetro  $V$ . Una fibra de índice escalonado con un valor grande de  $V$  admite muchos modos; sin embargo, el número de modos disminuye rápidamente a medida que se reduce su valor. La condición para el guiado monomodal se define como:

$$V = \frac{2\pi a n}{\lambda} \sqrt{2\Delta} \quad \rightarrow \quad \Delta = \frac{n_1^2 - n_2^2}{2n_1^2}, \quad (2.15)$$

el cual involucra el radio del núcleo de la fibra ( $a$ ) y la longitud de onda del haz de luz ( $\lambda$ ). La condición de corte que permite la propagación de un modo por la fibra, debe ser tal que  $V < 2.405$  [6]. De esta forma, todos los modos alcanzan la condición de corte, excepto el modo fundamental [49].

**Definición 2.2.5 (Pérdidas en la fibra óptica inducidas por flexión).** La curvatura de la fibra óptica provoca una alteración en los modos de propagación, causando un desplazamiento desde el núcleo hacia el revestimiento, alejándose del centro de curvatura [6]. Esto afecta la distribución de la luz acoplada en el revestimiento, la cual cambia proporcionalmente al variar el radio de curvatura de la fibra. Como resultado, el haz de luz que llega al detector experimenta una modulación en su amplitud, reflejando así la magnitud del movimiento de

curvatura presente en la fibra. La Figura 2.8 ilustra cómo un haz de luz que se propaga por la fibra supera el ángulo crítico y se refleja de forma incompleta en una superficie, lo que provoca pérdidas en la región de revestimiento.



**Figura 2.8.** Pérdidas en una sección de fibra óptica por flexión.

La alteración en los modos que se propagan en la fibra mientras se somete a curvatura depende de la constante de propagación ( $\beta_z$ ); por consiguiente, dependen de la longitud de onda ( $\lambda$ ).

$$\beta_z = \frac{2\pi}{\lambda} \quad (2.16)$$

Las pérdidas por curvatura en las guías de ondas ópticas se pueden predecir de varias maneras teóricas. Para radios de curvatura suficientemente grandes, se utiliza normalmente una fórmula simplificada propuesta por Marcuse [50], aplicable a la mayoría de las fibras ópticas [51]. Al aumentar la curvatura en una sección de fibra óptica, se altera la polarización y esto produce que la distribución del índice de refracción cambie. Este cambio sigue la siguiente relación:

$$n(x, y) = n \left[ 1 - \frac{n^2 x}{2R} [P_{12} - \nu (P_{11} + P_{12})] \right], \quad (2.17)$$

donde  $n(x, y)$  es el índice de refracción de la fibra recta,  $\nu$  es el coeficiente de Poisson,  $P_{11}$  y  $P_{12}$  son componentes del tensor fotoelástico. Además,  $R$  es el radio de curvatura de la sección de fibra óptica [51]. Si  $R$  es cercano a cero, el índice de refracción se mantiene constante; si  $R$  va aumentando gradualmente, el índice de refracción suele disminuir hacia el exterior de la curvatura.

El radio de curvatura que afecta la propagación de los modos en la fibra y que tiene en cuenta los efectos dominantes de la tensión, se puede definir como un radio efectivo ( $R_{\text{eff}}$ ); tal que,

$$R_{\text{eff}} \equiv \frac{R}{1 - \frac{n^2}{2} [P_{12} - \nu (P_{11} + P_{12})]} \quad (2.18)$$

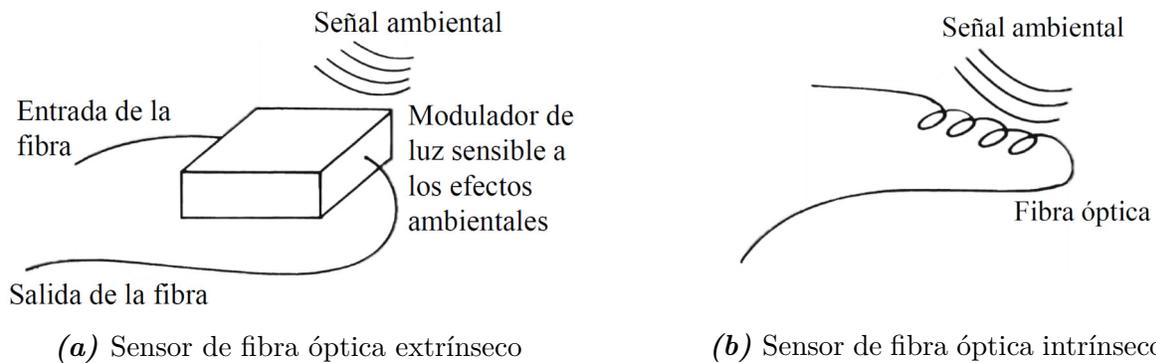
La fórmula simplificada y modificada, que incluye la tensión de la fibra utilizando el radio de curvatura efectivo  $R_{\text{eff}}$ , viene dada por:

$$2\alpha = \frac{\pi^{1/2} \kappa^2 \exp\left(-\frac{2\gamma^3 R_{\text{eff}}}{3\beta_z^2}\right)}{2R_{\text{eff}}^{1/2} \gamma^{3/2} V^2 K_{m-1}(\gamma a) K_{m+1}(\gamma a)}, \quad (2.19)$$

donde  $2\alpha$  es el coeficiente de pérdida de potencia,  $\kappa$  y  $\gamma$  son las tasas de decaimiento del campo en el núcleo y el revestimiento, el radio del núcleo de la fibra es  $a$  y  $\beta_z$  es la constante de propagación de los modos. Además, los términos  $K$  son funciones Bessel modificadas, y  $m$  es el número de modo azimutal correspondiente al subíndice en  $LP_{mn}$  (modos de menor orden en la fibra). Esta fórmula solo es aplicable a los modos  $LP$  pares [51]. La pérdida por curvatura en unidades  $[dB/\text{longitud}]$  se obtiene multiplicando  $2\alpha$  por el factor 4,343.

### 2.2.2. Sensor óptico

Los sensores de fibra óptica son dispositivos sensibles que se pueden utilizar para medir una amplia variedad de propiedades físicas, como cambios químicos, deformación, campos eléctricos y magnéticos, temperatura, presión, rotación, desplazamiento (posición), radiación, flujo, nivel de líquidos, vibraciones, intensidad luminosa y color [52]. Estos sensores son capaces de operar en entornos difíciles, donde los sensores eléctricos y electrónicos convencionales pueden fallar. En términos generales, los sensores de fibra óptica pueden ser clasificados de manera conveniente según la forma en que se utiliza la fibra óptica. Estos sensores pueden agruparse funcionalmente en sensores intrínsecos y extrínsecos [6].



**Figura 2.9.** Clasificación de los sensores de fibra óptica [6].

Los sensores intrínsecos funcionan mediante modulación directa de la luz guiada en la

fibra óptica, la luz no sale de la fibra excepto en el extremo de detección. En este tipo de sensor, las perturbaciones físicas modifican las características de la fibra óptica y por ende, las propiedades de la luz transportada [6]. Un sensor de fibra óptica extrínseco guía la luz hacia/desde un lugar en el que se encuentra el cabezal del sensor óptico. El cabezal del sensor es externo y modula las propiedades de la luz en respuesta a cambios ambientales asociados a perturbaciones físicas de interés. Otra configuración implica que la luz modulada se acopla de nuevo por reflexión o dispersión y luego es guiada de vuelta al sistema de detección [6].

### 2.2.3. Características estáticas de un sensor

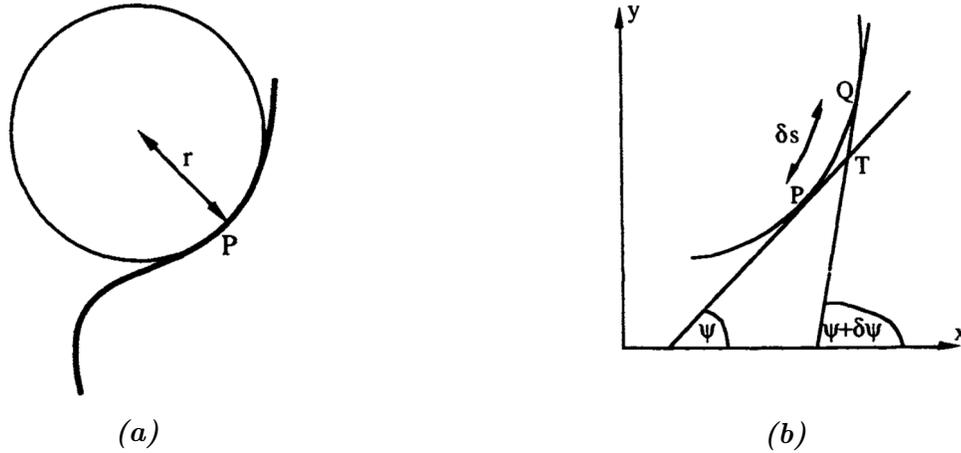
**Definición 2.2.6 (Sensibilidad).** La sensibilidad de un sensor es una medida de su capacidad para detectar cambios en una señal física. Se define como la relación entre la señal física de entrada y la señal eléctrica de salida. Cuanto mayor sea la sensibilidad de un sensor, más pequeño será el cambio en la señal física que puede detectar [53]. Las fibras ópticas tienen una alta sensibilidad a los efectos lineales y no lineales. Esto las hace ideales para la detección distribuida, que es el proceso de medir una señal física a lo largo de una fibra óptica [53]. Para lograr un rendimiento óptimo en un entorno de medición específico, es necesario realizar una cuidadosa adaptación del sistema al entorno y un diseño detallado del mismo.

## 2.3. Parámetros del sistema

### 2.3.1. Curvatura

El concepto de curvatura fue propuesto por Isaac Newton en el siglo XVII, como una extensión natural de sus estudios en cálculo matemático. Newton llegó a la idea de que el radio del círculo que mejor se ajustaba a una curva plana arbitraria en todos sus puntos sería una medida útil para describir dicha curva, y acuñó el término “crookedness” para referirse a este concepto [7].

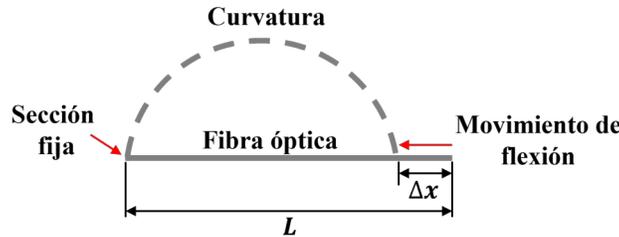
La curvatura de una curva plana es una medida que relaciona la longitud del arco a lo largo de la curva con los cambios del vector tangente en esa curva [7]. Las tangentes TP y QT en la Figura 2.10b subtienden ángulos  $\psi$ ,  $\psi + \delta\psi$  con el eje  $x$ , de modo que  $\delta\psi$  es el ángulo entre las dos tangentes. Si  $\delta_s$  es la longitud del arco PQ a lo largo de la curva, entonces  $\frac{\delta\psi}{\delta_s}$  es



**Figura 2.10.** (a) Curvatura de una curva plana en un punto P, (b) Tangentes TP y QT en dos puntos, P y Q, de una curva plana [7].

la curvatura media de la curva plana a lo largo del arco PQ. La curvatura en el punto P se define por ser el límite de esta expresión a medida que Q se aproxima a P,  $\frac{\delta\psi}{\delta s}$ .

**Definición 2.3.1 (Curvatura en fibra óptica).** Mediante la aplicación de un movimiento de flexión en una sección de fibra óptica, se origina una curvatura que se extiende desde el extremo de la fibra que se mueve o traslada, hacia el lado que permanece inmóvil, como se ilustra en la Figura 2.11.



**Figura 2.11.** Esquema de medición de curvatura en una sección de fibra óptica.

Por consiguiente, la curvatura de la fibra puede expresarse aproximadamente mediante la ecuación 2.20 [54], en la que  $L$  es la distancia entre los extremos de la sección de fibra y  $\Delta x$  es la distancia del movimiento del extremo móvil de la fibra.

$$C = \sqrt{\frac{24\Delta x}{L^3}} \tag{2.20}$$

## 2.4. Conceptos básicos del procesamiento de imágenes

Dos grandes áreas de aplicación han despertado el interés por las técnicas de tratamiento digital de imágenes: la mejora de la información gráfica para la interpretación humana y el tratamiento de datos de imágenes implementado en aprendizaje de máquina [8].

### 2.4.1. Imagen digital

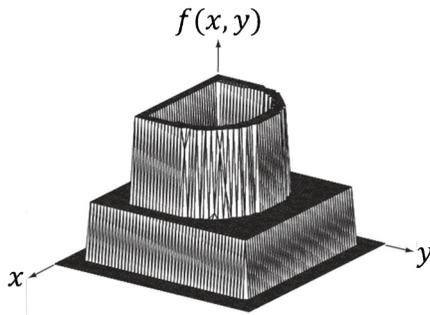
Puede definirse como una función bidimensional  $f(x, y)$ , en la que  $x$ - $y$  son coordenadas espaciales (planas), y el valor de  $f$  en cualquier par de coordenadas  $(x, y)$  se denomina intensidad o nivel de gris de la imagen en ese punto [8]. Las coordenadas  $(x, y)$  y los valores de intensidad de  $f$  son todas cantidades discretas.

La Figura 2.12 muestra las 3 formas básicas de representar la función  $f(x, y)$ ; por consiguiente, la Figura 2.12a representa el gráfico de la función con los ejes que indican la localización espacial y los valores de intensidad [8]. La Figura 2.12b representa como se visualiza en un monitor o fotografía la función  $f(x, y)$  y en la Figura 2.12c simplemente se muestran los valores numéricos de  $f(x, y)$  como una matriz, los cuales van de 1 a 256 cada uno y los valores de nivel de brillo van de 0 a 255 que es de negro a blanco. Por ende, esto es muy beneficioso para el desarrollo de algoritmos porque la imagen se analiza como valores numéricos [8].

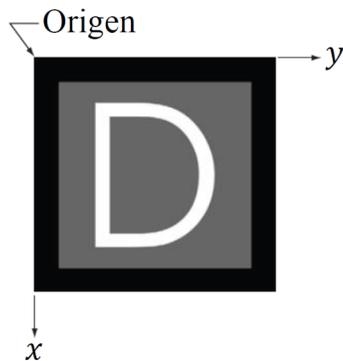
En forma de ecuación, la representación de una matriz numérica de  $f(x, y)$  tiene la forma  $M \times N$ , tal que,

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \cdots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & \cdots & f(1, N - 1) \\ \vdots & \vdots & & \vdots \\ f(M - 1, 0) & f(M - 1, 1) & \cdots & f(M - 1, N - 1) \end{bmatrix}, \quad (2.21)$$

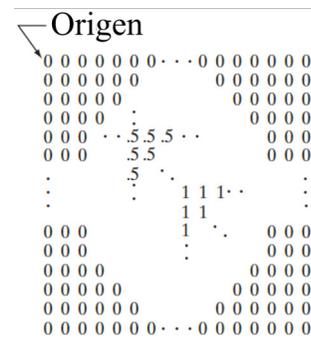
ambos lados de esta ecuación son equivalentes para expresar cuantitativamente una imagen digital [8]. El lado derecho es una matriz de números reales y cada elemento de esta matriz se denomina *píxel* o elementos de imagen (nivel de brillo asociado).



(a) Imagen representada como una superficie



(b) Imagen representada como una matriz de intensidad visual



(c) Imagen representada como una matriz numérica bidimensional

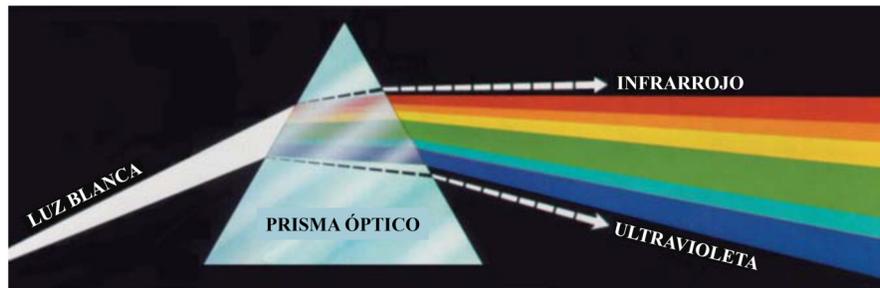
**Figura 2.12.** Representaciones de una imagen digital como una función bidimensional  $f(x, y)$  [8].

### 2.4.2. Procesamiento de imágenes en color

Dos razones principales motivan el uso del color en el tratamiento de imágenes; la primera es que ayuda como descriptor, debido a que el color con frecuencia facilita la identificación y extracción de objetos de una escena. La segunda consiste en la identificación de tonos, en comparación con las dos docenas de tonalidades grises, el ser humano puede distinguir numerosas tonalidades e intensidades de color [8].

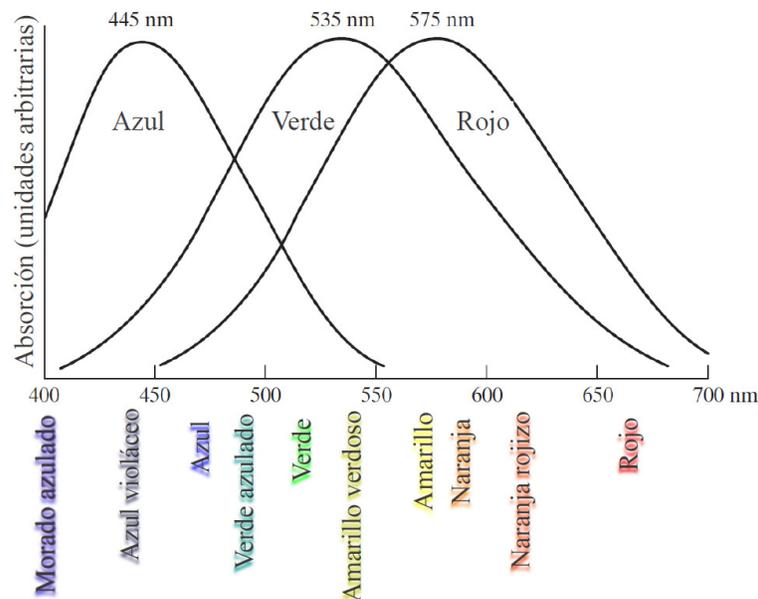
Por su parte, el procesamiento de imágenes en color se divide en dos categorías: *full-color* y *pseudocolor*. En la primera categoría, las imágenes suelen tomarse con un sensor a todo color, como una cámara o escáner en color. En la segunda categoría, el problema consiste en asignar un color a una intensidad monocroma concreta o a un rango de intensidades [8].

**Definición 2.4.1 (Principios básicos del color).** La naturaleza física del color puede expresarse de manera formal con base en resultados teóricos y experimentales [8]. Sir Isaac Newton descubrió en 1666 que cuando un rayo de luz solar atraviesa un prisma de cristal, el rayo que sale no es blanco; en cambio, es un espectro continuo de colores que va del violeta al rojo. Las seis áreas principales del espectro son violeta, azul, verde, amarillo, naranja y rojo [8]. No hay un color en el espectro que termine abruptamente; en cambio, cada color se combina suavemente con el siguiente.



**Figura 2.13.** Vista del espectro al pasar luz blanca a través de un prisma [8].

La luz cromática se sitúa en la región visible del espectro electromagnético, comprendido entre  $400 - 700\text{nm}$ . El resplandor (*radiance*), la luminancia (*luminance*) y el brillo (*brightness*) son los 3 parámetros fundamentales que se utilizan para definir las características de una fuente de luz cromática [8].



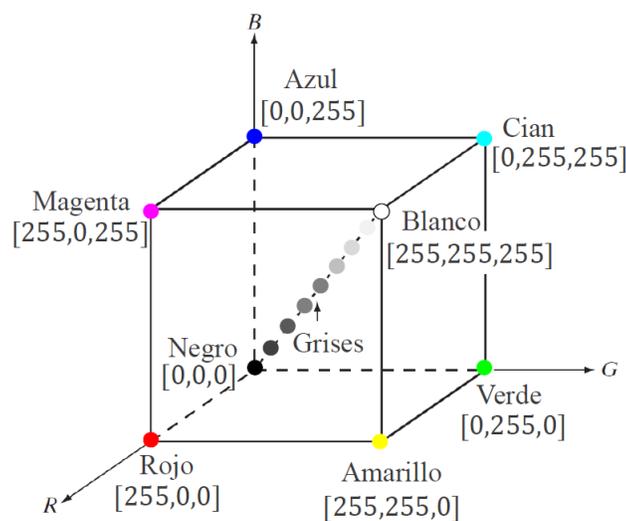
**Figura 2.14.** Absorción de la luz por los conos del ojo humano en función de la longitud de onda (rojos, verdes y azules) [8].

Debido a diversos parámetros característicos de la absorción del ojo humano, los colores se ven como combinaciones variables de los llamados colores primarios, rojo, verde y azul [8]. La CIE (Commission Internationale de l’Eclairage — the International Commission on Illumination) designó en 1931 los siguientes valores específicos de longitud de onda a los tres colores primarios: azul =  $435,8nm$ , verde =  $546,1nm$  y rojo =  $700nm$ . Esto sucede antes de que en 1965 se dispusiera de las curvas experimentales detalladas que se muestran en la Figura 2.14 [8]. Los colores secundarios de la luz son el magenta (rojo más azul), el cian (verde más azul) y el amarillo (rojo más verde). La luz blanca se produce mezclando los tres primarios o un secundario con su color primario opuesto en las intensidades adecuadas [8].

El brillo (*brightness*), el tono (*hue*) y la saturación (*saturation*) son las características que se utilizan con frecuencia para diferenciar un color de otro. El tono y la saturación combinados se denominan cromaticidad (*chromaticity*) [8]. Por lo tanto, un color puede caracterizarse por su brillo y cromaticidad.

**Definición 2.4.2 (Espacios de color).** Es una herramienta utilizada para especificar colores de manera uniforme y ampliamente reconocida; en su forma más simple, especifica un sistema de coordenadas y un subespacio dentro de él, donde cada color está representado por un único punto [55].

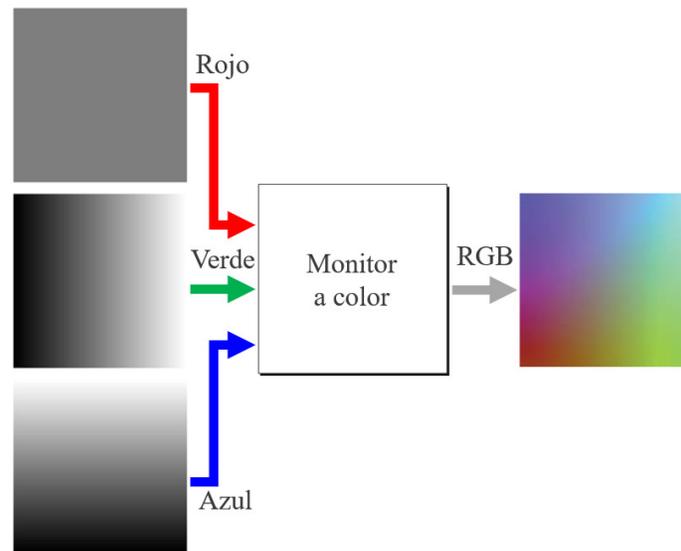
- **Modelo RGB:** Se basa en un sistema de coordenadas cartesianas y muestra cada color en sus componentes espectrales primarios de rojo (**R**), verde (**G**) y azul (**B**) [55].



**Figura 2.15.** Representación del espacio de color RGB [8].

Se utiliza un cubo para representar el subespacio de color (ver Figura 2.15); las tres

esquinas del cubo contienen los valores primarios RGB, mientras que las otras tres esquinas contienen los valores secundarios cian, magenta y amarillo [55]. El negro está en el origen, y el blanco está en la esquina más lejana al origen. A lo largo de la línea que une estos dos puntos, la escala de grises (puntos de valores RGB iguales) se extiende del negro al blanco. Los puntos dentro del cubo que representan los diferentes colores en este modelo están definidos por vectores que se extienden desde el origen [55].

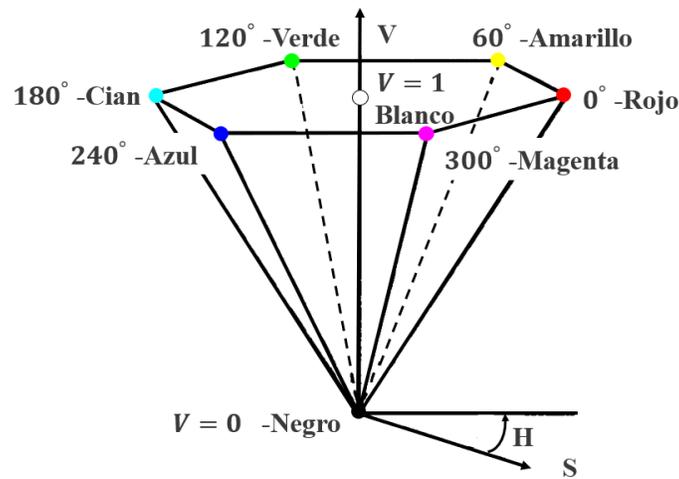


**Figura 2.16.** Generación de la imagen RGB [8].

Las imágenes digitales que se representan en el modelo de color RGB, están compuestas por los 3 componentes primarios (matriz tridimensional  $M \times N \times 3$ ) [55]. Cuando se visualizan en un monitor, se combinan cada componente en la pantalla para producir una imagen de color compuesto, tal como se muestra en la Figura 2.16 (son imágenes en escala de grises). Por consiguiente, el número de bits utilizados para representar cada píxel en el espacio RGB se denomina profundidad de píxel [55].

- Modelo HSV:** Espacio que se basa intuitivamente en la percepción humana del color, planteando que este se puede describirse más fácilmente mediante valores de tono (**H**, *hue*), saturación (**S**, *saturation*) y valor (**V**, *value*); a diferencia de hacerlo a partir de componentes vectoriales en otro espacio de color [55]. HSV es de gran interés en los campos de la visión y los gráficos por computadora.

Este modelo proyecta el cubo RGB a lo largo de las diagonales del blanco al negro, resultando un “hexacone” (ver Figura 2.17) que forma la parte superior de la pirámide HSV [56].



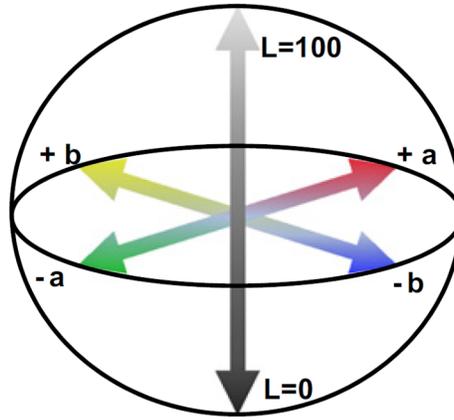
**Figura 2.17.** Representación del espacio de color HSV [8].

El tono o matiz  $H$  se indica como un ángulo alrededor del eje vertical, de manera que el rojo se determina con  $H = 0^\circ$  o  $H = 360^\circ$ , el verde con  $H = 120^\circ$ , y así sucesivamente [55]. La saturación  $S$  es la profundidad o pureza del color y se mide como una distancia radial desde 0 en el eje central (eje  $V$ ), hasta 1 en los lados de la pirámide. Para  $S = 0$ ,  $H$  no está definido [55]. La luminosidad  $V$  determina el tono de gris concreto al que converge esta transformación; está comprendida desde el valor de 0 (color negro) en el vértice de la pirámide, hacia el valor de 1 en la base. Los colores más claros se encuentran en la parte superior de la pirámide; sin embargo, no todos los colores con el mismo brillo son visibles en este plano [55].

- Modelo CIEL\*a\*b\*:** La comisión internacional de iluminación (CIE, *international lighting commission*) recomendó el espacio de color  $L^*a^*b^*$  CIE 1976 como aproximación a los espacios de color uniformes [55]. Los espacios de color uniformes son interesantes para diversas áreas de aplicaciones de procesamiento de imágenes en color, especialmente si hay que comparar colores muy similares.

En este espacio de color, se tiene un canal para la luminancia ( $L^*$ , *Lightness*) y otros dos canales de color,  $a^*$  y  $b^*$ , conocidos como capas de cromaticidad [57]. El canal  $a^*$  indica el color a lo largo del eje *rojo-verde*; en este caso los valores negativos representan el verde, mientras que los valores positivos representan el rojo. Por otra parte, el canal  $b^*$  indica el color a lo largo del eje *azul-amarillo*; los valores negativos de  $b^*$  representan el color azul y los valores positivos representan el color amarillo [57]. Como se puede observar en la Figura 2.18,  $L^*$  puede tomar valores de 0 (negro) a 100 (blanco). Los ejes de coordenadas siguen el hecho de que un color no puede ser a la vez rojo o verde, o a la

vez azul y amarillo, porque estos colores se oponen entre sí. Además, para ambos ejes el cero representa el gris neutro [57].



**Figura 2.18.** Representación del espacio de color CIE L\*a\*b\* [9].

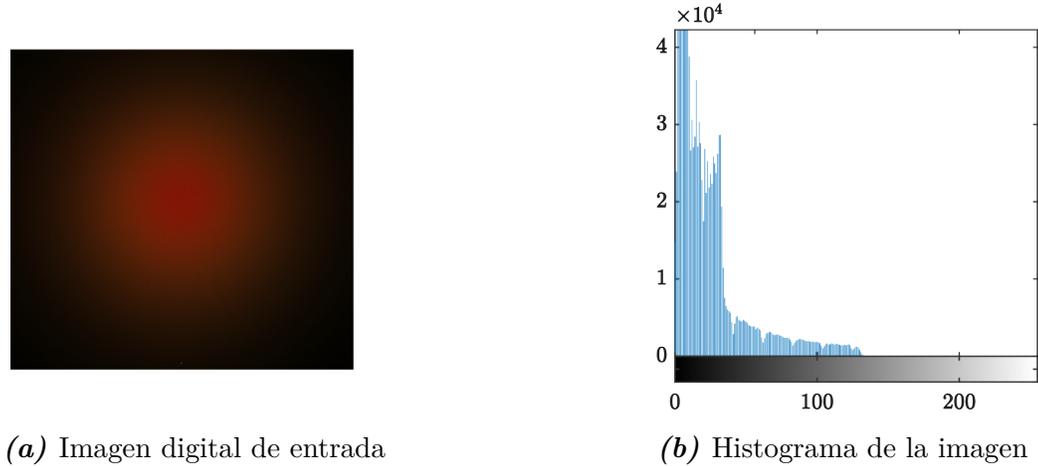
### 2.4.3. Procesamiento de histogramas

El procesamiento digital de imágenes utiliza métodos para corregir el color, eliminar el ruido o aumentar el contraste; algunos de los cuales dependen de operaciones realizadas sobre el histograma de la imagen [8]. Un histograma de una imagen digital representa la frecuencia con la que se distribuyen los valores de los píxeles, descartando la posición que tengan estos en la imagen [8].

Para diversos niveles de intensidad en el intervalo  $[0, L - 1]$ , se define con una función discreta  $h(r_k) = n_k$ , donde  $r_k$  es el  $k$ -ésimo valor de intensidad y  $n_k$  es el número de píxeles de la imagen con intensidad  $r_k$  [8].  $P(r_k)$  es una estimación de la probabilidad de aparición del nivel de intensidad  $r_k$  en una imagen, en la que  $n$  es el total de píxeles (MN).

$$P(r_k) = \frac{n_k}{n} \quad k = 0, 1, 2, \dots, L - 1 \quad (2.22)$$

La Figura 2.19a muestra la imagen digital leída por una cámara CCD de un sensor de fibra óptica y el resultado gráfico del histograma. Para La Figura 2.19b, el eje horizontal corresponde a los valores de intensidad  $r_k$  y el eje vertical corresponde a los valores de  $h(r_k) = n_k$  [8].



**Figura 2.19.** Histograma de una imagen digital RGB.

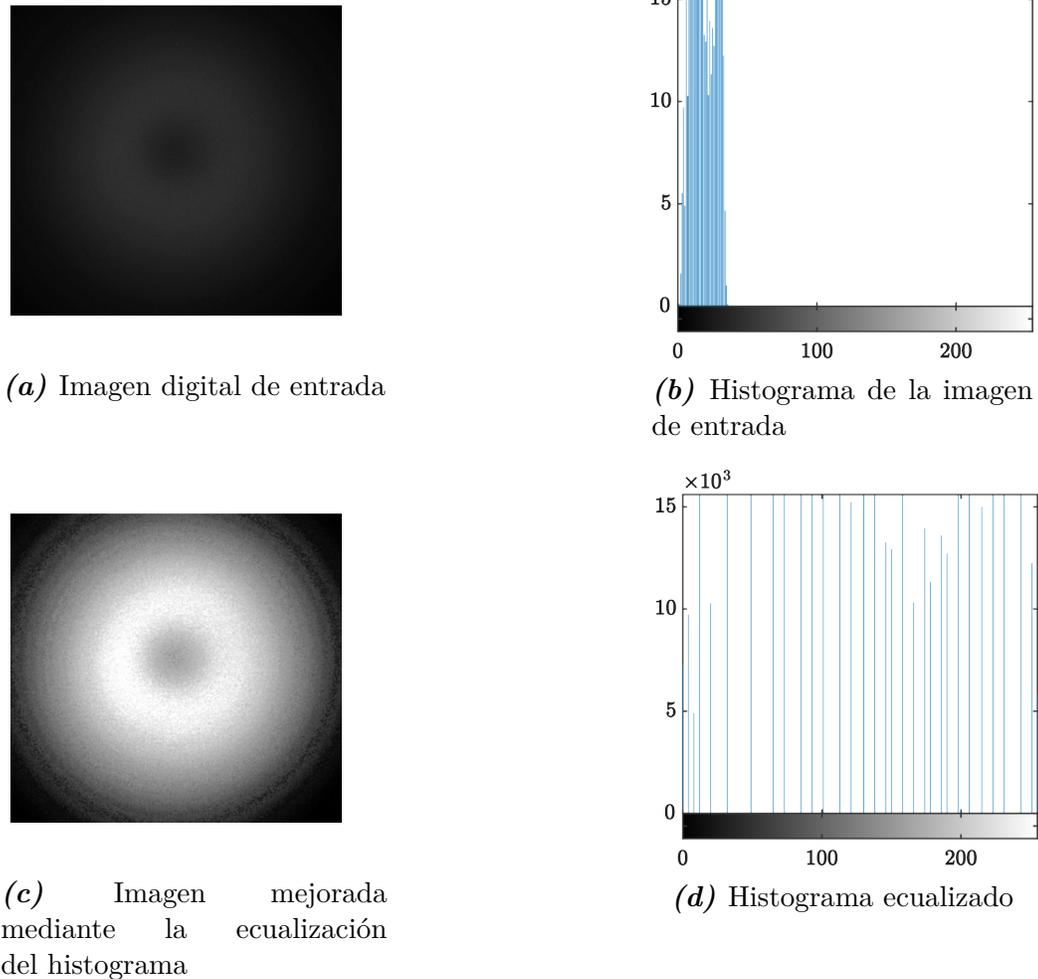
**Definición 2.4.3 (Ecuación de histogramas).** Este método iguala los valores de intensidad en toda la gama del histograma de una imagen, para producir un resultado mejorado que cambia la distribución uniforme de los niveles de intensidad. De esta manera, se aumenta el contraste de la imagen de cada píxel, lo que resulta en una expansión del rango dinámico [8]. Es simple de usar y funciona bien con todo tipo de imágenes con un buen rendimiento y baja complejidad computacional. En función de la ecuación 2.22, al realizar la transformación (mapeo de intensidad) de salida con la forma  $s = T(r_k)$  para el rango  $0 \leq k \leq L - 1$  [8], a partir de cada píxel de la imagen de entrada que tiene una intensidad  $r_k$ ; se debe satisfacer que:

1.  $T(r_k)$  sea una función creciente de forma monótona para el intervalo  $0 \leq k \leq L - 1$ . Así pues, los valores de intensidad de salida no serán inferiores a los valores de entrada.
2. El rango de intensidades de salida debe ser el mismo que el de entrada, tal que  $0 \leq T(r_k) \leq L - 1$  para  $0 \leq k \leq L - 1$

Por lo tanto, la ecualización del histograma se realiza a través de la transformación discreta:

$$s_k = T(r_k) = (L - 1) \sum_{j=0}^k P_r(r_j), \quad k = 0, 1, 2, \dots, L - 1 \quad (2.23)$$

donde  $s_k$  representa el nivel de intensidad de la imagen de salida que se obtiene mapeando cada píxel de la imagen de entrada con intensidad  $r_k$  [8]. La ecuación 2.23 se conoce como transformación de ecualización del histograma y solo se basa en la información que puede extraerse directamente de la imagen de entrada, sin necesidad de especificar más parámetros.

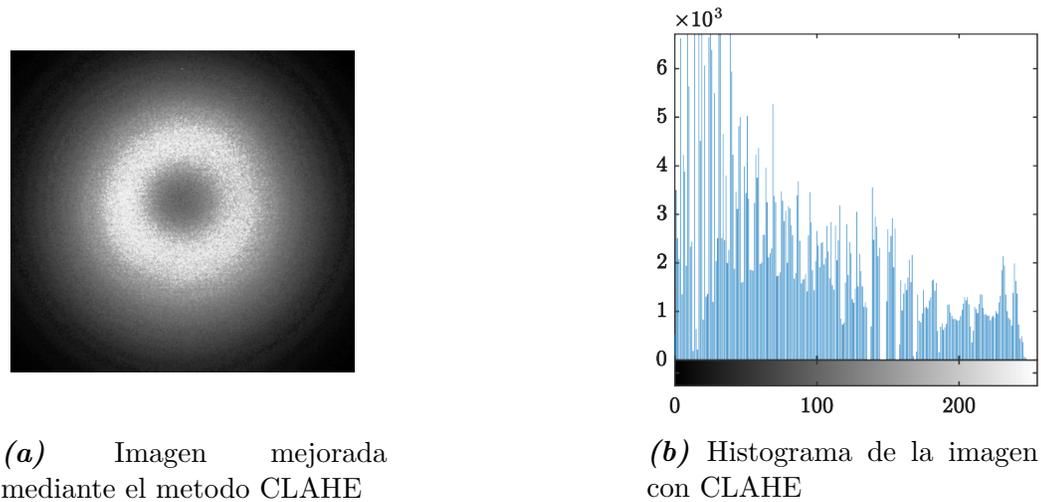


**Figura 2.20.** Comparación del histograma de una imagen digital y el resultado al hacer la transformación de ecualización. La imagen de entrada 2.20a proviene de la descomposición en el plano  $\mathbf{G}$ , de la imagen RGB en la Figura 2.19a

El resultado en la parte superior de la Figura 2.20 muestra la imagen de entrada (a) que está mayormente conformada por píxeles de intensidad oscura y en el centro una forma de círculo en tonos grises; seguido de su histograma (b). En la parte inferior, la Figura 2.20d muestra que el histograma ecualizado de la imagen de entrada tiene una forma uniforme y casi lineal, lo que indica que las entradas se asignaron a salidas casi iguales. La imagen resultante de esta transformación (c) tiene una mejora significativa en el contraste, debido a que resalta los círculos del centro.

Este ejemplo demuestra el poder de la ecualización de histograma como herramienta de mejora del contraste debido a las notables diferencias con la imagen original [8].

**Definición 2.4.4 (Ecuación adaptativa de histograma limitada por el contraste (CLAHE)).** Este método se usa para mejorar el contraste en una imagen mediante el aumento del contraste por regiones. La transformación de salida se produce a través de la creación de múltiples áreas simétricas o bloques rectangulares de igual tamaño en la imagen de entrada, en lugar de utilizar la imagen completa. Por lo tanto, se determina la función de transformación del contraste para cada bloque específico. Después, para eliminar los límites artificiales, se utiliza la interpolación bilineal para combinar los bloques contiguos [58].



**Figura 2.21.** Histograma de una imagen digital obtenido mediante el método CLAHE. La imagen de entrada 2.21a proviene de la descomposición en el plano  $\mathbf{G}$ , de la imagen RGB en la Figura 2.19a

Se debe proporcionar un valor límite para evitar el aumento excesivo del contraste y de esta forma se establece la altura máxima del histograma de salida [58]. Se puede calcular el límite de recorte mediante la siguiente ecuación:

$$\beta = \frac{M}{N} \left( 1 + \frac{\alpha}{100} S_{max} \right), \quad (2.24)$$

donde  $M$  es el número de píxeles por bloque,  $N$  su rango dinámico,  $S_{max}$  es la pendiente máxima y  $\alpha$  es el factor de recorte. La Figura 2.21 muestra la imagen mejorada con el método CLAHE y su histograma. En la imagen 2.21a se puede observar que luego de la transformación, el área del círculo central se resaltan aún más hacia un blanco brillante y el histograma (Figura 2.21b), tiene una distribución de la intensidad de los píxeles en forma exponencial. En este punto se puede asegurar que el histograma resultante con el método CLAHE, tiene más valores de intensidad que el histograma original (Figura 2.20b) y el histograma ecualizado (Figura 2.20d).

# CAPÍTULO 3

---

## Aprendizaje Automático

---

---

<b>3.1 Modelos de aprendizaje automático</b> . . . . .	<b>34</b>
3.1.1 Análisis discriminante . . . . .	34
3.1.2 Bayesiano ingenuo . . . . .	35
3.1.3 Árboles de decisión . . . . .	36
3.1.4 Máquinas de soporte vectorial . . . . .	37
3.1.5 $K$ Vecinos más próximos . . . . .	38
<b>3.2 Evaluación de los modelos de clasificación</b> . . . . .	<b>39</b>
<b>3.3 Algoritmos de selección de características</b> . . . . .	<b>41</b>
3.3.1 ReliefF . . . . .	41
3.3.2 Análisis de Componentes del Vecindario . . . . .	42
3.3.3 Mínima Redundancia Máxima Relevancia . . . . .	43

---

El aprendizaje automático, conocido en inglés como *Machine Learning* (ML), pertenece a una rama de la inteligencia artificial que proporciona la habilidad a un sistema de aprender y reconocer patrones de forma autónoma [59]. Una de las metodologías empleadas para su desarrollo se conoce como aprendizaje supervisado; en este enfoque, se utilizan conjuntos de datos que contienen ejemplos de entrada y salida (etiquetas o respuestas) asociadas. Los datos de entrada son las características o atributos, mientras que las salidas son las etiquetas que deseas predecir o clasificar. La clave aquí es que el conjunto de datos de entrenamiento contiene ejemplos para los cuales se conoce el resultado correcto, lo que significa que tienes una “supervisión” de lo que el modelo debe aprender. Por su parte, se tiene un conjunto de datos de prueba que mide el rendimiento y la capacidad de generalización del modelo, debido a que son muestras no vistas durante el proceso de entrenamiento [60].

Las aplicaciones del aprendizaje supervisado son amplias y van desde la clasificación de correos electrónicos como spam o no spam hasta la detección de enfermedades a partir de imágenes médicas. Algunos algoritmos comunes utilizados en el aprendizaje supervisado incluyen regresión lineal, regresión logística, máquinas de soporte vectorial, árboles de decisión, bosques aleatorios, redes neuronales, entre otros [59].

En este capítulo se desarrolla la revisión teórica de cinco modelos de aprendizaje automático, usados para la clasificación y detección del ángulo de curvatura del dedo índice en un brazo robótico. Además de tres algoritmos de selección de características y la métrica para evaluar el rendimiento de los modelos.

## 3.1. Modelos de aprendizaje automático

Existen numerosos modelos y algoritmos de aprendizaje automático, cada uno con sus propias características y aplicaciones específicas [59]. A continuación se define los modelos empleados en este trabajo:

### 3.1.1. Análisis discriminante

El análisis discriminante (DA - *Discriminant Analysis*) es un modelo generativo que clasifica una observación al calcular la probabilidad posterior de que dicha observación pertenezca a cada clase [61]. Este algoritmo de aprendizaje supervisado utiliza observaciones

de entrenamiento para determinar la ubicación de un límite entre las clases de respuesta. Este límite se determina tratando las observaciones de cada clase como muestras de una distribución normal multidimensional, calculando el vector de medias y la matriz de covarianza para cada clase. Una vez conseguida una distribución ajustada, se genera una frontera entre las clases determinando el conjunto de puntos en los que las probabilidades son iguales. Las observaciones situadas a un lado de la frontera se clasificarán como una clase y las situadas al otro lado, como otra clase. Existen diferentes enfoques de algoritmos de análisis discriminante, pero los dos más comunes son: Análisis Discriminante Lineal (LDA) y Análisis Discriminante Cuadrático (QDA). Sin embargo, el proceso general del Análisis Discriminante implica los siguientes pasos:

- Seleccionar un conjunto de datos con múltiples clases o grupos.
- Calcular las medias y matrices de covarianza para cada clase.
- Utilizar estas estadísticas para encontrar las funciones discriminantes lineales o cuadráticas que maximizan la separación entre las clases.
- Proyectar los datos en el espacio de características de menor dimensión definido por las funciones discriminantes.

Ahora bien, desde el punto de vista matemático, la regla discriminante que rige la pertenencia de un vector de datos ( $x$ ) a una clase ( $k$ ), se define mediante la siguiente ecuación:

$$p(x|k) = \text{MIN}_k \left[ (x - \bar{x}_k)^T C_k^{-1} (x - \bar{x}_k) + \ln|C_k| - 2\ln\Pi_k \right], \quad (3.1)$$

donde el primer término es la distancia de Mahalanobis al cuadrado entre la observación y el vector de la media poblacional  $\bar{x}_k$  de la clase  $k$ . El término del medio es el logaritmo del determinante de la matriz de covarianza  $C_k$  y el último término es el logaritmo de la probabilidad a priori de la clase  $k$  [62]. Esta regla asigna la observación a la clase en la que la puntuación discriminante anterior es menor o que la distancia de Mahalanobis al cuadrado sea menor [63].

### 3.1.2. Bayesiano ingenuo

En el campo de la estadística, los clasificadores bayesiano ingenuo o *Naïve-Bayes* (NB) pertenecen a un grupo de “*clasificadores probabilísticos*” poco complicados que se basan en

la utilización del teorema de Bayes asumiendo una independencia robusta (ingenua) entre las características [64]. En términos generales, en respuesta a distintos valores de entrada de un conjunto específico de atributos o variables, el clasificador bayesiano ingenuo tiene la capacidad de calcular la probabilidad de que los datos de entrada estén vinculados a una categoría particular [65].

El teorema de Bayes proporciona una forma de calcular la probabilidad posterior  $P(c|x)$  de la forma:

$$P(c | x) = \frac{P(x | c)P(c)}{P(x)} \quad (3.2)$$

$$P(c | X) = P(x_1 | c) \times P(x_2 | c) \times \dots \times P(x_n | c) \times P(c),$$

donde  $P(c)$  es la probabilidad previa de la clase,  $P(x)$  la probabilidad previa del predictor y  $P(x|c)$  es la verosimilitud; es decir, la probabilidad del predictor dada la clase [65].

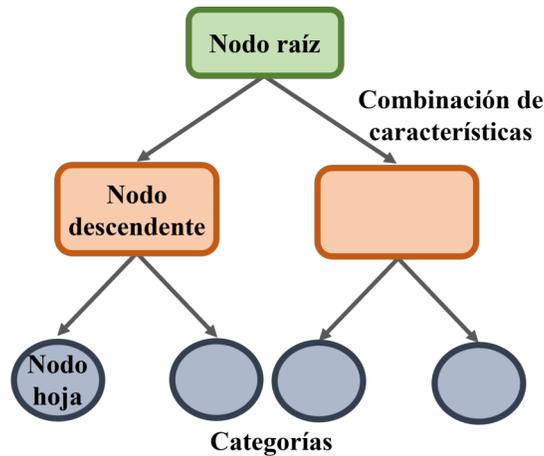
Cuando se desconocen las relaciones de dependencia entre las características, se adopta una hipótesis simple, en la que las características son condicionalmente independientes dada la categoría [64], es decir,

$$P(c_k | x) \propto \prod_{i=1}^d P(x_i | c_k) \quad (3.3)$$

Esta regla se conoce como Naïve-Bayes. El modelo de clasificación ofrece asistencia para distribuciones condicionales de predictor gaussiano, kernel, multinomial y multinomial multivariante [65]. Cuando se utiliza una distribución kernel para cada predictor, el clasificador bayesiano ingenuo calcula distintas estimaciones de densidad kernel para cada clase utilizando los datos de entrenamiento de la clase correspondiente.

### 3.1.3. Árboles de decisión

Un árbol de decisión (DT -*Decision Tree*) se emplea como un modelo predictivo para inferir resultados sobre un grupo de observaciones, a partir de una secuencia de preguntas, en la que la siguiente formulada depende de la respuesta a la pregunta actual, realizando un recorrido de una estructura de árbol [66]. En esta situación, la variable objetivo adopta valores discretos para su clasificación. Para esta estructura de árbol, las hojas simbolizan las categorías de clase vinculadas a una distribución de probabilidad específica; mientras que las ramas reflejan la combinación de características que llevan a dichas categorías de clase [64].



**Figura 3.1.** Estructura básica de un árbol de decisión.

La clasificación de un patrón determinado comienza en el nodo raíz (*root node*) y los distintos enlaces desde el nodo raíz corresponden a los distintos valores posibles [64]. En función de la respuesta, se sigue el enlace adecuado hasta un nodo posterior o descendente; hasta llegar a un nodo hoja, que no tiene más preguntas. Por consiguiente, los enlaces deben ser mutuamente distintos y exhaustivos y cada nodo hoja lleva una etiqueta de categoría [64]. El diseño de árboles se centra en decidir qué prueba de propiedades o consulta debe realizarse en cada nodo. Para hacer la selección de atributos, se usan los siguientes criterios: impureza de entropía, índice Gini, impureza de clasificación errónea, entre otras [59].

### 3.1.4. Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM - *Support Vector Machine*), corresponde a un modelo de aprendizaje supervisado que se constituye como un clasificador lineal binario no probabilístico [67, 68]. SVM crea hiperplanos de separación entre las clases de datos para maximizar el ancho de la brecha entre ellas; a su vez, asigna las predicciones de nuevas muestras a una clase en función del lado de la brecha en el que se encuentren [67]. Este algoritmo realiza la separación de los datos a través de la Ecuación 3.4, en la que  $y_i = \varphi(x_i)$  corresponde a la transformación o mapeo no lineal apropiado del conjunto de características  $x_i$ ,  $\mathbf{w}^T$  es un vector normal que controla la dirección del hiperplano y  $w_{i0}$  es la distancia desde el origen al hiperplano (bias).

$$g_i(\mathbf{y}_i) = \mathbf{w}^T \mathbf{y}_i + w_{i0} \quad i = 1, \dots, c \quad (3.4)$$

Durante el entrenamiento, los parámetros  $\mathbf{w}^T$  y  $w_{i0}$  se ajustan; SVM encuentra el hiperplano con la máxima distancia a los patrones de entrenamiento más cercanos, los vectores de soporte. Estos patrones de entrenamiento (transformados), están en proximidad (equivalente) al hiperplano a una distancia que se le conoce como margen [64]. Para los problemas multicategoría, SVM crean límites de decisión que consisten en secciones de dichos hiperplanos [63].

Aunque las SVM son conocidas por su capacidad para encontrar hiperplanos de separación lineal, también pueden manejar problemas de clasificación no lineal mediante el uso de funciones kernel [67, 68]. Los kernels permiten que las SVM proyecten los datos en un espacio de características de mayor dimensión, donde la separación puede ser lineal, incluso si los datos son linealmente inseparables en el espacio de características original. El truco del kernel se usa para mapear implícitamente la transformación adecuada, para este las funciones conocidas son la polinomial, base radial gaussiana, sigmoide y laplaciano [64, 65]. De esta forma, trata de encontrar el hiperplano que separa los datos con el máximo margen en el nuevo espacio.

### 3.1.5. $K$ Vecinos más próximos

Conocido en inglés como *K-Nearest Neighbor* (KNN), es un clasificador de aprendizaje no paramétrico y basado en instancias que no asume explícitamente la distribución del conjunto de datos en cada clase [60]; por lo que puede ser adecuado para conjuntos de datos no gaussianos. Clasifica una muestra externa a los datos en función de cómo se distribuyen sus vecinos. Debido a que el método se basa en instancias, no construye el modelo de manera explícita durante el entrenamiento, por lo que memoriza las instancias de entrenamiento como base de conocimiento para las predicciones [69]. Esto implica que deben conservar todas las observaciones como componente del modelo para dar una respuesta y clasificar nuevos casos basándose en una medida de similitud.

El valor  $K$  es un parámetro que se refiere al número de vecinos más cercanos que se deben incluir en el proceso de votación. Un punto de datos externo se clasifica por la mayoría de votos de sus  $K$  vecinos más cercanos. Elegir el valor correcto de  $K$  es un proceso llamado ajuste de parámetros, y es importante para mejorar la precisión. Al clasificar una nueva observación (desconocida), el método calcula la distancia Euclidiana con respecto a todos los patrones

anteriores que están en la base de datos, tal como se muestra en la Ecuación 3.5;

$$d_E(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (3.5)$$

donde  $n$  representa el número de dimensiones o características,  $x_i$  y  $y_i$  son los valores de las características en los puntos a comparar. Además de la distancia Euclidiana, son usadas también la Manhattan, Chebyshev, Minkowski y Mahalanobis para los datos numéricos [63]; mientras que la distancia de Hamming se puede utilizar para los datos categóricos o binarios [63]. Cada una de ellas, puede proporcionar resultados diferentes en un mismo problema.

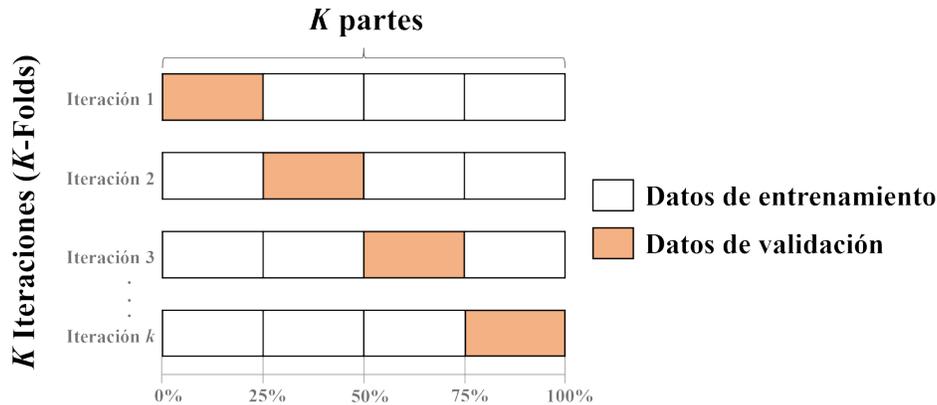
Luego, toma los  $K$  patrones anteriores con los que se ha obtenido menores distancias (por lo tanto, mayor parecido), calcula la probabilidad de clase condicional y apunta sus clases asociadas [60]. Así pues, cuenta el número de veces ( $V(x)$ ) que cada clase ( $X$ ) aparece en estos  $K$  patrones vecinos. Se dice que el nuevo patrón de entrada pertenece con la clase que ha obtenido un valor  $V(x)$  mayor (asigna la observación a una clase con la mayor probabilidad) [60, 69].

## 3.2. Evaluación de los modelos de clasificación

La evaluación de modelos de clasificación es un paso crucial en el desarrollo de sistemas de aprendizaje automático y en la toma de decisiones basadas en modelos. La evaluación se realiza para determinar qué tan bien un modelo es capaz de hacer predicciones precisas sobre conjuntos de datos no vistos. A continuación se define las técnicas de validación usadas:

**Definición 3.2.1 (Validación cruzada de  $k$  iteraciones).** Técnica usada para evaluar el rendimiento de los algoritmos de clasificación, conocida en inglés como  $k$ -Fold Cross-Validation. Los datos enviados al clasificador son subdivididos aleatoriamente en  $k$  secciones, donde tanto los conjuntos de entrenamiento como los de validación mantienen las mismas proporciones de muestras por categoría (ver Figura 3.2) [60, 69]. Cada subdivisión entrena al modelo mediante  $k - 1$  conjuntos, preservando uno como conjunto de validación; lo que resulta en la creación de un modelo de validación cruzada [70].

En el proceso de la predicción de los datos, el algoritmo anticipa las etiquetas de categoría para las observaciones de cada bloque de validación, al emplear un clasificador de validación cruzada. Este calcula una respuesta para cada observación utilizando el modelo entrenado sin esa observación.



**Figura 3.2.** Ilustración gráfica de la técnica de validación cruzada  $k$ -fold.

**Definición 3.2.2 (Exactitud (Accuracy)).** Es una de las métricas más populares en la clasificación multiclase y se calcula directamente a partir de la matriz de confusión.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \times 100\% \quad (3.6)$$

La fórmula de la exactitud involucra la suma de elementos verdaderos positivos ( $TP$ ) y verdaderos negativos ( $TN$ ) en el numerador y la suma de todas las entradas de la matriz de confusión en el denominador ( $FP$  - falso positivo,  $FN$  - falso negativo), los cuales se muestran en la Figura 3.3. Los verdaderos positivos y los verdaderos negativos corresponden a los elementos correctamente clasificados por el modelo y están situados en la diagonal principal de la matriz de confusión, mientras que el denominador también considera todos los elementos fuera de la diagonal principal que han sido erróneamente clasificados por el modelo [71].

		PREDICCIÓN	
		Positivo	Negativo
REAL	Positivo	TP	FP
	Negativo	FN	TN

**Figura 3.3.** Matriz de confusión

En palabras sencillas, la exactitud es la probabilidad de que las predicciones del modelo sean correctas con respecto al conjunto de datos [71].

### 3.3. Algoritmos de selección de características

La selección de características tiene una importancia considerable en el análisis de datos y el aprendizaje automático. Tiene como objetivo identificar las características significativas, de forma tal que se reduce el espacio de evaluación al descartar los datos irrelevantes que le restan potencia al modelo evaluado. Estos algoritmos proporcionan un nuevo espacio de características, por ende, este cambio o rotación aporta la capacidad a los datos de adquirir un comportamiento que mejore la capacidad de diferenciación entre distintas clases. De esta forma, los modelos de aprendizaje automático tienen un mejor desempeño al momento de predecir o clasificar patrones.

#### 3.3.1. ReliefF

Desarrollado en 1992 con un enfoque de filtro, este algoritmo es notablemente sensible a las interacciones de las características [72, 73]. Realiza la clasificación de los predictores a través de la utilización de  $k$  vecinos más cercanos por categoría. En este proceso, calcula un peso o ponderación para cada característica de los datos, aplicando una penalización a los predictores que proporcionan valores diferentes respecto a los vecinos pertenecientes a una misma clase, y otorgando incentivos a los predictores que presentan variaciones respecto a los vecinos pertenecientes a categorías distintas [74]. Dicha ponderación se basa en la detección de diferencias en los valores de las características entre pares de instancias próximas [74].

El algoritmo selecciona iterativamente una observación aleatoria ( $x_r$ ) y encuentra las  $k$  observaciones más cercanas de cada clase a  $x_r$ ; actualizando para cada vecino más cercano ( $x_q$ ) todas las ponderaciones para los predictores  $F_j$  [74], de la siguiente manera:

- Si  $x_r$  y  $x_q$  pertenecen a la misma clase,

$$W_j^i = W_j^{i-1} - \frac{\Delta_j(x_r, x_q)}{m} \cdot d_{rq} \quad (3.7)$$

- Si  $x_r$  y  $x_q$  pertenecen a clases diferentes,

$$W_j^i = W_j^{i-1} + \frac{p_{y_q}}{1 - p_{y_r}} \frac{\Delta_j(x_r, x_q)}{m} \cdot d_{rq}, \quad (3.8)$$

donde  $W_j^i$  es el peso de los predictores  $F_j$  en la  $i$ th iteración,  $p_{y_r}$  la probabilidad a priori de la clase a la que pertenece  $x_r$ ,  $p_{y_q}$  la probabilidad a priori de la clase a la que pertenece  $x_q$  y  $m$  es el número de iteraciones [74]. Además,  $\Delta_j(x_r, x_q)$  es la diferencia en el valor del predictor  $F_j$  debido a las observaciones,  $d_{rq}$  es una función de distancia que tiene la forma:

$$d_{rq} = \frac{\tilde{d}_{rq}}{\sum_{l=1}^k \tilde{d}_{rl}} \quad (3.9)$$

La distancia está sujeta a la escala  $\tilde{d}_{rq} = e^{-(\text{rank}(r,q)/\text{sigma})^2}$ ; en la que,  $\text{rank}(r, q)$  es la posición de la  $q$ -ésima observación entre los vecinos más cercanos de la  $r$ -ésima observación, ordenados por distancia [74]. El valor  $k$  es el número de vecinos más cercanos.

### 3.3.2. Análisis de Componentes del Vecindario

Algoritmo no paramétrico conocido en inglés como Neighborhood component analysis (NCA). Su objetivo es evaluar la ponderación de las características en relación con el vecino más cercano, el cual aprende un vector de ponderación de características que maximiza la precisión de clasificación esperada “*leave-one-out*”, mediante un término de regularización [75]. NCA elige aleatoriamente un punto de referencia ( $x_j$ ) de un conjunto de datos  $S$ , para que sea el vecino más cercano de un punto  $x_i$  del vector de características [75]. La probabilidad  $P_{ij}(x_i = x_j|S)$  de que se elija el punto  $x_j$  es mayor si está más cerca de  $x_i$ ; por lo tanto, se determina por medio de la función de distancia  $d_w$  [75],

$$d_w(x_i, x_j) = \sum_{r=1}^p w_r^2 |x_{ir} - x_{jr}|, \quad (3.10)$$

donde  $w_r$  es el vector de pesos de las características,  $d_w$  la distancia ponderada entre las dos muestras y  $w_r$  es un peso asociado a la  $r$ -ésima característica. La relación entre la probabilidad  $P_{ij}$  y la función de distancia  $d_w$  se establece introduciendo un kernel, el cual asume valores

grandes cuando  $d_w(x_i, x_j)$  es pequeña [75]. Por consiguiente, la  $P_{ij}$  puede definirse como:

$$P_{ij} = \frac{k(d_w(x_i, x_j))}{\sum_{j=1, j \neq i}^n k(d_w(x_i, x_j))}, \quad (3.11)$$

en la cual la función *kernel* ( $k$ ) es definida como  $k(z) = e^{-\frac{z}{\sigma}}$  y el parámetro  $\sigma$  es el ancho del kernel. Este parámetro de entrada influye en la probabilidad de que una muestra  $x_j$  sea seleccionada como punto de referencia [75]. Por tanto, la precisión media de la clasificación *leave-one-out* con el término de regularización para aliviar el *sobreaajuste*, conduce a la obtención de la siguiente función objetivo [75]:

$$\xi(w) = \sum_{i=1}^n \sum_{j=1}^n Y_{ij} P_{ij} - \lambda \sum_{r=1}^p w_r^2, \quad (3.12)$$

donde  $n$  es el número de observaciones y  $p$  es el número de variables predictoras,  $\lambda > 0$  es el parámetro de regularización. Dado que la función objeto  $\xi(w)$  es diferenciable, se calcula su derivada con respecto a  $w_r$  y se obtiene una ecuación de actualización de ascenso del gradiente [75]:

$$\frac{\partial \xi(w)}{\partial w_r} = 2 \left( \frac{1}{\sigma} \sum_{i=1}^n (P_i \sum_{j \neq i}^n P_{ij} |x_i - x_j| - \sum_{j=1}^n Y_{ij} P_{ij} |x_i - x_j|) - \lambda \right) w_r \quad (3.13)$$

### 3.3.3. Mínima Redundancia Máxima Relevancia

El algoritmo de Mínima Redundancia Máxima Relevancia (mRMR - *Minimum Redundancy Maximum Relevance*) es un método de medición para filtrado de características, cuya función es calcular la redundancia entre características y la correlación entre características y las clases [76].

El propósito es reducir la redundancia en un grupo de atributos y simultáneamente incrementar la pertinencia de dicho conjunto para la variable de salida, basándose en la información mutua  $I(x, z)$  [77]; por ende, selecciona las características que son más relevantes. La información mutua entre dos variables cuantifica cuánta incertidumbre de una variable puede ser disminuida al conocer la otra variable [76].

La idea de minimizar la redundancia ( $W_s$ ) es seleccionar las características que sean mutuamente lo más diferente posible, de manera que el nuevo conjunto de características ( $S$ )

representen mejor todo el conjunto de datos [76]. La condición de redundancia mínima es:

$$W_s = \frac{1}{|S|^2} \sum_{x,z \in S} I(x, z) \quad (3.14)$$

La condición para maximizar la relevancia total de todos los datos en el conjunto de características  $S$  con respecto a una variable de respuesta  $y$ , es:

$$V_s = \frac{1}{|S|} \sum_{x \in S} I(x, y) \quad (3.15)$$

El conjunto de características óptimo ( $S$ ) se logra optimizando simultáneamente las condiciones de las ecuaciones 3.14 y 3.15; para lo cual se requiere que ambas se combinen en una única función de criterio [76]. mRMR clasifica las características mediante el esquema de adición directa, utilizando el valor del cociente de información mutua ( $MIQ$ ) [76];

$$MIQ_x = \frac{V_x}{W_x}, \quad (3.16)$$

donde  $V_x$  y  $W_x$  son la relevancia y la redundancia de una característica, respectivamente:

$$V_x = I(x, y), \quad (3.17)$$

$$W_x = \frac{1}{|S|} \sum_{x \in S} I(x, z) \quad (3.18)$$

El algoritmo mRMR clasifica todas las características y devuelve un vector de índices (los índices son las características ordenadas por importancia), cuantificando la importancia de una característica mediante un algoritmo heurístico y devolviendo una puntuación (*scores*) [77]. Un valor de puntuación grande indica que el índice de un predictor correspondiente es importante; a partir de este máximo, la puntuación de las características va en descenso, representando de forma tal la confianza en la selección.

# CAPÍTULO 4

---

## Metodología

---

---

<b>4.1</b>	<b>Dispositivo óptico</b>	<b>46</b>
4.1.1	Configuración experimental	46
4.1.2	Principio de operación	50
<b>4.2</b>	<b>Aplicación del sistema para monitorizar curvatura</b>	<b>55</b>
4.2.1	Adquisición de datos	57
4.2.2	Procesamiento de imágenes	59
4.2.3	Base de datos	64
4.2.4	Visualización de los datos	66
4.2.5	Diagrama propuesto de detección de curvatura	68

---

En este capítulo se desarrolla la caracterización y el principio de funcionamiento del dispositivo óptico propuesto para detectar curvatura, el cual se basa en la modulación de intensidad debido a las pérdidas por flexión en una fibra óptica monomodo. Además, se propone aplicar este dispositivo para conocer la curvatura ante el movimiento de flexión en una sección del dedo índice de un brazo robótico. Esto se logra por medio de la construcción de una base de datos de las imágenes obtenidas a partir del perfil de salida de la fibra cuando se somete a curvatura.

Los modelos de inteligencia artificial (AI) se utilizan para analizar las imágenes capturadas por el sistema propuesto y encontrar patrones en los datos extraídos mediante la clasificación. Esto permite identificar el comportamiento característico del sistema de fibra óptica y, por lo tanto, determinar la posición angular del dedo índice en un brazo robótico. Por consiguiente, se plantea que los sistemas basados en aprendizaje automático, pueden modelar sistemas ópticos con respuestas lineales y no lineales, alcanzando resultados favorables.

## 4.1. Dispositivo óptico

A continuación, se describe el proceso de desarrollo y validación del dispositivo óptico propuesto.

### 4.1.1. Configuración experimental

El montaje que se muestra en la Figura 4.1 se utilizó para caracterizar el dispositivo óptico sugerido y determinar la respuesta a la curvatura. La instrumentación consiste en los siguientes componentes:

- Micrómetro Vernier SM-13: Tiene un rango de recorrido de 13.0 mm con un paso de rosca de 0.5 mm, realiza lecturas con incrementos de 10  $\mu\text{m}$  y una lectura vernier de 1  $\mu\text{m}$ .
- Etapa de traslación lineal  $X$ , modelo M-460P- $X$  con un recorrido suave total de 25.4 mm.
- Arduino UNO
- Motor a pasos de 4 líneas de control (5 Vcc)
- Tarjeta de control para motor a pasos, modelo ARD-300. Trabaja con el driver ULN2003A

- LED acoplado a fibra modelo MBB1F1, marca Thorlabs que cuenta con las especificaciones de la Tabla 4.1

**Tabla 4.1.** Características del LED MBB1F1 (datos tomados de la hoja de datos del fabricante [10])

Especificaciones	Valor
Color	Broadband
Longitud de onda	470 – 850 nm
Corriente máxima	500 mA
Energía eléctrica	1800 mW

- Fibra óptica monomodo (**SMF** - *Single Mode Fiber*) modelo 630HP marca Thorlabs, que cuenta con las especificaciones de la Tabla 4.2.

**Tabla 4.2.** Características geométricas y ópticas de la SMF 630HP (datos tomados de la hoja de datos del fabricante [11])

Especificaciones	Valor
Diámetro de núcleo	3,5 $\mu\text{m}$
Diámetro del revestimiento ( <i>cladding</i> )	125 $\mu\text{m}$
Radio mínimo de curvatura	6 mm (Momentáneo) 13 mm (A largo plazo))
Longitud de onda operativa	600 – 770 nm
Longitud de onda de corte ( <i>cutoff</i> )	570 $\pm$ 30 nm

- Analizador de espectro óptico modelo USB2000 marca Ocean Optics, que cuenta con las especificaciones de la Tabla 4.3.

**Tabla 4.3.** Características del espectrómetro USB2000 (datos tomados de la hoja de datos del fabricante [12])

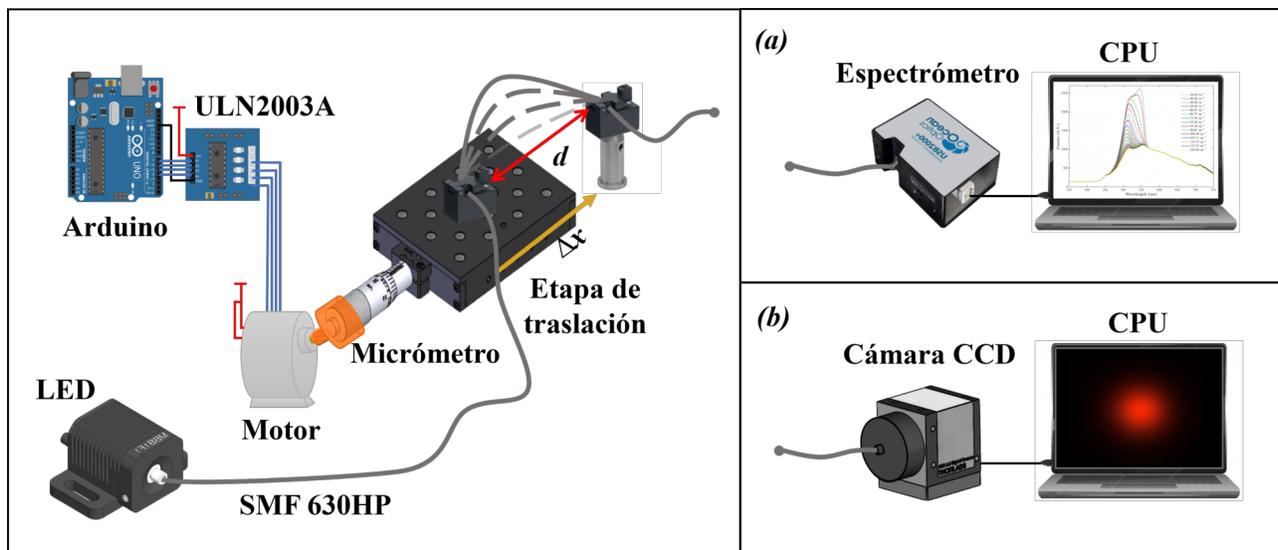
Especificaciones	Valor
Detector CCD	Sony ILX511 linear silicon CCD array
Alcance del detector	200 – 1100 nm

- Cámara CCD modelo DCC3240x (Color) marca Thorlabs, que cuenta con las especificaciones de la Tabla 4.4.

**Tabla 4.4.** Características de la cámara CCD (datos tomados de la hoja de datos del fabricante [13])

Especificaciones	Valor
Tipo de sensor	CMOS
Clase de resolución	SXGA
Resolución	1280 × 1024 (1.3 Megapixel)
Frecuencia de imagen	60 fps

El sistema óptico de la Figura 4.1 usa 2.0 m de longitud de SMF comercial (630HP) que se conecta a los extremos con conectores SMA905. La señal de luz visible del LED (MBB1F1) se incorpora a la fibra en su totalidad. La curvatura de la SMF está controlada por dos abrazaderas de fibra (T711-250), una está en la etapa de traslación lineal (M-460P-X) y la otra está fijada y ubicada a una distancia “ $d$ ” de la base de traslación. Se utiliza el Arduino UNO para manejar el motor a pasos y controlar la dirección de avance y retroceso de los pasos del micrómetro cada 0.5 mm. Esto hace que la SMF se curve al accionar la etapa de traslación. El motor a pasos se une al micrómetro a través de una pieza de impresión 3D.

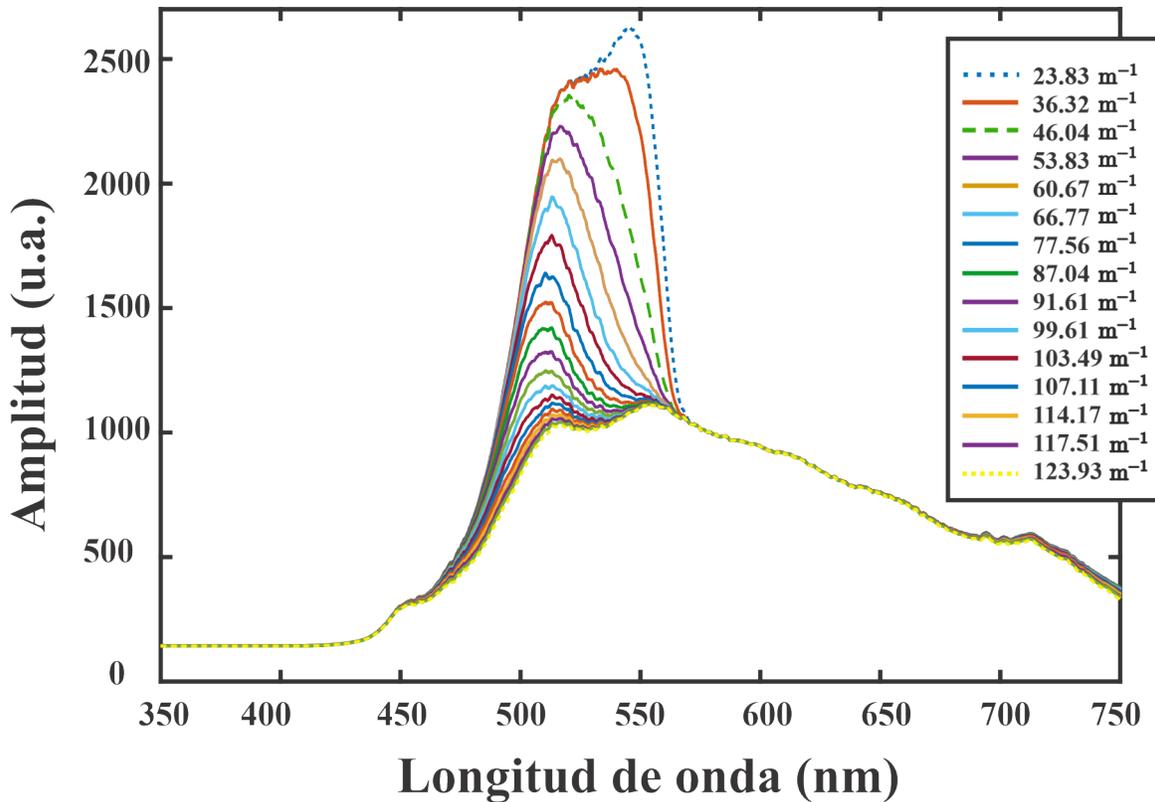


**Figura 4.1.** Montaje experimental del dispositivo de fibra óptica para medir curvatura.

En este montaje se evalúa en dos pasos; el primero implica comprender la respuesta de la fibra óptica ante la curvatura, mediante la lectura del espectrómetro. En cuanto al segundo paso, se centra en el análisis estadístico de las imágenes capturadas por la cámara CCD. Este enfoque tiene como objetivo comprender el principio de funcionamiento del sistema y establecer una estrategia de análisis en el procesamiento de las imágenes, asegurando una apropiada incorporación de la curvatura en el sistema de monitorización biomecánica. Se usa

la ecuación 2.20 para el cálculo de la curvatura en la fibra óptica, teniendo en cuenta cada movimiento del micrómetro de 0.5 mm, con una longitud de desplazamiento total de 10.0 mm de la etapa de traslación lineal.

### 1. Respuesta del espectrómetro



**Figura 4.2.** Variación de la longitud de onda con respecto a la curvatura.

Se conecta el extremo de la SMF al espectrómetro para analizar el comportamiento del espectro de la luz conforme se va curvando la fibra (Figura 4.1a). De la Figura 4.2 se desprende que el espectro del LED oscila entre 450 y 570 nm, con una intensidad máxima centrada en 550 nm (longitud de onda amarilla). Al aumentar la curvatura, la longitud de onda del pico central del espectro de transmisión pasa de 550 nm a 520 nm (longitud de onda verde), con una curvatura en torno a  $46,04m^{-1}$ .

Simultáneamente, cuando la curvatura alcanza su máximo ( $123,93m^{-1}$ ), el pico espectral se desplaza a  $513nm$  (longitud de onda verde). Por lo tanto, en las mediciones se observa que a medida que la curvatura aumenta, la intensidad disminuye; el pico central y las demás longitudes de onda tienen un comportamiento similar para la longitud de onda

verde. Es esencial observar que la señal transmitida de 570 nm a 720 nm no se ve afectada; en esta región, la fibra óptica actúa como una guía de ondas monomodo.

#### 4.1.2. Principio de operación

El comportamiento que se observa en la Figura 4.2, se explica a través de las ecuaciones de pérdidas por curvatura en la fibra óptica expuestas en el Capítulo 2. A medida que aumenta el radio efectivo de curvatura (ecuación 2.18) para ciertas constantes de propagación ( $\beta_z$ ), aumenta el coeficiente de pérdida expuesto en la ecuación 2.19. Al aumentar las pérdidas, la potencia disminuye y es lo que se observa con el espectrómetro. Esto sucede para ciertas condiciones de longitud de onda, sobre todo a aquellas del rango multimodal de la fibra (450 - 570 nm). Este cambio genera la variación en las constantes de propagación debido a la dependencia de la longitud de onda (Ecuación 2.16). A partir de los 570 nm (*cutoff*) la fibra funciona como monomodo, la energía está mayormente concentrada en el núcleo y las pérdidas son menores, considerando que se opera por encima del radio mínimo de curvatura (13 mm).

Bajo este principio de operación, los modos que se propagan se alejan del núcleo hacia el revestimiento al aumentar el radio de curvatura, lo que produce una múltiple interacción de modos que afecta en la cantidad de luz leída por el espectrómetro.

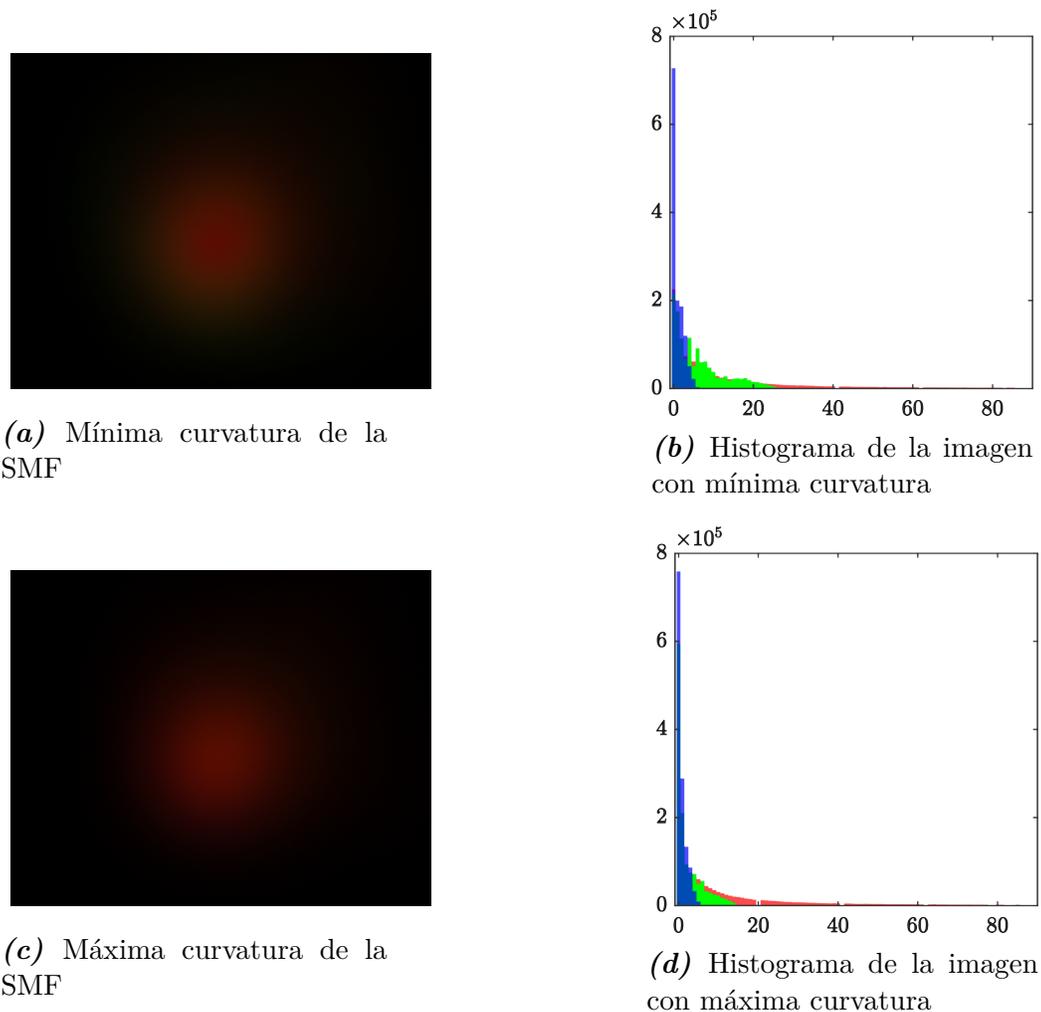
Se propone la aplicación de este trabajo considerando las variaciones de longitud de onda generadas por la fibra óptica 630HP cuando se aplica curvatura, así como el análisis estadístico para garantizar repetibilidad y la longitud con la mejor respuesta ante curvatura. Consiste en un sistema que, por medio del procesamiento de imágenes, detecte el ángulo de curvatura del dedo índice en una sección de 25 mm en un brazo robótico. Todo esto se basa en procesar imágenes en un espacio de color que involucre el estudio del color verde.

## 2. Análisis estadístico de las imágenes

Teniendo en cuenta el radio de curvatura crítico de la fibra óptica para evitar quiebres (13 mm), se definen cuatro secciones de distancia “*d*” en los que se va a curvar la SMF, que van desde 25 a 40 mm, aumentando en 5 mm. El propósito es determinar la longitud óptima de curvatura de la fibra óptica, con la que se obtenga un rango de medición ideal para la aplicación en el brazo robótico.

Se conecta el extremo de la SMF a la cámara CCD mediante un adaptador de fibra desnuda y un soporte impreso en 3D, para el análisis estadístico de las imágenes (Figura

4.1b). En este paso se considera tres recorridos en las direcciones hacia delante y hacia atrás para cada longitud “ $d$ ”, garantizando la repetibilidad del sistema. Las imágenes que se capturan con la cámara CCD son las que se muestran en la Figura 4.3a y 4.3c. En estas se puede apreciar el perfil de salida de luz de la fibra 630HP cuando se somete a curvatura y cuando se estira. El histograma para cada imagen revela la forma de distribución de la intensidad de los *bins* para cada espacio de color del modelo RGB. Para el componente verde (G) se puede apreciar la variación de la frecuencia de los *bins*, en comparación al cambio en los otros dos componentes de color.



**Figura 4.3.** Imagen del perfil de salida de la SMF leída por la cámara CCD y sus respectivos histogramas en el espacio de color RGB.

Mientras tanto, el proceso de captura de imágenes se lleva a cabo de la siguiente manera: el desplazamiento de la etapa de traslación lineal abarca un rango de 0.5 a 10 mm. Al realizar avances en el micrómetro de 0.5 mm, se logran 20 puntos de medición en este

intervalo. En cada punto de medición, se capturan 20 imágenes a medida que la fibra óptica monomodo (SMF) se curva y estira. Como resultado, se obtienen un total de 1200 imágenes para cada valor de distancia “ $d$ ”, tal como se muestra en la Tabla 4.5.

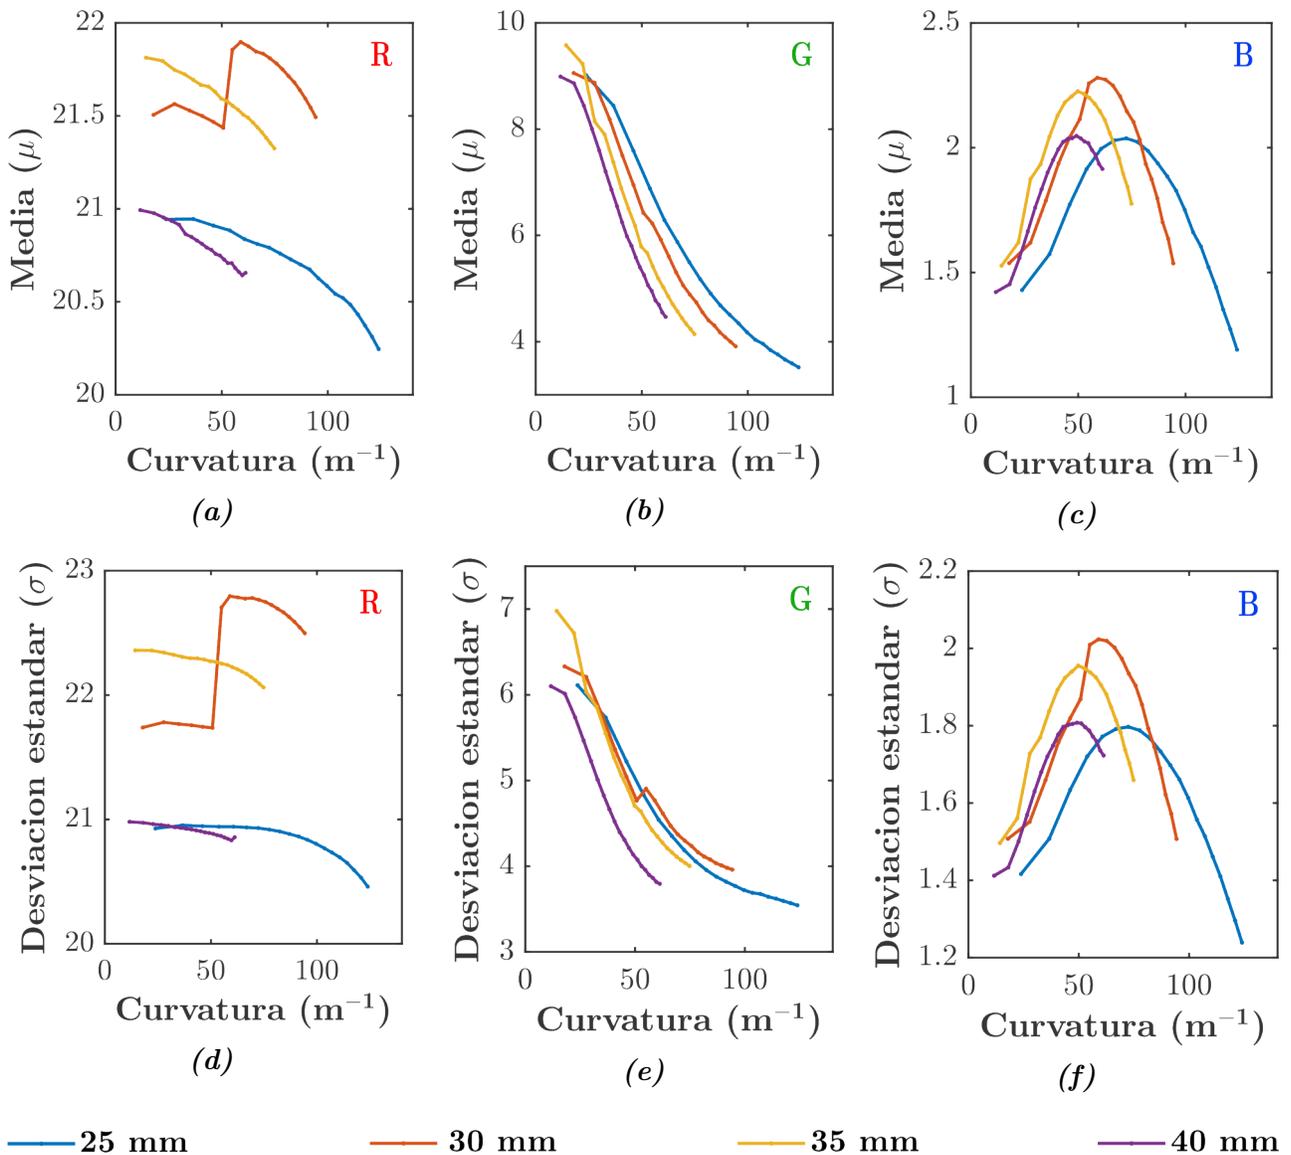
**Tabla 4.5.** Total de imágenes capturadas con el primer montaje propuesto.

“ $d$ ”	# de pasos [0.5 – 10] mm	# de imágenes por paso	Total de imágenes en 3 repeticiones
25 mm	20	20	1200
30 mm	20	20	1200
35 mm	20	20	1200
40 mm	20	20	1200

El procesamiento de imágenes se realiza con el software MATLAB R2020b. Las imágenes son leídas en el espacio de color RGB, que tiene planos de color rojo (R), verde (G) y azul (B). Se calcula dos características estadísticas que permiten conocer la distribución de color en una imagen, como lo son la media y desviación estándar, las cuales se definen en la Tabla 4.7. En este caso,  $i$  indica los planos R, G y B; además, la imagen en la forma  $I(j, k, i)$  indica las intensidades de los píxeles en el plano correspondiente con tamaño  $m \times n$ . Se aplica la descomposición en cada plano RGB, para que el estudio del comportamiento de la curvatura ante los cambios de intensidad en las imágenes esté directamente vinculado con el paso anterior del análisis del espectrómetro.

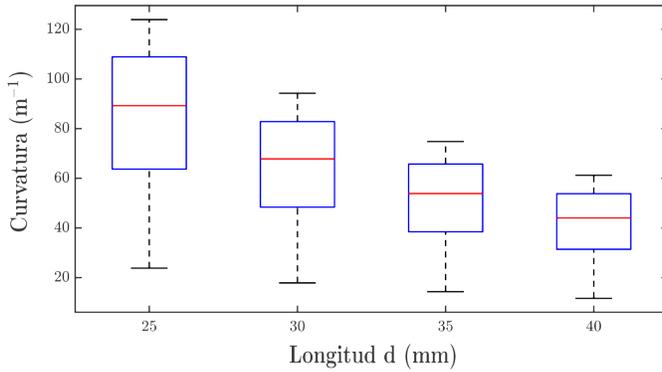
La Figura 4.4 muestra los resultados obtenidos en el análisis de las características estadísticas. Las filas muestran la media y desviación estándar, mientras que las columnas corresponden a la descomposición de las bandas RGB. La banda R corresponde respectivamente a las Figuras 4.4a y 4.4d; la banda G a las Figuras 4.4b y 4.4e, mientras que la banda B se relaciona con las Figuras 4.4c y 4.4f.

Es fácil observar en las Figs. 4.4a y 4.4d el cambio abrupto mientras va aumentando la curvatura de la fibra óptica, para la sección de  $d = 30$  mm. Para las otras distancias, la tendencia de los puntos no es tan significativa en esta banda roja (R), ya que el mayor cambio de amplitud es de aproximadamente  $0.69\mu \pm 0,46\sigma$  para  $d = 25$  mm. Vale la pena notar que todas las distancias en la banda azul (Figs. 4.4c y 4.4f) exhiben una forma gaussiana, que es inadecuada para propósitos de medición de curvatura. Por lo demás, los resultados de la banda verde (G) evidencian que la respuesta de curvatura del dispositivo óptico no es lineal, los valores de la media y la desviación típica disminuyen gradual y significativamente. La respuesta de la banda verde (G) coincide plenamente con



**Figura 4.4.** Estadísticas resultantes de los parámetros RGB para diferentes variaciones de curvatura.

el resultado del análisis con el espectrómetro, debido a que los demás colores como el rojo y el azul no forman parte de la variación del espectro de la luz, tal como se muestra en la Figura 4.2. A medida que aumenta la curvatura hay un decaimiento de la intensidad y una variación del color verde, por lo que el rango dinámico va disminuyendo o aumentando, dependiendo de la dimensión de fibra que se curve. En este caso, se logra un amplio rango dinámico de curvatura con  $d = 25$  mm que disminuye para otras distancias (ver Fig. 4.5).



(a) Gráfico de cajas que representa la distribución de valores de curvatura para diferentes longitudes “ $d$ ”

$d$	Rango de curvatura
25 mm	23.83 – 123.93 $m^{-1}$
30 mm	17.88 – 94.28 $m^{-1}$
35 mm	14.32 – 74.81 $m^{-1}$
40 mm	11.67 – 61.23 $m^{-1}$

(b) Rango dinámico de curvatura para las diferentes longitudes “ $d$ ”

**Figura 4.5.** Rango dinámico de curvatura en el análisis estadístico de la banda G.

Además, se calcula la sensibilidad de curvatura de la SMF a través del análisis estadístico en la banda verde. Por consiguiente, la sensibilidad se expresa como la pendiente de la curva para los resultados de la Figura 4.5, con respecto a la media ( $\Delta\mu/\Delta m^{-1}$ ) y la desviación estándar ( $\Delta\sigma/\Delta m^{-1}$ ); tal que para la distancia  $d = 25$  mm se tienen los siguientes resultados:

$$\Delta\mu/\Delta m^{-1} = \frac{9.01 - 3.51}{123.93 - 23.83} = 0.0549 \quad (4.1)$$

$$\Delta\sigma/\Delta m^{-1} = \frac{6.11 - 3.54}{123.93 - 23.83} = 0.0257$$

Para la longitud de 40 mm la sensibilidad en el cambio en la media es de 0.0912  $\mu/m^{-1}$ ; a medida que la distancia disminuye hasta 25 mm, la sensibilidad se reduce a 0.0549  $\mu/m^{-1}$ . Para las medidas de desviación estándar, la sensibilidad a 40 mm corresponde a 0.0465  $\sigma/m^{-1}$ . Siguiendo el comportamiento anterior, el valor disminuye a 0.0257  $\sigma/m^{-1}$  para  $d = 25$  mm.

Por lo tanto, mediante el procesamiento de imágenes y el análisis estadístico en las bandas de color correspondientes del modelo RGB, se demuestra que el dispositivo de fibra óptica es sensible a las variaciones de curvatura en el espacio de color verde. Además, se determina que la distancia de 25 mm es la ideal para detectar curvatura porque tiene un amplio rango dinámico de detección.

La forma en la que se analiza las imágenes en esta sección, está descrito por el Algoritmo 1.

**Algoritmo 1** Análisis estadístico en las imágenes

**Input** :  $n$ : total de imágenes por posición de curvatura,  $d$ : secciones de curvatura,  $r$ : repeticiones,  $l$ : posiciones de desplazamiento (0.5 – 10 mm).

**Output**:  $I_f$ : estructura de datos  $\bar{x}_\mu$  y  $\bar{x}_\sigma$  por cada banda de color del espacio RGB,  $C$ : matriz de valores de curvatura de cada sección  $d$  (rangos dinámicos).

**for** cada valor  $d$  **do**

Entrar a la carpeta de imágenes de la longitud  $d$

**for** cada repeticion  $r$  **do**

▷ Repetibilidad

**for** total de imagenes  $n$  **do**

Cargar imagenes .tif por posicion de curvatura

Leer imagenes en el espacio RGB y descomponer en cada banda

Calcular  $\mu_n$  y  $\sigma_n$  para cada banda de color

**end**

Estructura de datos  $M$  con los valores de  $\mu_r$  y  $\sigma_r$  por cada banda de color

**end**

**for** cada repeticion  $r$  **do**

▷ Por cada banda de color del espacio RGB

Leer estructura  $M$

**for** cada  $n$  **do**

Calcular los promedios  $\bar{x}_\mu = \frac{1}{n} \sum_{i=1}^r \sum_{j=1}^n \mu_n$  y  $\bar{x}_\sigma = \frac{1}{n} \sum_{i=1}^r \sum_{j=1}^n \sigma_n$

Calcular la curvatura  $C$  con la ecuacion 2.20

**end**

**end**

Estructura de datos  $I_f$  con los valores promediados  $\bar{x}_\mu$  y  $\bar{x}_\sigma$  de las repeticiones

**end**

**return**  $I_f, C$

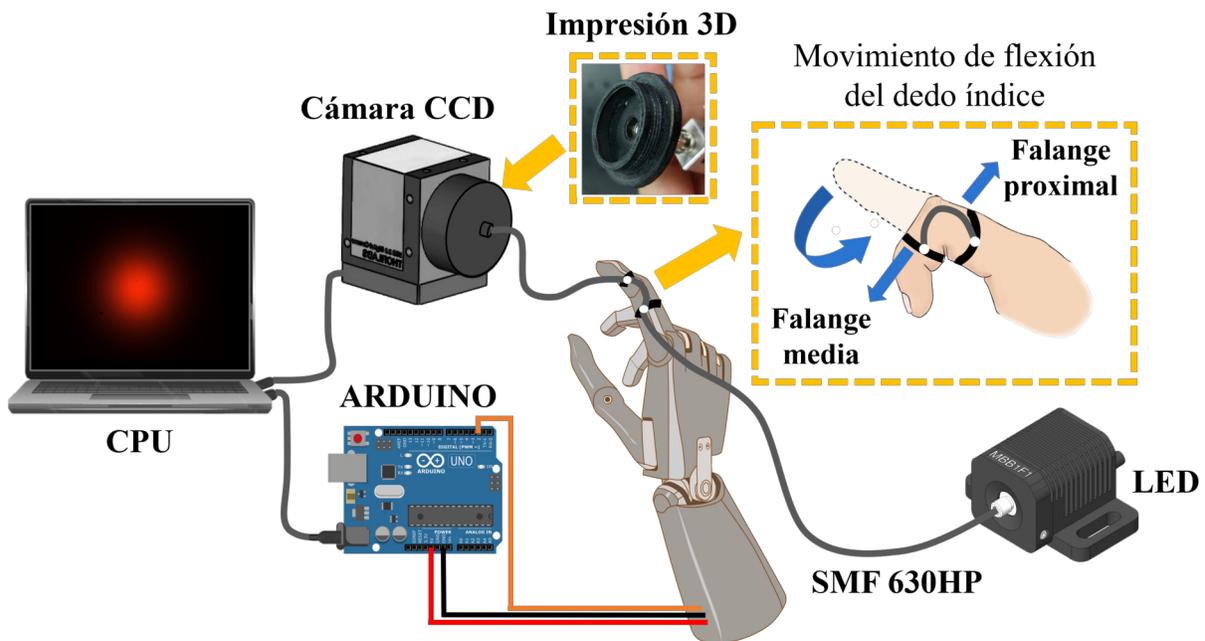
## 4.2. Aplicación del sistema para monitorizar curvatura

Las aplicaciones robóticas permiten la reproducción segura y adecuada de los movimientos humanos mediante un control estricto de seguimiento. El hecho de que un robot pueda ejecutar políticas de movimiento parecidas a las humanas, ha despertado la atención científica en los últimos años. La principal limitación de aplicar trabajos con monitorización robótica, es que las soluciones dependen en gran medida del diseño del robot [17]. No obstante, crear un patrón de estudio que describa un movimiento, facilita las aplicaciones de manipulación remota en servicios de asistencia de rehabilitación palmar y en los controladores de robótica médico-quirúrgica. Es por esta razón que se propone un marco general de adquisición de datos, usando un brazo robótico, ya que provee un ambiente controlado para conocer la respuesta de

curvatura del dedo índice, por medio de un sistema de detección de fibra óptica. Realizar el montaje y adquisición de datos con humanos, agrega un rango de incertidumbre que sesga los resultados, debido a la variabilidad de la biomecánica entre individuos.

Es importante destacar que actualmente solo un pequeño número de sensores de fibra óptica utilizan el procesamiento de imágenes [78]. Por consiguiente, hasta el momento de esta investigación, no existe una base de datos pública que pueda proporcionar información sobre el comportamiento de un dispositivo óptico. Crear una base de datos permite que se expanda el estudio y aplicación de modelos más precisos.

El método planteado en esta sección es una alternativa versátil, que utiliza la descomposición y análisis del color verde en las imágenes del perfil de salida de una fibra óptica, para obtener información sobre la posición angular del movimiento de flexionar del dedo índice. Ahora bien, el dedo índice fue elegido teniendo en cuenta los diversos movimientos de la mano humana que implican su uso.



**Figura 4.6.** Sistema de adquisición de imágenes para monitorizar el ángulo del dedo índice en un sistema robótico.

La Figura 4.6 muestra el esquema propuesto para la adquisición de datos ante la monitorización del ángulo del dedo índice en un sistema robótico. Para completar esta prueba, se agregaron algunos componentes adicionales a la instrumentación:

- *Brazo robótico*: Usa cinco servomotores MG995 para provocar los movimientos de flexión individual del pulgar, índice y medio; flexión conjunta de anular y meñique; aducción y extensión del pulgar y giro de antebrazo (Giro de muñeca). Es necesaria una alimentación de 5V. Tiene las tres articulaciones conocidas como distal interfalángica (DIF), metacarpofalángica (MCF) Y proximal interfalángica (PIF); que representan las articulaciones de los huesos humanos.
- *Etapa de rotación motorizada*: Modelo PRM1Z8 y marca Thorlabs, con un alcance continuo de 360° y una repetibilidad bidireccional de  $\pm 0.1^\circ$ .

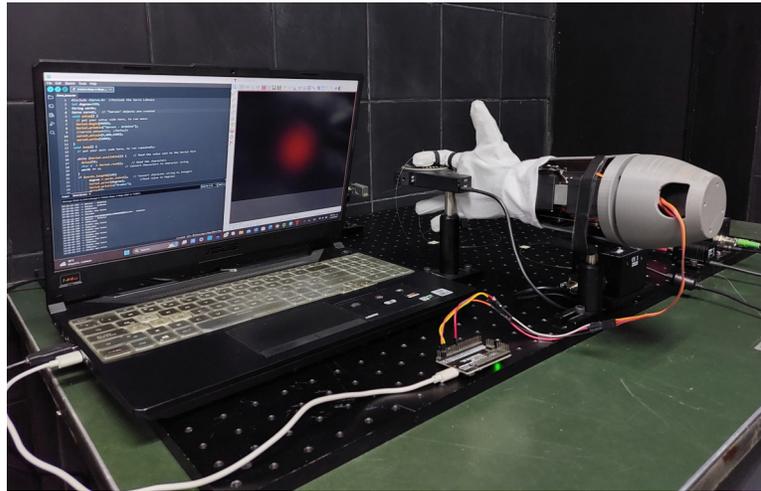
### 4.2.1. Adquisición de datos

Para la adquisición de los datos es importante señalar que el Arduino controla los movimientos del servomotor del montaje, lo que permite cambiar el ángulo de la articulación PIP del dedo índice del brazo robótico, como se muestra en la Figura 4.7c. El alcance del ángulo robótico del dedo índice osciló entre 0° y 85°. Utilizando un polímero curado con UV y velcro, se fija la sección de 25 mm de fibra óptica al dedo índice, entre las secciones de falange proximal y media, con un guante de tela que cubre el brazo robótico (ver Figura 4.7). Con el propósito de garantizar la precisión del movimiento automático del dedo, empleamos un soporte de rotación (PRM1Z8) que monitoriza el ángulo del dedo índice robótico. Las imágenes capturadas en cada movimiento de curvatura que se genera en esta sección de fibra óptica, se utilizarán para obtener información sobre la posición del ángulo del dedo índice.

**Tabla 4.6.** Total de imágenes capturadas con el montaje robótico propuesto y las posiciones de curvatura equivalentes.

Posición angular	Total de imágenes
0°	180
5°	180
10°	180
⋮	⋮
75°	180
80°	180
85°	180

El proceso de adquisición de imágenes se realiza de la siguiente forma: Se ejecuta una rutina previamente establecida en el microcontrolador Arduino, para que ejecute movimientos



(a) Vista completa del montaje



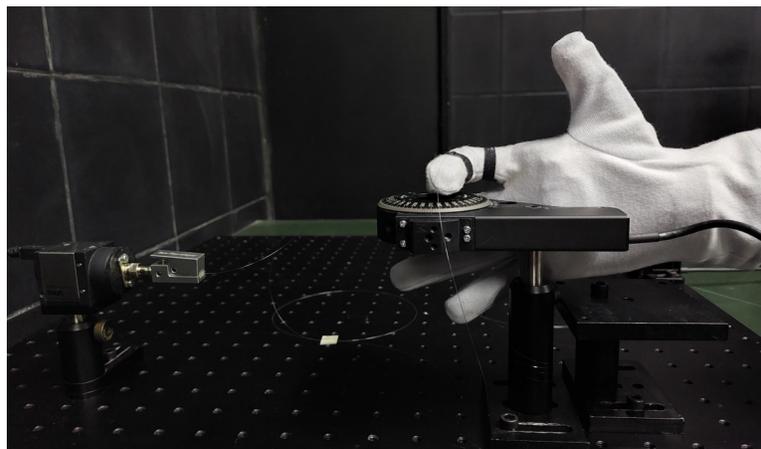
(b) Flexión del dedo índice



(c) Curvatura de SMF



(d) Extensión del dedo índice



(e) Vista lateral del montaje

**Figura 4.7.** Montaje experimental del sistema robótico de adquisición de imágenes.

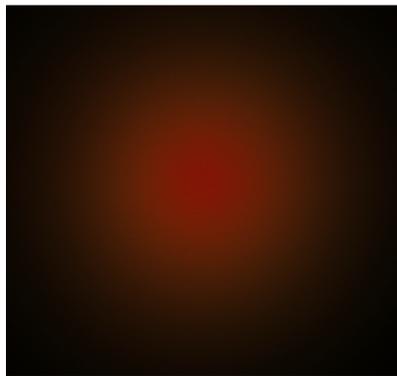
con un incremento de ángulo de  $5^\circ$ , lo que resulta en 18 posiciones robóticas del dedo índice. Así pues, en cada una de las posiciones de  $0^\circ - 85^\circ$ , se capturan 10 imágenes mientras el dedo va en la dirección de avance y el mismo número de imágenes en la dirección de retroceso. Este procedimiento se repite 9 veces, de modo que se guardaron 180 imágenes en cada posición, distribuidas como se muestran en la Tabla 4.6.

En consecuencia, el conjunto de datos se compone por 3240 imágenes grabadas por la cámara CCD con una resolución de  $1280 \times 1024$  píxeles.

### 4.2.2. Procesamiento de imágenes

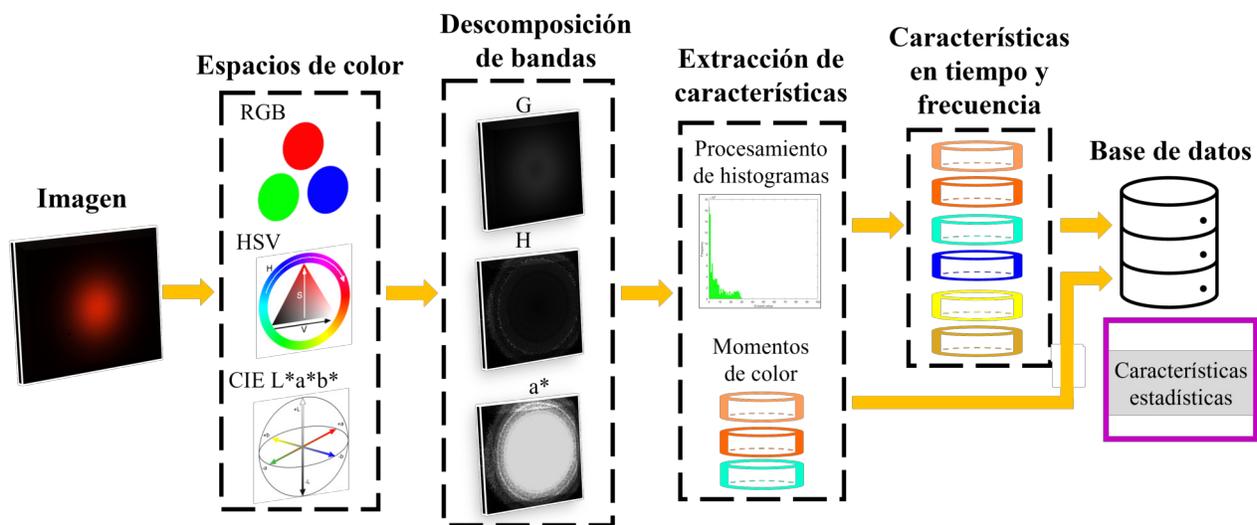
El sistema de adquisición proporciona imágenes en el espacio de color RGB, con un formato conocido por sus siglas en inglés TIFF - Tagged Image File Format (formato de archivo de imágenes con etiquetas); el cual representa el perfil de salida de la fibra óptica con una distribución radial de la intensidad en el centro (ver Figura 4.3). Debido a la alta resolución de las imágenes, el proceso computacional es costoso y aumenta el tiempo de análisis.

Por otra parte, las imágenes obtenidas tienen gran cantidad de información correspondiente al color negro (píxeles de valor cero en intensidad) alrededor del radio de intensidad de la luz. En consecuencia, se busca el píxel de mayor intensidad en la imagen y se aplica una ventana de tamaño  $a \times b$ , cuyo límite va hasta el píxel de menor intensidad diferente de cero. Como resultado, se recorta la imagen de forma automática en la sección que contiene la información más relevante, realizando una especie de “zoom” que elimina las partes del fondo sin importancia. El tamaño final de la imagen resultante es de  $900 \times 950$  píxeles para las tres bandas de color.



**Figura 4.8.** Imagen resultante al aplicar la ventana  $a \times b$  con mayor intensidad.

A continuación, se procede a normalizar los valores de intensidad de la imagen en el rango  $[0, 1]$  dividiéndolos por el valor máximo posible de un píxel, que es 255. La normalización facilita la comparación y el análisis de las características de una imagen al reducir los efectos de iluminación y contraste [8]. Ahora bien, como se demostró y validó anteriormente, la fibra óptica 630HP presenta una variación de color verde a medida que se aplica la curvatura, por lo que el ángulo del dedo índice del brazo robótico puede estimarse utilizando estos cambios de color. Por esta razón se sugiere el esquema de trabajo de la Figura 4.9, que ilustra el procesamiento de imágenes para la formación de la base de datos y la extracción de características. Los siguientes son los pasos del proceso:



*Figura 4.9.* Esquema del procesamiento de imágenes.

### 1. Espacios de color y descomposición de bandas

Las imágenes se analizan en los tres espacios de color RGB, HSV y CIEL\*a\*b\*. Luego, para extraer la información concerniente al color verde, se descompone cada espacio de color en una sola banda. Del espacio de color RGB se extrae el plano G que contiene el valor de la intensidad del color verde; de HSV el plano H proporciona el tono de la imagen como un valor angular, donde  $120^\circ$  es el valor del ángulo cromático del color verde. En cuanto a CIEL\*a\*b\*, se extrae el canal a\* (capa de cromaticidad) debido a que valores altamente negativos representan el color verde a lo largo de este eje, el cual toma valores en el rango de  $[-100, 100]$  o  $[-128, 127]$ .

### 2. Extracción de características

La extracción directa de atributos de las bandas G, H y a\* proporciona información relacionada con la posición de la curvatura. Esto tiene un impacto significativo en el

ángulo de detección final del dedo índice robótico. En este caso, no solo se utilizan las imágenes de cada banda de color, sino que también se examinan los histogramas.

- *Procesamiento de histogramas*: La distribución de probabilidad de las imágenes en cada plano de color, proporciona información sustancial que se extraen de los histogramas. Se emplea dos métodos conocidos como, ecualización de histogramas y ecualización adaptativa limitada por contraste (CLAHE). Mediante estos algoritmos es posible resaltar, a través de la modificación del contraste, la información de cada plano de color.

Por lo tanto, se lee el histograma base, el histograma ecualizado y el histograma CLAHE para cada imagen, lo que da como resultado un vector de datos de tamaño  $1 \times 255$ .

- *Imágenes*: Las características de imagen conocida como *momentos de color* son usadas para comparar dos imágenes. La media, la desviación estándar y la asimetría son los tres momentos de color principales, por lo que se calcula para cada plano de color G, H y a\*.

La Tabla 4.7 muestra la definición de estas características, donde  $i$  indica el plano de estudio específico y  $I(j, k, i)$  indica la intensidad de los píxeles del plano correspondiente con tamaño  $m \times n$ .

**Tabla 4.7.** Características de color

No.	Dimensión	Definición
20	Media	$\mu_i = \frac{1}{m*n} \sum_{j=1}^m \sum_{k=1}^n I(j, k, i)$
21	Desviación estándar	$\sigma_i = \sqrt{\frac{1}{m*n} \sum_{j=1}^m \sum_{k=1}^n (I(j, k, i) - \mu_i)^2}$
22	Asimetría	$Sk_i = \sqrt[3]{\frac{1}{m*n} \sum_{j=1}^m \sum_{k=1}^n (I(j, k, i) - \mu_i)^3}$

- *Características estadísticas*: Se caracterizan por medir cambios en el comportamiento de una señal no estacionaria en el tiempo o la frecuencia. En este trabajo se calcula 16 características representativas en el dominio del tiempo (Tabla 4.8) y 3 en el dominio tiempo-frecuencia (Tabla 4.9). Por consiguiente, a los histogramas anteriormente mencionados, se le calcula el total de estas 19 características.

A continuación, se muestran las fórmulas matemáticas para las características estadísticas del dominio del tiempo y frecuencia; donde  $\mathbf{y}$  es el vector resultante de un histograma,  $y_i$  es cada punto de frecuencia para  $i = 1, 2, \dots, N$ ;  $N$  es el número de puntos equivalente a 256.

**Tabla 4.8.** Características en el dominio del tiempo

No.	Dimensión	Definición
1	Raíz cuadrática media	$Y_{rms} = \left[ \frac{1}{N} \sum_{i=1}^N (y_i)^2 \right]^{1/2}$
2	Raíz media cuadrática	$Y_{smr} = \left[ \frac{1}{N} \sum_{i=1}^N  y_i ^{1/2} \right]^2$
3	Máximo	$\max(\mathbf{y})$
4	Varianza	$Y_{\sigma^2} = \frac{1}{N-1} \sum_{i=1}^N  y_i - Y_{\mu} ^2$
5	Desviación estándar	$Y_{\sigma} = \sqrt{Y_{\sigma^2}}$
6	Asimetría o sesgo	$Y_{sk} = \frac{1}{N-1} \frac{\sum_{i=1}^N (y_i - Y_{\mu})^3}{Y_{\sigma}^3}$
7	Curtosis	$Y_{ku} = \frac{1}{N-1} \frac{\sum_{i=1}^N (y_i - Y_{\mu})^4}{Y_{\sigma}^4}$
8	5to momento estadístico	$Y_{5m} = \frac{1}{N-1} \frac{\sum_{i=1}^N (y_i - Y_{\mu})^5}{Y_{\sigma}^5}$
9	6to momento estadístico	$Y_{6m} = \frac{1}{N-1} \frac{\sum_{i=1}^N (y_i - Y_{\mu})^6}{Y_{\sigma}^6}$
10	Factor de forma con RMS	$Y_{SFrms} = \frac{Y_{rms}}{\frac{1}{N} \sum_{i=1}^N  y_i }$
11	Factor de forma con SMR	$Y_{SFsmr} = \frac{Y_{smr}}{\frac{1}{N} \sum_{i=1}^N  y_i }$
12	Factor de cresta	$Y_{cf} = \frac{\max( \mathbf{y} )}{Y_{rms}}$
13	Factor de impulso	$Y_{if} = \frac{\max( \mathbf{y} )}{\frac{1}{N} \sum_{i=1}^N  y_i }$
14	Factor de latitud	$Y_{lf} = \frac{\max( \mathbf{y} )}{Y_{smr}}$
15	Valor medio absoluto	$Y_{mav} = \frac{1}{N-1} \sum_{i=1}^N  y_{i+1} - y_i $
16	Desviación media absoluta	$Y_{mad} = \frac{1}{N} \sum_{i=1}^N  y_i - \mu $

**Tabla 4.9.** Características en el dominio del tiempo-frecuencia

No.	Dimensión	Definición
17	Homogeneidad	$Y_{homo} = \frac{1}{N-1} \sum_{i=1}^N \frac{1}{1+ y(i+1)-y(i) }$
18	Entropía de Renyi normalizada	$Y_{nre} = \frac{1}{1-\nu} \log_2 \sum_{i=1}^N \left( \frac{y(i)}{NY_{\mu}} \right)^{\nu}, \nu = 3$
19	Concentración de energía	$Y_{ec} = \left( \sum_{i=1}^N \sqrt{ y(i) } \right)^2$

A partir del cálculo de las características, se procede a construir la base de datos con esta información. En la siguiente sección se explica a detalles la organización y etiquetado de la misma. La forma en la que se hace el procesamiento de imágenes en esta sección, está descrito por el Algoritmo 2.

---

**Algoritmo 2** Procesamiento de las imágenes.

---

**Input** :  $n$ : total de imágenes por posición de curvatura,  $p$ : posición angular de curvatura,  $r$ : repeticiones.

**Output:**  $I_{(n,p,r)}$ : estructura de datos

**for** cada valor  $r$  **do**

▷ Repetibilidad

**for** cada posición  $p$  **do**

**for** cada imagen  $n$  **do**

            Entrar a las carpetas por posiciones

            Cargar imagen .tif

            Fijar ventana  $a \times b$

            Normalizar imagen

            Leer imagen RGB y descomponer en la banda G

            Leer imagen HSV y descomponer en la banda H

            Leer imagen CIEL\*a\*b\* y descomponer en la banda a\*

▷ Cada plano G-H-a\*

            ▷ Calcular características de color 4.7

            ▷ Leer histogramas y calcular características de tiempo y frecuencia 4.8 y 4.9

            Estructura de datos  $I_{(n,p,r)}$  con las características por espacio de color

**end**

**end**

**end**

**return**  $I_{(n,p,r)}$

---

### 4.2.3. Base de datos

En este trabajo se propone la creación de una base de datos estadísticos a partir del cambio de intensidad del color verde en las imágenes. Luego, usar estos datos para conocer el ángulo de curvatura a través de algoritmos de aprendizaje automático. Todo esto, como una primera aproximación en este tipo de investigación y aplicación.

El proceso para construir la base de datos sigue paso a paso el esquema de la Figura 4.9. En ella, a partir de la imagen de entrada, se analiza la banda que representa el color verde de cada espacio de color y, a continuación, se realizan dos análisis. El primer análisis consiste en la extracción de 16 características de dominio del tiempo y 3 de dominio tiempo-frecuencia a partir de sus histogramas. El segundo análisis consiste en calcular tres momentos de color en las imágenes de cada banda que corresponde al color verde. Este proceso se explicó a detalle en la sección anterior. A continuación, se procede a combinar las características por imagen en un vector de la siguiente forma:

- 19 Características de tiempo y frecuencia del histograma.
- 19 Características de tiempo y frecuencia del histograma ecualizado.
- 19 Características de tiempo y frecuencia del histograma CLAHE.
- 3 Características de color de la imagen.

Como resultado, cada banda (G-H-a\*) proporciona 60 elementos en su espacio de color, lo que deriva en un vector final de 180 dimensiones. La distribución de los índices asignados para las características en la base de datos, se muestran en las Tablas 4.10, 4.11 y 4.12.

**Tabla 4.10.** Descripción de las diferentes características extraídas de la banda G

Índice	Descripción	Tipo de análisis
1-16	Dominio del tiempo	Histograma
17-19	Dominio del tiempo y frecuencia	Histograma
20-35	Dominio del tiempo	Histograma ecualizado
36-38	Dominio del tiempo y frecuencia	Histograma ecualizado
39-54	Dominio del tiempo	Histograma CLAHE
55-57	Dominio del tiempo y frecuencia	Histograma CLAHE
58-60	Momentos de color	Imagen

**Tabla 4.11.** Descripción de las diferentes características extraídas de la banda H

Índice	Descripción	Tipo de análisis
61-76	Dominio del tiempo	Histograma
77-79	Dominio del tiempo y frecuencia	Histograma
80-95	Dominio del tiempo	Histograma ecualizado
96-98	Dominio del tiempo y frecuencia	Histograma ecualizado
99-114	Dominio del tiempo	Histograma CLAHE
115-117	Dominio del tiempo y frecuencia	Histograma CLAHE
118-120	Momentos de color	Imagen

**Tabla 4.12.** Descripción de las diferentes características extraídas de la banda a\*

Índice	Descripción	Tipo de análisis
121-136	Dominio del tiempo	Histograma
137-139	Dominio del tiempo y frecuencia	Histograma
140-155	Dominio del tiempo	Histograma ecualizado
156-158	Dominio del tiempo y frecuencia	Histograma ecualizado
159-174	Dominio del tiempo	Histograma CLAHE
175-177	Dominio del tiempo y frecuencia	Histograma CLAHE
178-180	Momentos de color	Imagen

Finalmente, para crear el conjunto de datos estadísticos, las características mencionadas anteriormente se extrajeron de las 3240 imágenes capturadas del movimiento del dedo índice del brazo robótico.

Puesto que cada imagen corresponde a una de las 18 posiciones de curvatura que se muestran en la Tabla 4.6, cada vector de características se etiqueta con su posición correspondiente equivalente a los números 1 al 18. De esta manera, se agrega una columna adicional a la base de datos que contiene el número de la clase (posición angular) a la que pertenece. Cada clase tiene un total de 180 muestras (vector de características), lo que corresponde a una base de datos balanceada, con una dimensión de 3240 muestras y 181 columnas de características, incluyendo la columna de etiquetas por clase.

Los pasos a seguir para formar la base de datos descrita en esta sección, se explica en el Algoritmo 3.

---

**Algoritmo 3** Construcción de la base de datos.

---

**Input** :  $I_{(n,p,r)}$ : estructura de datos,  $n$ : total de imágenes por posición de curvatura,  $p$ : posición angular de curvatura,  $r$ : repeticiones.

**Output**:  $M$ : base de datos ( $3240 \times 181$ )

La estructura  $I_{(n,p,r)}$  proviene del algoritmo 2

Inicializar  $Class \rightarrow (3240 \times 1)$ , vector de las etiquetas por posición angular de curvatura (1–18)

Inicializar  $V \rightarrow (180 \times 1)$ , vector de las características

**for** cada valor  $p$  **do**

**for** cada valor  $n$  **do**

        | Asignar la etiqueta  $p$  en  $n$  posiciones de  $Class$

**end**

$n + 1$

**for** cada valor  $r$  **do**

**for** cada valor  $n$  **do**

            | Leer estructura  $I_{(n,p,r)}$

            |  $\triangleright$  Extraer características de tiempo y frecuencia del histograma

            |  $\triangleright$  Extraer características de tiempo y frecuencia del histograma ecualizado

            |  $\triangleright$  Extraer características de tiempo y frecuencia del histograma CLAHE

            |  $\triangleright$  Extraer características de los momentos de color

$\triangleright$  Cada plano G-H-a\*

$\triangleright$  Vector final

            | Unir las características G-H-a\* en un solo vector  $V$  ( $180 \times 1$ )

            | Asignar  $V$  a  $M$  siguiendo el orden de la posición angular

**end**

**end**

**end**

Asignar  $Class$  a la última columna de  $M$

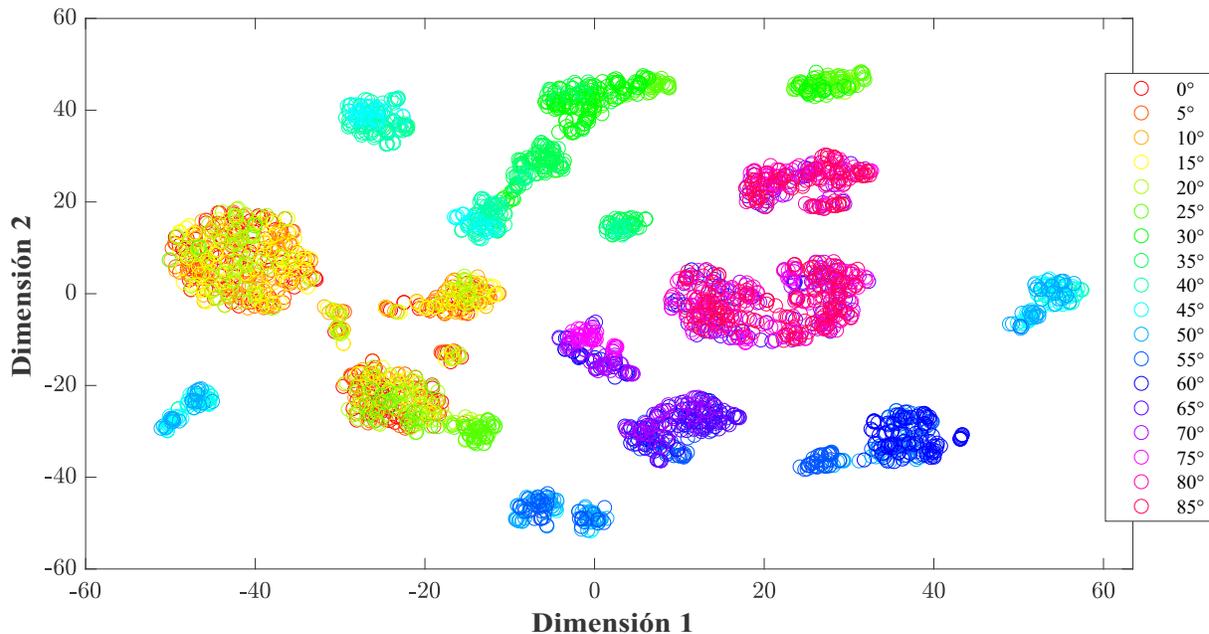
**return**  $M$

---

#### 4.2.4. Visualización de los datos

Para visualizar la distribución de los datos se utiliza el método estadístico *t-Distributed Stochastic Neighbor Embedding* (t-SNE). Es una técnica no lineal de reducción de la dimensionalidad que transforma datos de alta dimensión, de manera que sean visualizados en un espacio de dimensiones reducidas. Específicamente, asigna a cada objeto de alta dimensión un punto bidimensional o tridimensional, de manera que objetos similares sean representados por puntos cercanos, mientras que objetos disímiles sean representados por puntos distantes con una probabilidad elevada [79].

El gráfico t-SNE de la base de datos, corresponde a la Figura 4.10 y muestra las nubes de puntos de cada clase (posición angular). Se observa que los puntos que corresponden a las posiciones en el rango de  $0^\circ - 15^\circ$  y de  $70^\circ - 85^\circ$  están mezclados, de forma tal que no hay puntos distantes que logren diferenciar satisfactoriamente una clase de otra.

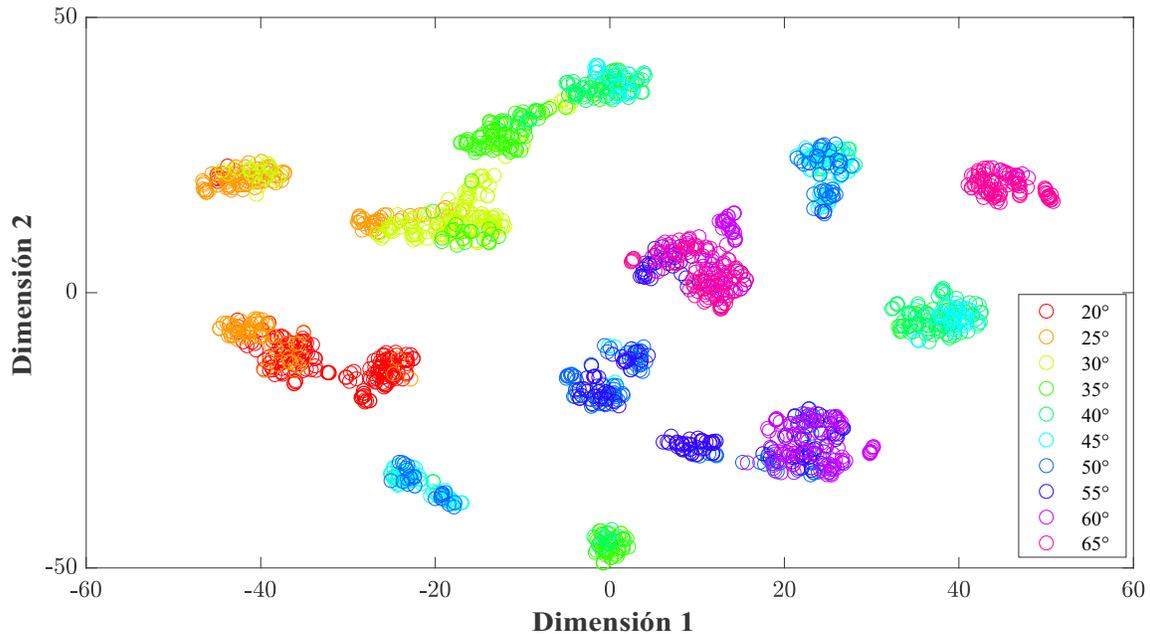


**Figura 4.10.** Proyección t-SNE de los datos en el rango de  $0^\circ - 85^\circ$ .

Este comportamiento se atribuye, en parte, a la estructura del brazo robótico que se construye mediante impresión 3D. El roce entre las piezas al realizar movimientos contribuye de cierta manera a la dificultad para lograr un movimiento natural. Además, al observar la respuesta del espectrómetro para los valores de mínima curvatura (ver Figura 4.2), se nota que la intensidad inicial corresponde a la longitud de onda del color amarillo (550 nm). A medida que la curvatura aumenta, se produce una transición a la variación en la longitud de onda correspondiente al color verde. La metodología propuesta para el análisis de imágenes se centra en el espacio de color verde, sin tener en cuenta la influencia del color amarillo en las primeras posiciones de curvatura.

Por otra parte, es importante señalar que el rango de movilidad digital de la articulación PIF en el plano sagital (flexión-extensión), es limitado para los temas de aplicación en manipulación remota de controladores robóticos médico-quirúrgicos o monitorización robótica. Un pequeño grado de flexión no es un movimiento óptimo o natural en robótica; incluso, un grado máximo de flexión constituye un paso de poca utilidad, si se requiere desarrollar una tarea. Debido a la similitud de los datos, se decide limitar la base de datos para un rango

de posiciones de curvatura de  $20^\circ$  -  $65^\circ$  al momento de aplicar las técnicas de aprendizaje automático. Sin embargo, se sabe que algunos métodos más robustos pueden llegar a clasificar estos datos. Como resultado, disminuye a 10 el número de posiciones para la detección. El gráfico t-SNE de esta selección de datos corresponde a la Figura 4.11.



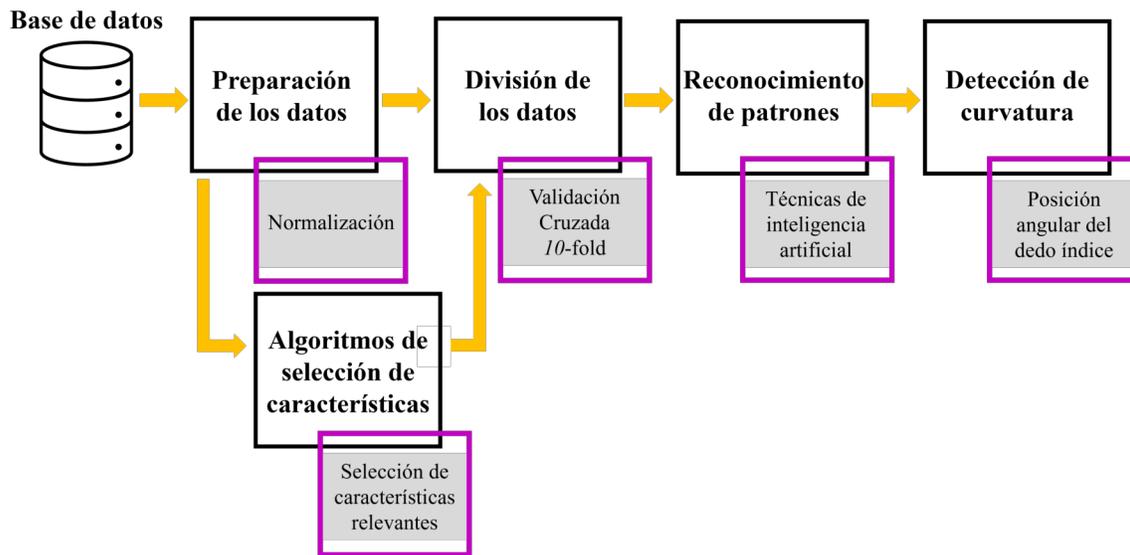
**Figura 4.11.** Proyección t-SNE de los datos en el rango de  $20^\circ$  -  $65^\circ$ .

#### 4.2.5. Diagrama propuesto de detección de curvatura

En esta sección se discute los detalles de la aplicación de técnicas de aprendizaje automático para detectar la posición angular de curvatura del dedo índice robótico, a través de la base de datos estadísticos descrita anteriormente. El esquema de la Figura 4.12 presenta el diagrama de flujo del enfoque propuesto. Los cuatro pasos básicos que hacen posible el modelo de detección conforme a la evaluación de diversos algoritmos de aprendizaje supervisado, son los siguientes:

##### 1. Preparación de los datos

En esta etapa, se normalizan las variables de la base de datos con respecto a su valor máximo, asegurando así que todas las características tengan un impacto similar en el análisis debido a que sus valores tendrán un peso uniforme. Por lo tanto, caen en el mismo rango relativo de  $[0, 1]$ , lo que facilita la comparación y el procesamiento de datos y mejora la interpretación de los resultados.



**Figura 4.12.** Diagrama de flujo del desarrollo y aplicación de aprendizaje automático para la detección de curvatura.

## 2. Algoritmos de selección de características

La siguiente sección consiste en la selección de características que aportan la información significativa en el análisis de la base de datos. El objetivo principal de este paso es reducir la alta dimensionalidad y mejorar la capacidad de diferenciación entre las clases del conjunto de datos, buscando así aumentar la precisión predictiva de los algoritmos de clasificación. Estos algoritmos de selección de características proporcionan un nuevo conjunto de datos.

## 3. División de los datos

La base de datos es dividida en los conjuntos de entrenamiento y prueba por medio de la técnica de validación K-fold. Cada división de conjuntos asegura la misma dimensión por cada grupo.

## 4. Reconocimiento de patrones

En este punto se realiza una identificación automática de patrones en los datos mediante técnicas de inteligencia artificial. En este trabajo se compara y evalúa cinco algoritmos de clasificación de aprendizaje supervisado para detectar la posición angular en el dedo índice del brazo robótico. Tales algoritmos son análisis discriminante (DA), bayesiano ingenuo (NB), árbol de decisión (DT), máquinas de soporte vectorial (SVM) y K-vecinos más próximos (KNN). Se definen ciertas características para cada modelo, las cuales se describen a continuación:

- Análisis discriminante (DA): Se entrena dos modelos usando una superficie discriminante lineal (LDA) y otro utilizando una superficie discriminante cuadrática (QDA).
- Bayesiano ingenuo (NB): Dos tipos de distribuciones son usadas en este modelo de clasificación, distribución normal (gaussiana) y kernel.
- Árbol de decisión (DT): Se evalúa tres pruebas estadísticas que determinan cómo dividir los nodos usando el mejor predictor. Estos se conocen como *Standard CART*, *Curvature test* e *Interaction test*.
- Máquinas de soporte vectorial (SVM): Se usa dos funciones tipo kernel, el gaussiano y el polinómico orden dos. Ambos con el parámetro de optimización mínimo secuencial y una tolerancia de la brecha de viabilidad de 0.01, para comprobar la convergencia de la optimización.
- $K$  vecinos más próximos (KNN): Para este clasificador se emplea dos métricas de distancia; la Euclidiana (ecuación 3.5) y Minkowski (ecuación 4.2).

$$d_M(x, y) = \left[ \sum_{i=1}^n (|x_i - y_i|)^p \right]^{\frac{1}{p}} \quad (4.2)$$

Para esta fórmula  $n$  representa el número de características,  $x_i$  y  $y_i$  son los valores de las características en los puntos a comparar, y  $p$  es un parámetro que determina el orden de la distancia (por ejemplo, cuando  $p = 1$  se tiene la distancia de Manhattan; cuando  $p = 2$  la distancia euclidiana; cuando  $p = \infty$  la distancia de Chebyshev).

La manera en la que se desarrolla estos pasos se divide en tres pruebas que se explican a continuación:

- *Prueba 1*: Se utiliza la base de datos que incluye todas las posiciones de curvatura obtenidas por el sistema robótico ( $0^\circ - 85^\circ$ ), la cual tiene un tamaño de 3240 observaciones  $\times$  180 características. Luego se normaliza los datos y se divide en los conjuntos de entrenamiento y prueba con la técnica K-fold, donde  $k = 10$ . Por último, se entrenan los modelos de clasificación y se analiza la exactitud de detección con los resultados.
- *Prueba 2*: Se utiliza la base de datos limitada a las posiciones de curvatura de  $20^\circ - 65^\circ$  que tiene un tamaño de 1620 observaciones  $\times$  180 características. Luego de normalizar y realizar la división K-fold en los conjuntos de entrenamiento y prueba; se entrenan los modelos de clasificación y se analiza la exactitud de los resultados.

- *Prueba 3*: A partir de la base de datos limitada que se usa en la Prueba 2 y de normalizar los datos, en esta prueba se usa los algoritmos de selección de características. Después de la creación de un nuevo espacio de características reducido, se aplica la división K-fold y se procede con el entrenamiento y prueba de las cinco técnicas de aprendizaje automático propuestas.

Los resultados obtenidos en cada una de estas pruebas, se muestran y discuten en el siguiente capítulo.

## CAPÍTULO 5

---

### Resultados

---

---

<b>5.1</b>	<b>Análisis de resultados</b>	<b>73</b>
5.1.1	Prueba 1	73
5.1.2	Prueba 2	75
5.1.3	Prueba 3	79

---

## 5.1. Análisis de resultados

Todos los experimentos numéricos se realizaron en Matlab R2020b ejecutándose en una ASUS TUF Gaming F15 con procesador Intel(R) Core(TM) i5-10300H CPU @ 2.50GHz, con 16GB RAM, y utilizando Windows 11-64 bit. La evaluación de las tres pruebas propuestas en la metodología, se definen a continuación:

### 5.1.1. Prueba 1

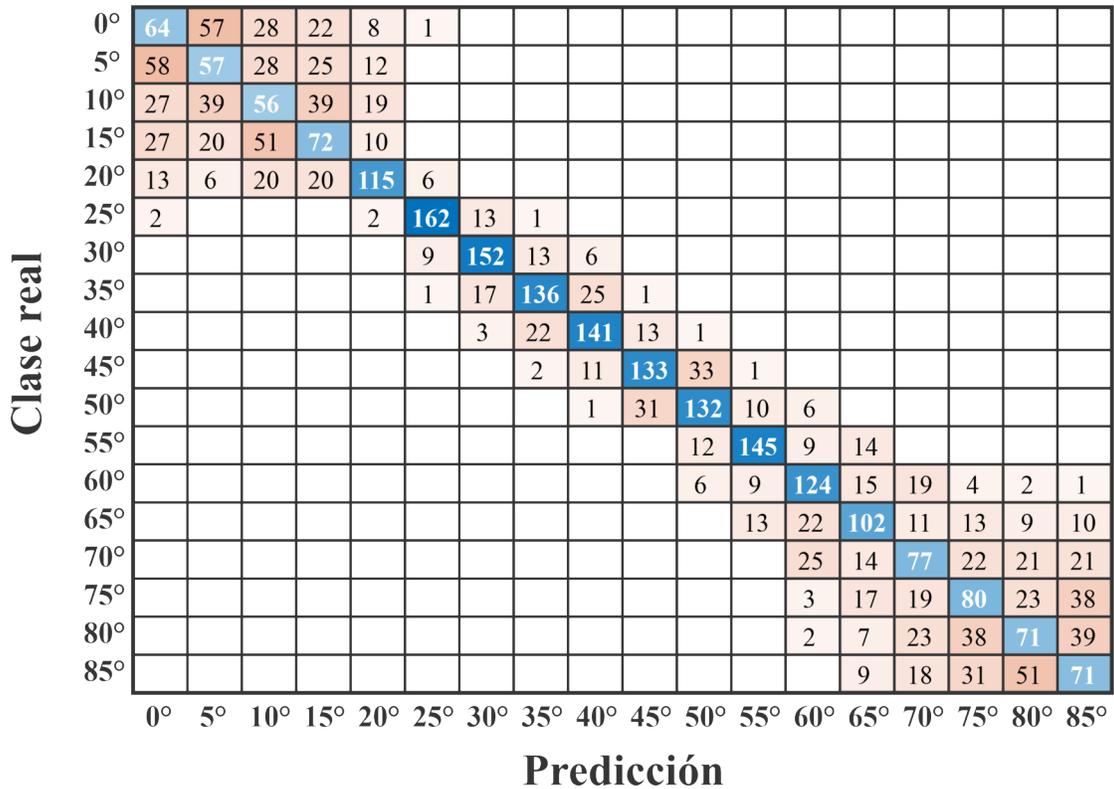
La base de datos utilizada consta de 3240 muestras (*filas*) con 180 características (*columnas*) estadísticas. Las clases corresponden a 18 posiciones de curvatura que van desde  $0^\circ$  hasta  $85^\circ$ , incrementando en pasos de  $5^\circ$ . Cabe destacar que cada una de estas posiciones cuenta con un conjunto de 180 observaciones, lo que indica que la base de datos es balanceada. Tanto el entrenamiento como la prueba de los modelos de clasificación de aprendizaje automático, se hacen de forma aleatoria 10 veces mediante una validación cruzada; de los cuales nueve subconjuntos se adoptan como conjunto de entrenamiento, y el subconjunto restante se toma como conjunto de validación. Cada uno de los 10 conjuntos tiene la misma proporción, 2916 vectores de características para entrenar y 324 vectores para validar. Cada clasificador genera una estimación de respuesta para cada observación al emplear el modelo entrenado sin considerar esa observación, es decir, el modelo se entrena sin tener en cuenta el bloque completo de pruebas. Luego de realizar el entrenamiento de los modelos de aprendizaje supervisado, se obtiene los resultados expuestos en la Tabla 5.1. El tiempo calculado y expuesto en esta sección de resultados es medido durante el proceso de entrenamiento y prueba de los algoritmos de aprendizaje automático.

El promedio general de la exactitud al clasificar correctamente una observación externa con los algoritmos propuestos es de 49.87%. De forma individual, la técnica de árbol de decisión obtiene 58.33% en 4.840 seg. Este modelo usa la prueba estadística “*Interaction test*”, la cual evalúa la hipótesis nula de que no existe interacción entre un par de variables predictoras y la variable de respuesta. No obstante, a pesar de que este análisis es el primero que se hace con esta base de datos, el resultado no representa un valor de exactitud significativa. Esto se debe a que la disposición de los datos (Ver Figura 4.10) afecta la identificación y clasificación de las diferentes posiciones de curvatura, ya que en términos generales no supera el 50% de precisión.

La Figura 5.1 muestra la matriz de confusión del modelo de árbol de decisión, que

**Tabla 5.1.** Comparación del rendimiento de los algoritmos de aprendizaje automático.

Algoritmos (AI)	Parámetros y Función	Exactitud [%]	Tiempo [seg]
DA	Discriminante Lineal	46.35	1.185
	Discriminante Lineal	46.54	1.184
	Discriminante Cuadrático	48.98	1.818
NB	Distribución - Gaussiana	41.48	2.762
	Distribución - Kernel	45.64	97
DT	Prueba - Standard CART	58.05	4.678
	Prueba - Curvature test	58.24	5.189
	Prueba - Interaction test	<b>58.33</b>	<b>4.840</b>
SVM	Kernel Polinómico (d=2)	53.30	19.959
	Kernel Gaussiano	50	20.303
KNN	Distancia Euclidiana (K=5)	46.23	1.610
	Distancia Minkowski (K=16)	45.40	1.756
<b>Promedio</b>		49.87	



**Figura 5.1.** Matriz de confusión del modelo DT.

destaca en la identificación de curvatura en esta prueba. El eje  $\boldsymbol{x}$  corresponde a la predicción por clase, mientras que el eje  $\boldsymbol{y}$  representa la clasificación real y los elementos correctamente clasificados se sitúan en la diagonal principal. Aquí la cantidad de muestras clasificadas correctamente corresponde aproximadamente al 34.2% para las clases equivalentes a las posiciones en el rango de  $0^\circ - 15^\circ$ , para el rango de posición angular de  $70^\circ - 85^\circ$  corresponde al 40.36% de precisión en la detección de la posición real. Las demás muestras se clasificaron incorrectamente como otra posición superior a la real.

Esta prueba revela la complejidad de la base de datos que hemos construido, destacando la necesidad de utilizar técnicas más robustas como las redes convolucionales para obtener resultados satisfactorios con las imágenes capturadas. Sin embargo, se debe tener en cuenta que el uso de redes convolucionales puede implicar desventajas computacionales, incluida una mayor demanda de recursos y una complejidad de entrenamiento potencialmente superior en comparación con algunos algoritmos clásicos de machine learning. Sin embargo, se plantean las pruebas descritas a continuación, en la que se trabaja con datos más limpios o que cuentan con una mejor separación entre clases, de manera tal que afecte positivamente el proceso de entrenamiento de los modelos de aprendizaje automático.

### 5.1.2. Prueba 2

En esta prueba se limita la base de datos para un rango de posiciones de curvatura de  $(20 - 65)^\circ$ , debido a la similitud de los datos para las posiciones que tienen un ángulo pequeño, así como las limitantes cinemáticas del dedo humano. Por ende, disminuye el número de posiciones para su clasificación a 10 y el gráfico t-SNE de esta selección de datos corresponde a la Figura 4.11. El entrenamiento y prueba de los modelos de aprendizaje automático también se hacen de forma aleatoria 10 veces mediante una validación cruzada; cada uno de los conjuntos tiene la misma proporción de 1620 vectores de características para entrenar y 180 vectores para validar. Los modelos de clasificación estiman una respuesta por cada observación utilizando el modelo entrenado sin esa observación. Los resultados de tiempo mostrados en la Tabla 5.2, son medidos en el proceso de entrenamiento y prueba de los algoritmos de aprendizaje automático.

El resultado de los modelos en esta prueba tiene una exactitud promedio para la detección del movimiento de curvatura de 74.01%. Tal como sucede en la sección 5.1.1, la técnica de clasificación que tiene un mejor resultado es el árbol de decisión con una exactitud de 82.66% en un tiempo de 1.836 seg (ver la Tabla 5.2). En la Figura 5.2 podemos observar la matriz de confusión obtenida para este modelo, en la cual se detalla que para cada posición

angular la mayoría de las muestras se identifican de manera precisa. Sin embargo, la posición que tiene menor cantidad de observaciones identificadas correctamente, equivalente al 74 % de los datos, corresponde a 50°. En este caso, el modelo de árbol de decisión predice erróneamente el 18 % de las muestras como pertenecientes a la posición de 45°.

**Tabla 5.2.** Comparación del rendimiento de los algoritmos de aprendizaje automático.

Algoritmos (AI)	Parámetros y Función	Exactitud [%]	Tiempo [seg]
DA	Discriminante Lineal	71.22	1.122
	Discriminante Lineal	72.27	1.013
	Discriminante Cuadrático	74.05	1.433
NB	Distribución - Gaussiana	63.50	1.918
	Distribución - Kernel	66.27	46.123
DT	Prueba - Standard CART	81.50	2.025
	Prueba - Curvature test	80.50	1.766
	Prueba - Interaction test	<b>82.66</b>	<b>1.836</b>
SVM	Kernel Polinómico (d=2)	78.22	6.259
	Kernel Gaussiano	75.16	5.732
KNN	Distancia Euclidiana (K=9)	71.27	0.911
	Distancia Minkowski (K=14)	71.55	1.080
<b>Promedio</b>		74.01	

Cabe resaltar que los resultados en esta prueba aumentan aproximadamente 20 % en comparación con los de la prueba realizada en la sección 5.1.1 (ver la Tabla 5.1); no solo para la técnica de árbol de decisión, sino para bayesiano ingenuo y análisis discriminante. Por ende, con análisis discriminante se tiene una exactitud al detectar curvatura por encima del 70 %; sin embargo, su principal limitación es que es adecuado para datos que tienen una distribución gaussiana unimodal por clase y no es el caso en este trabajo. Esta afirmación viene del análisis de estudiar estadísticamente solo el comportamiento en el cambio de amplitud del color verde, que se muestra en la Figura 4.4. La clasificación con los modelos de máquinas de soporte vectorial y K vecinos próximos, corresponde a una exactitud del 78.22 % y 71.27 % respectivamente. Por lo tanto, se demuestra que ante este escenario, SVM y KNN tienen un resultado y mejora significativa para identificar la posición angular de curvatura externa.

En la Figura 5.3, se presentan los resultados óptimos obtenidos al evaluar los modelos propuestos en las Pruebas 1 y 2 utilizando el conjunto de datos de prueba. Cada uno de los algoritmos de aprendizaje automático, se entrenó 50 veces usando diferentes parámetros y

20°	178	2								
25°	7	164	9							
30°		8	158	12	2					
35°			18	138	23	1				
40°			4	16	149	9	2			
45°				2	13	138	26	1		
50°					1	34	134	7	4	
55°							17	137	11	15
60°							5	12	147	16
65°								10	25	145
	20°	25°	30°	35°	40°	45°	50°	55°	60°	65°

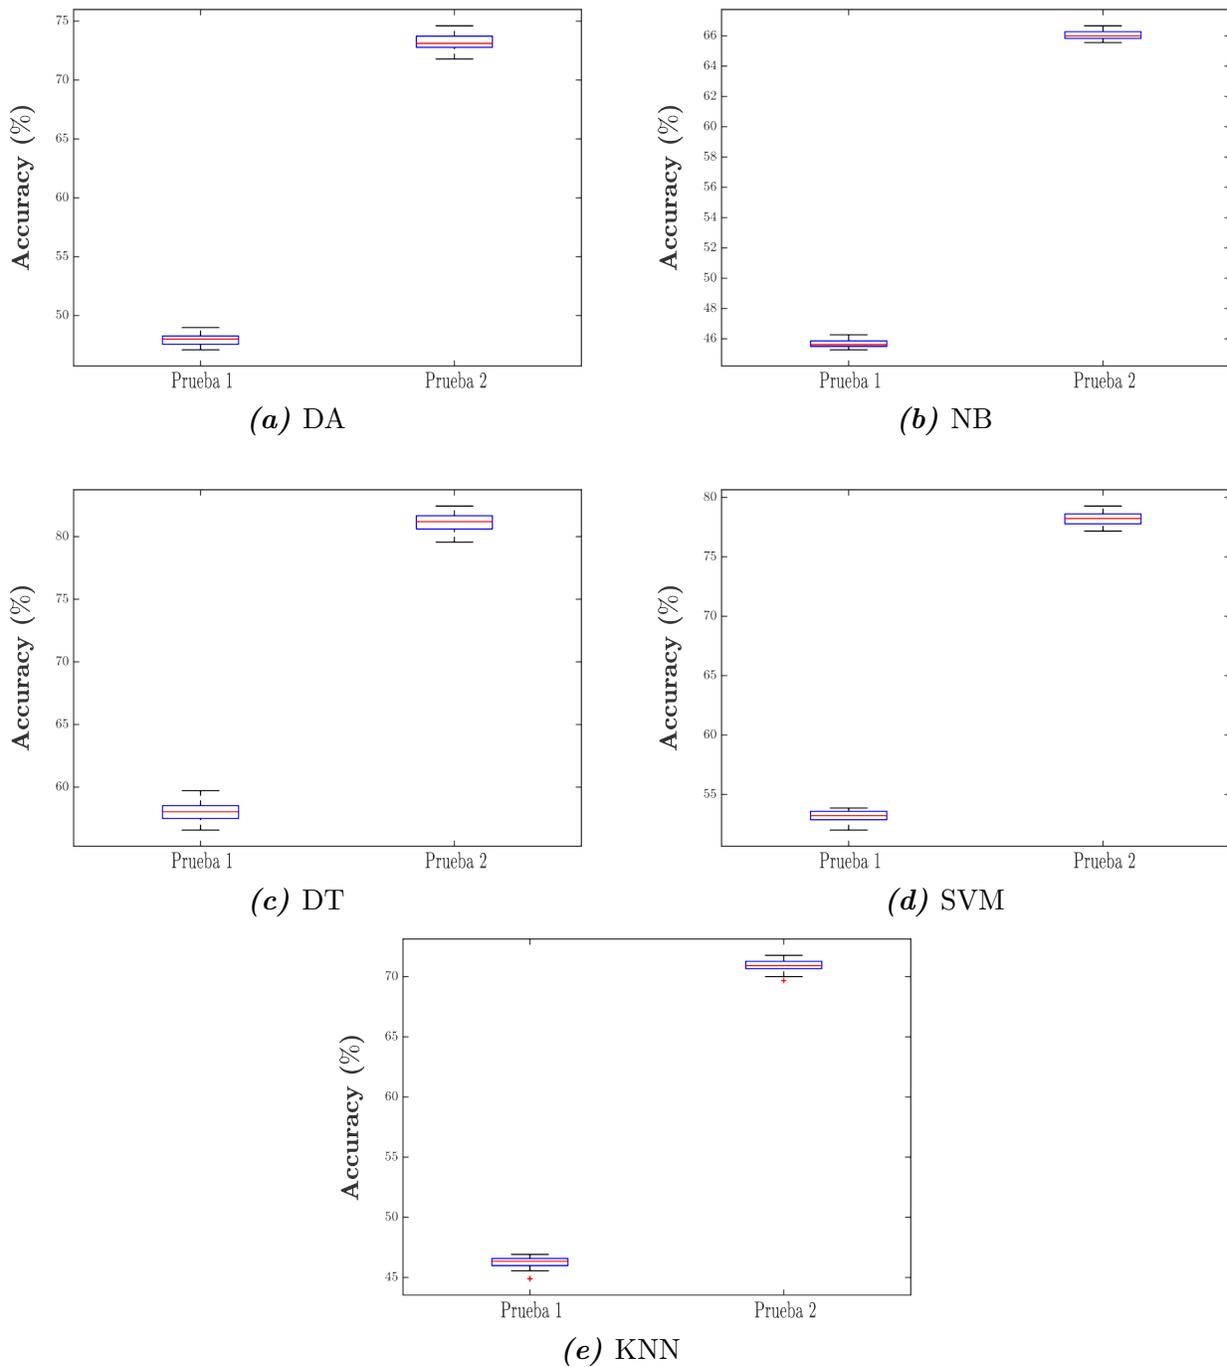
**Predicción**

*Figura 5.2.* Matriz de confusión del modelo DT.

verificando la repetibilidad del resultado.

Con el gráfico de cajas de la Figura 5.3, podemos observar la distribución del *accuracy* (exactitud) de cada uno de los cinco algoritmos al detectar la posición angular de curvatura en estas pruebas. Cada gráfico evidencia que la mediana de los datos en la prueba 2 (ver sección 5.1.2) aumenta alrededor de 27% con respecto a la prueba 1 (ver sección 5.1.1), además de mantener un comportamiento simétrico, alcanzando resultados por encima del 70% de exactitud. El gráfico de cajas de la Figura 5.3a expone los resultados obtenidos por el modelo de Análisis discriminante (DA), el cual exhibe para la prueba 1 una mediana en cuanto a la exactitud del 48% con un rango intercuartil de 0.7099; por su parte la prueba 2 tiene una mediana de 73.11% con un rango intercuartil de 0.9444. La Figura 5.3b evidencia el comportamiento estadístico del modelo Bayesiano Ingenuo (NB) que obtiene una mediana de 45.71% para detectar la posición angular en la prueba 1 y un rango intercuartil de 0.3704; en la prueba 2 la mediana equivale al 66% de exactitud con un rango intercuartil de 0.4444.

La distribución de los valores de exactitud con el modelo de Árbol de Decisión (DT) se muestra en la Figura 5.3c. De esta forma, en la prueba 1 se tiene una mediana de exactitud equivalente al 58.02% y un rango intercuartil de 1.0185; por su parte, en la prueba 2 el resultado de la mediana es de 81.19% con un rango intercuartil de 1.0556. Los resultados obtenidos en la prueba 1 con el modelo de Máquina de Soporte Vectorial (SVM) (ver Figura 5.3d), tienen una



**Figura 5.3.** Gráfico de cajas para cada modelo: Análisis Discriminante (DA), Bayesiano Ingenuo (NB), Árbol de Decisión (DT), Máquinas de Soporte Vectorial (SVM) y K-Vecinos más Próximos (KNN); para un número de repeticiones de 50.

mediana de 53.20 % de exactitud para la detección de la posición angular y un rango intercuartil de 0.7099. Además, en la prueba 2 la mediana aumenta al 78.22 % con un rango intercuartil de 0.8333 respectivamente. Para finalizar, los resultados para el modelo de clasificación de

K-Vecinos más Próximos corresponde a la Figura 5.3e; puesto que, la exactitud para reconocer la posición angular tiene una mediana del 46.34% para la prueba 1 y la dimensión del rango intercuartil es de 0.5864. Mientras tanto, en la prueba 2 la mediana equivale al 70.91% de exactitud con un rango intercuartil de 0.6111. Es fácil observar cómo los modelos logran un alto grado de repetibilidad, evidenciado por el achatamiento de las cajas y los valores del rango intercuartil en cada gráfico, lo que indica estabilidad a nivel algorítmico.

### 5.1.3. Prueba 3

Hasta ahora se logra obtener una mejora significativa al momento de clasificar los datos. No obstante, no se ha realizado un ajuste de ellos. Por lo que para esta prueba se evalúa tres algoritmos de selección de características (ReliefF, Análisis de Componentes del Vecindario - NCA, Mínima Redundancia Máxima Relevancia - mRMR). Esto permitirá identificar cuáles características aportan información significativa entre las 180 que comprenden la base de datos. Con esto se busca ayudar a los modelos a clasificar mejor la base de datos; además de disminuir el tiempo de cómputo requerido para el procesamiento de las imágenes (ver esquema de la Figura 4.9), ya que son menos las características a calcular en cada espacio de color. Este proceso lo describimos a continuación.

#### 1. ReliefF

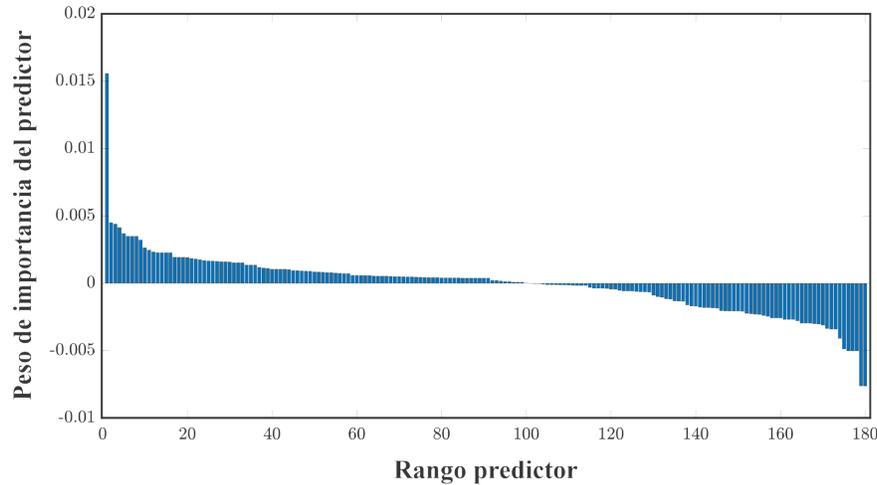
Este algoritmo calcula las ponderaciones para cada característica de la base de datos, tal como se muestra en la Figura 5.4. Los coeficientes de las características se presentan en secuencia descendente, lo que implica que se asigna un rango a cada característica en función de su importancia.

**Tabla 5.3.** Valores  $K$  para algoritmo ReliefF.

Valores $K$	12	14	2,5,10	6,11	8,18
Características (No.)	3	5	6	8	9

En otras palabras, la característica con la ponderación más destacada se posiciona en primer lugar, y así sucesivamente posiciona todas las 180 características. Luego, la selección de características se basa en el valor de  $K$  vecinos más cercanos por categoría; en este estudio, el valor óptimo se elige evaluando un rango definido para  $1 \leq K \leq 20$ . Cuando el algoritmo ReliefF va probando los valores  $K$ , elige de forma automática el total de características y los índices (posición por columna correspondientes en la base de datos) que tienen mayor peso, los cuales son diferentes de acuerdo a cada valor de

$K$  (ver Tabla 5.3). A partir de esta selección de características, se entrenan los cinco algoritmos de aprendizaje automático.



*Figura 5.4.* ReliefF.

**Tabla 5.4.** Comparación del rendimiento de los algoritmos de aprendizaje automático con las características seleccionadas por el algoritmo ReliefF.

Algoritmos (AI)	Parámetros y Función	Exactitud [%]	Tiempo [seg]	Características No.
DA	Discriminante Lineal	65.55	3.899	6
	Discriminante Lineal	65.38	4.107	6
	Discriminante Cuadrático	67.5	4.308	9
NB	Distribución - Gaussiana	66.11	4.679	3
	Distribución - Kernel	67.94	8.126	9
DT	Prueba - Standard CART	89.83	4.605	6
	Prueba - Curvature test	89.05	4.668	8
	Prueba - Interaction test	88.66	4.764	6
SVM	Kernel Polinómico (d=2)	85.77	10.267	9
	Kernel Gaussiano	<b>92.55</b>	<b>7.374</b>	<b>6</b>
KNN	Distancia Euclidiana (K=9)	90.5	4.232	8
	Distancia Minkowski (K=14)	89.11	4.486	5
<b>Promedio</b>		<b>79.82</b>		

La Tabla 5.4 muestra los resultados de los cinco algoritmos de clasificación al evaluar las 10 posiciones de curvatura comprendidas en el rango de  $20^\circ$  -  $65^\circ$ , con las características elegidas por ReliefF; además, los tiempos expuestos en esta tabla son calculados durante el proceso de selección de características del algoritmo ReliefF y el entrenamiento y

prueba de los modelos de clasificación. La exactitud en la detección de las posiciones aumenta al 92.55 % usando seis características que se muestran en la Tabla 5.5, como resultado de entrenar el clasificador SVM con kernel gaussiano. Cuatro de estas características provienen de calcular los momentos de color de las imágenes; asimismo, se puede observar en la Tabla 5.5 el índice al que corresponden en la base de datos.

**Tabla 5.5.** Características seleccionadas por ReliefF usadas en el modelo SVM.

No.	Índice No	Dimensión	Tipo de análisis	Espacio de color
1	35	Valor medio absoluto	Histograma Ecualizado	Banda G (RGB)
2	60	Asimetría	Momentos de color	Banda G (RGB)
3	59	Desviación estándar	Momentos de color	Banda G (RGB)
4	179	Desviación estándar	Momentos de color	Banda a* (CIELab)
5	58	Media	Momentos de color	Banda G (RGB)
6	11	Factor de forma con SMR	Histograma	Banda G (RGB)

Clase real	20°	180									
	25°		179	1							
	30°			177	3						
	35°			3	172	5					
	40°				7	167	5	1			
	45°				1	6	163	10			
	50°						8	163	6	3	
	55°							6	150	4	20
	60°							4	3	151	22
	65°									16	164
		20°	25°	30°	35°	40°	45°	50°	55°	60°	65°
		<b>Predicción</b>									

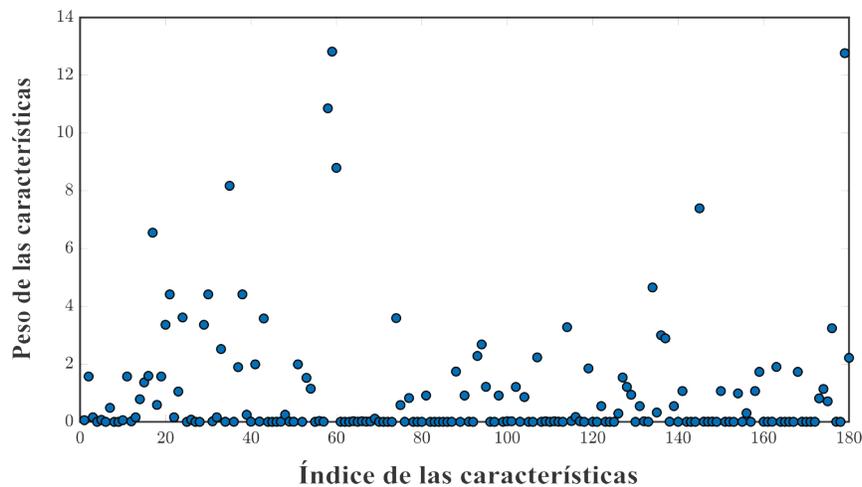
**Figura 5.5.** Matriz de confusión del modelo SVM con las características de ReliefF.

La matriz de confusión para el resultado del 92.55 % con SVM se muestra en la Figura 5.5. La predicción de los datos de prueba para la posición de 20° se realiza correctamente. No obstante, conforme aumenta la curvatura, la predicción disminuye en un rango de 3 a 20 muestras asignadas a otra posición. Sin embargo, esta cantidad de datos asignada

erróneamente es pequeña al compararlo con el total de las 180 observaciones que se tienen por posición de curvatura.

## 2. Neighborhood component analysis (NCA)

Evalúa para cada característica de la base de datos un peso, el cual se calcula con un término de regularización que en este trabajo se define como  $\lambda = 5e^{-6}$ . El peso está relacionado con los vecinos más cercanos con respecto a un punto de referencia que elige de forma aleatoria, este depende del ancho de kernel que se defina, en este caso dé  $\sigma = 0.2$ . La distribución de ponderaciones se muestran en la Figura 5.6, donde los pesos de las características irrelevantes son cercanos a cero.



*Figura 5.6.* NCA.

Durante este proceso se busca minimizar una función objetivo usando el algoritmo conocido como Limited-memory BFGS (LBFGS). Para evitar que los pesos tengan diferentes magnitudes, se estandariza los predictores con media cero y desviación estándar unitaria, antes de aplicar NCA. Este proceso toma aproximadamente 378.62 seg para los datos que representan las posiciones de curvatura de  $20^\circ - 65^\circ$ .

**Tabla 5.6.** Valores de umbral  $th$  para algoritmo NCA.

Umbral ( $th$ )	0.3	0.4-0.5	0.6	0.7
Características (No.)	11	7	5	3

Luego se utiliza un valor de umbral ( $th$ ) para elegir las características. En este paso, se compara el peso de cada característica con una estimación calculada a partir del umbral y los pesos máximos. De esta manera, se seleccionan las características con una ponderación

superior a esa estimación, que están asociadas con las de mayor peso. En las pruebas de este trabajo, se usa un rango de umbral  $0.3 \leq th \leq 0.7$  tal como se ve en la Tabla 5.6.

El entrenamiento de los algoritmos de clasificación se lleva a cabo para todos los valores de umbral. Como se describió en el método de selección anterior, de este ciclo de entrenamiento se extrae el valor de umbral y, por lo tanto, las características que selecciona para obtener el mayor porcentaje de exactitud al detectar la posición de curvatura. Es importante señalar que cada algoritmo usa un valor de características diferentes. En la Tabla 5.7, se presentan estos resultados, donde la elección de NCA para

**Tabla 5.7.** Comparación del rendimiento de los algoritmos de aprendizaje automático con las características seleccionadas por el algoritmo NCA.

Algoritmos (AI)	Parámetros y Función	Exactitud [%]	Tiempo [seg]	Características No.
DA	Discriminante Lineal	65.61	0.931	5
	Discriminante Lineal	65.33	1.006	5
	Discriminante Cuadrático	67.83	1.028	7
NB	Distribución - Gaussiana	64.05	1.22	5
	Distribución - Kernel	68.66	4.607	11
DT	Prueba - Standard CART	88.50	1.017	5
	Prueba - Curvature test	88.55	1.06	3
	Prueba - Interaction test	89	0.913	5
SVM	Kernel Polinómico (d=2)	85.81	10.29	7
	Kernel Gaussiano	91	6.184	5
KNN	Distancia Euclidiana (K=9)	<b>92.88</b>	<b>1.406</b>	<b>3</b>
	Distancia Minkowski (K=14)	89.66	1.586	5
<b>Promedio</b>		79.74		

cada algoritmo contribuye a un promedio general de exactitud del 79.74 %. Cabe destacar que este cálculo incluye los tiempos asociados con el entrenamiento y la prueba de los cinco algoritmos de aprendizaje automático. El modelo KNN tarda 1.406 seg en entrenar y realizar la prueba con las tres características seleccionadas (Tabla 5.8), cuyo resultado de exactitud es el más alto hasta ahora, 92.88 %. Los modelos SVM y DT utilizan 5 características, respectivamente, y tienen una exactitud del 91 % y 89 %.

Aunque el tiempo de selección de características NCA es mayor debido al bucle interno para la estimación de pesos y minimización de la función objetivo, se trata de un procedimiento de una sola vez y no tiene impacto en el tiempo de prueba. Además, como resultado de la eliminación de una mayor cantidad de características innecesarias,

NCA con el clasificador KNN creó un modelo de predicción que alcanzó una velocidad de clasificación más rápida en comparación con los modelos de predicción creados utilizando ReliefF y mRMR como métodos de selección de características y el clasificador KNN. La Tabla 5.8 muestra las características correspondientes a los momentos de color de las imágenes, que también son parte de la selección del algoritmo ReliefF.

**Tabla 5.8.** Características seleccionadas por NCA usadas en el modelo KNN.

No.	Índice No	Dimensión	Tipo de análisis	Espacio de color
1	58	Media	Momentos de color	Banda G (RGB)
2	59	Desviación estándar	Momentos de color	Banda G (RGB)
3	179	Desviación estándar	Momentos de color	Banda a* (CIELab)

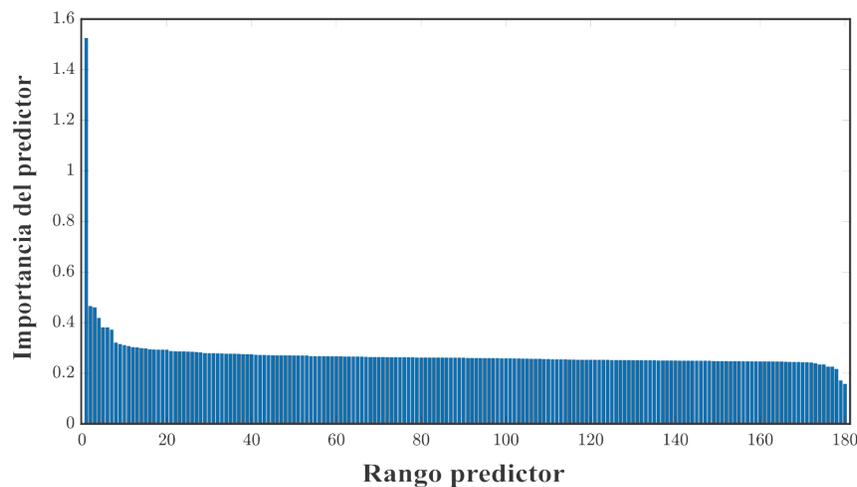
En la matriz de confusión en la Figura 5.7 se puede analizar la exactitud del resultado de crear un modelo de clasificación KNN para detectar la curvatura del sistema propuesto, con estas 3 características. El 100 % de las observaciones usadas en la etapa de validación, se asignan en su totalidad para la posición angular de 20° y 25°. A medida que la posición angular robótica aumenta, solo el 89.91 % de los datos se identifican en la posición real.

Clase real	20°	180									
	25°		180								
	30°			179	1						
	35°				169	11					
	40°				15	159	4	2			
	45°					7	161	12			
	50°					1	12	161	2	4	
	55°							8	169	2	1
	60°							4	5	156	15
	65°								6	16	158
		20°	25°	30°	35°	40°	45°	50°	55°	60°	65°
		<b>Predicción</b>									

**Figura 5.7.** Matriz de confusión del modelo KNN con las características de NCA.

### 3. Mínima Redundancia Máxima Relevancia (mRMR)

El método mRMR no utiliza parámetros predeterminados para su evaluación, por su parte calcula el cociente de información mutua para la búsqueda óptima de las características de la base de datos. Un vector con los índices de las características ordenadas por su importancia se devuelve al evaluar todas las características, como se muestra en la Figura 5.8. La confianza en la selección de características como predictor es aceptable cuando hay una gran caída de la puntuación entre un predictor y el siguiente. En otras palabras, el software tiene la confianza de elegir el predictor más importante. Los descensos pequeños indican que la diferencia en la importancia de los predictores no es significativa.



**Figura 5.8.** mRMR.

Una vez que se tiene el vector de las características ordenadas por su importancia, la elección se hace de manera arbitraria; es decir, de forma iterativa se va seleccionando un predictor y entrenando los clasificadores. Continúa con cada predictor hasta finalizar y luego, se realiza la búsqueda del valor máximo de exactitud obtenido al identificar una posición. Por ende, también se conoce el total de características asociadas a este resultado, junto a sus índices de importancia. En este trabajo se define un rango de selección de predictores que va desde 2 hasta 10, ya que gráficamente se puede observar que luego de 10 predictores, el descenso no es relevante.

**Tabla 5.9.** Características seleccionadas por mRMR usadas en el modelo DT.

No.	Índice No	Dimensión	Tipo de análisis	Espacio de color
1	58	Media	Momentos de color	Banda G (RGB)
2	35	Valor medio absoluto	Histograma Ecuilizado	Banda G (RGB)

Los resultados de la Tabla 5.10 se obtienen al usar los conjuntos de entrenamiento y

prueba de los 5 algoritmos de clasificación, utilizando las características seleccionadas como relevantes por mRMR. Los tiempos expuestos en esta tabla corresponden a la selección de características por mRMR, además del entrenamiento y prueba de los algoritmos de clasificación. Para los modelos de DA como para NB el porcentaje de exactitud al detectar la posición de la curvatura se encuentra alrededor del 65%. La tendencia a este resultado con estos modelos ocurre también para la selección de ReliefF y NCA, como se observa en las Tablas 5.4 y 5.7. Con los modelos SVM y KNN los resultados están por encima del 85% y 89% de exactitud al usar las características de ReliefF y NCA; pero con la selección de mRMR, SVM y KNN alcanzan el 83.50%.

**Tabla 5.10.** Comparación del rendimiento de los algoritmos de aprendizaje automático con las características seleccionadas por el algoritmo mRMR.

Algoritmos (AI)	Parámetros y Función	Exactitud [%]	Tiempo [seg]	Características No.
DA	Discriminante Lineal	65.61	5.214	3
	Discriminante Lineal	65.77	5.710	3
	Discriminante Cuadrático	62.94	5.291	9
NB	Distribución - Gaussiana	65.94	5.378	2
	Distribución - Kernel	68.05	9.071	10
DT	Prueba - Standard CART	83.44	4.402	2
	Prueba - Curvature test	82.61	3.457	2
	Prueba - Interaction test	<b>83.61</b>	<b>3.689</b>	<b>2</b>
SVM	Kernel Polinómico (d=2)	73.77	50.784	3
	Kernel Gaussiano	83.50	6.933	2
KNN	Distancia Euclidiana (K=9)	83.05	4.586	2
	Distancia Minkowski (K=14)	77.72	3.591	2
<b>Promedio</b>		74.66		

Por último, los modelos usados de DT son los que tienen un mejor rendimiento en esta prueba, con un alcance de identificar cada posición del 83.61% al usar las 2 características de mRMR de la Tabla 5.9. Este resultado demuestra que, comparado con los algoritmos ReliefF y NCA, el resultado de predicción es menor, a pesar de que este algoritmo selecciona solo dos características de todo el conjunto de datos como las de mayor confianza para la predicción.

La manera en que el algoritmo de DT identifica cada dato de prueba externa a una posición angular, se ve en la matriz de confusión en la Figura 5.9. Para las posiciones de 40° - 60° se presenta la mayor cantidad de muestras clasificadas incorrectamente,

20°	176	4								
25°	4	162	14							
30°		3	171	5	1					
35°			4	155	20	1				
40°			2	14	140	19	5			
45°				1	21	140	18			
50°					7	28	117	20	8	
55°							14	141	11	14
60°							5	5	139	31
65°								9	17	154
	20°	25°	30°	35°	40°	45°	50°	55°	60°	65°

**Predicción**

**Figura 5.9.** Matriz de confusión del modelo DT con las características de mRMR.

abarcando aproximadamente 44 observaciones reconocidas en una posición inferior o superior a la real.

El gráfico de cajas de la Figura 5.10 muestra el comportamiento de la exactitud obtenida al entrenar 50 veces los modelos de aprendizaje automático con el nuevo espacio de datos, producto de usar los algoritmos de selección de características.

La respuesta del modelo de Análisis Discriminante (DA) se muestra en la Figura 5.10a. Con las 9 características que selecciona el algoritmo ReliefF, la exactitud de detección del modelo DA al reconocer la posición angular tiene una mediana del 67.55%; con un valor máximo de 68.16% y un mínimo de 66.77%. Además, la dimensión del rango intercuartil (equivale el 50% de los datos agrupados) es de 0.5556. El algoritmo NCA proporciona 7 características, que al ser usadas en el modelo DA aportan una mediana de 67.72% de exactitud, con un valor máximo de 68.83% y mínimo de 67.05%; el rango intercuartil corresponde a 0.50. El nuevo espacio de datos que resulta de usar el algoritmo mRMR equivale a 3 características, con las cuales el modelo tiene una mediana de 65.27%, un máximo porcentaje de precisión para clasificar las posiciones de 65.61% y mínimo de 64.83%; el rango intercuartil en este caso es de 0.2778.

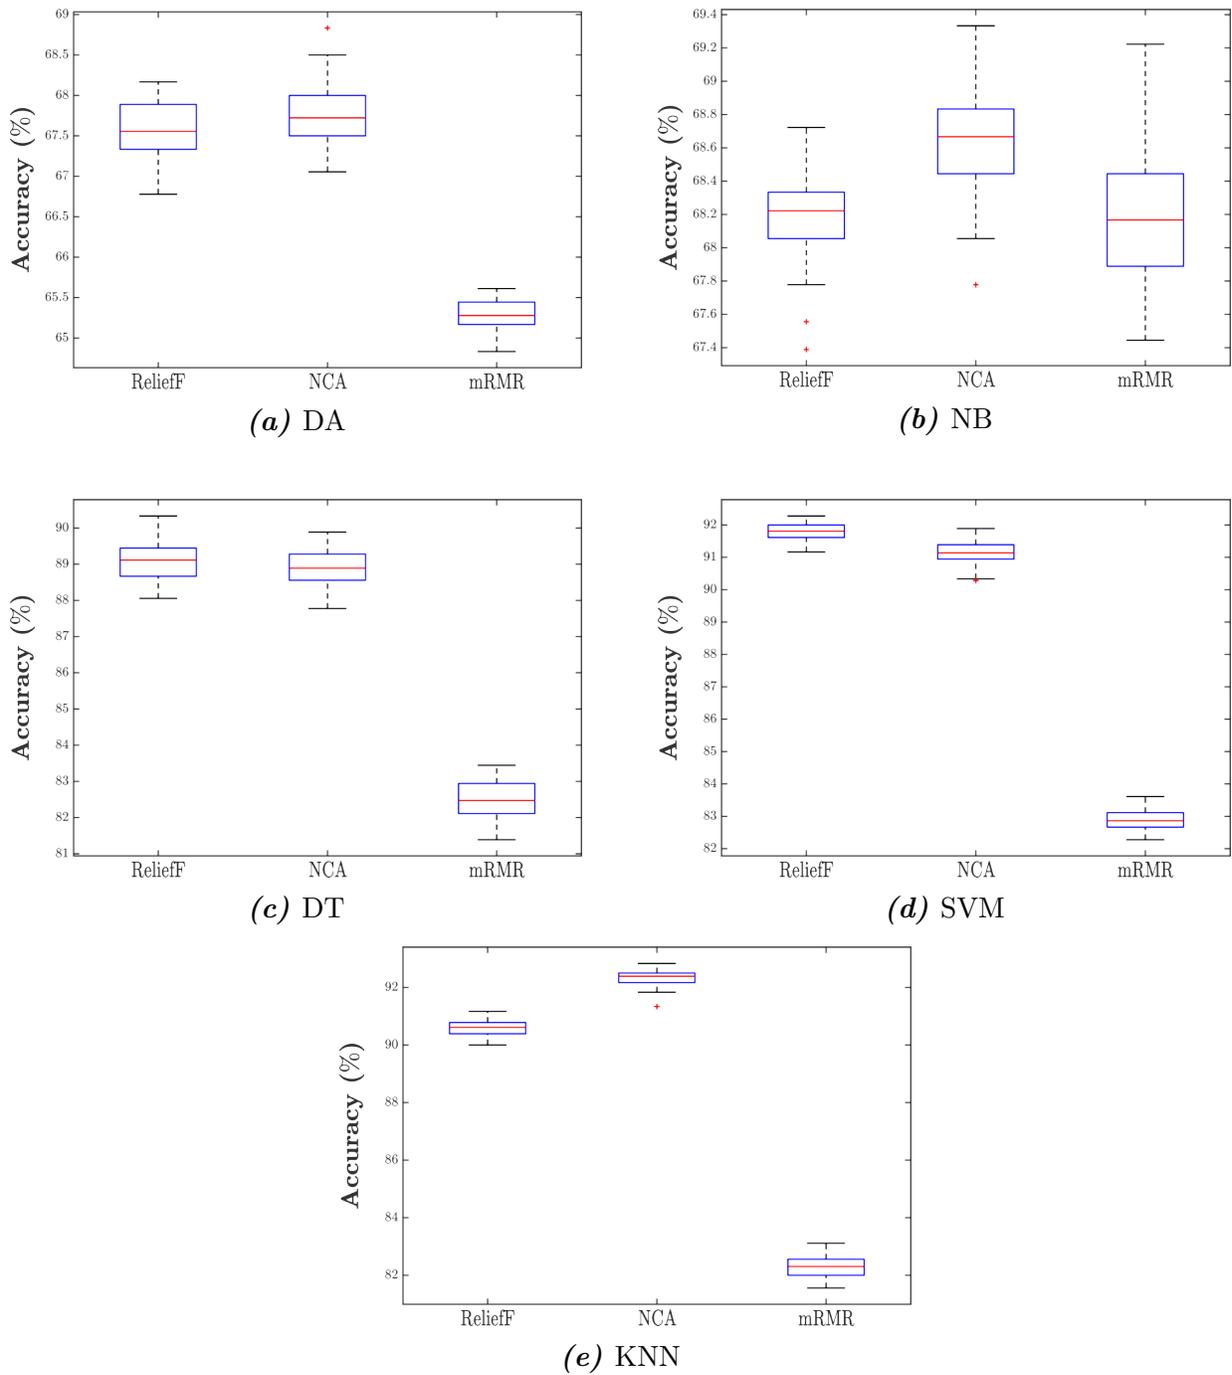
La distribución de los valores de exactitud obtenidos con el modelo Bayesiano

Ingenio (NB) usando las muestras de los algoritmos de selección de características, corresponde a la Figura 5.10b. El algoritmo ReliefF escoge 9 características que permiten obtener al clasificador una mediana del 68.22 %, con un porcentaje máximo de exactitud de 68.72 %, un mínimo no excepcional de 67.77 % y un valor atípico de 67.37 % (valor que está a más de 1,5 veces el rango intercuartil de la parte inferior de la caja). Para este caso, el rango intercuartil es de 0.2778. Por su parte, con 11 características que elige el Algoritmo NCA, el valor de la mediana de las muestras identificadas correctamente por el modelo equivale a una exactitud del 68.66 %. Asimismo, alcanza un valor máximo de exactitud de 69.33 %, un valor adyacente inferior de 68.05 % y se observa un valor atípico en 67.77 %; el rango intercuartil de 0.3889. El algoritmo mRMR proporciona 10 características, que al ser usadas por el modelo NB se tiene una mediana de 68.16 %, un valor máximo de 69.22 % y mínimo 67.44 % de exactitud; el rango intercuartil es de 0.5556.

El modelo de Árbol de Decisión (DT) tiene un comportamiento correspondiente en cuanto a la respuesta de exactitud que se muestra en la Figura 5.10c. Con las 6 características que selecciona el algoritmo ReliefF, la mediana de los datos que se asignan a la posición de curvatura verdadera es de 89.11 %; se tiene un valor máximo de exactitud de 90.33 % y mínimo de 88.05 %, el rango intercuartil es de 0.7778. Con 5 características elegidas por el algoritmo NCA, el modelo DT logra un valor de mediana de 88.88 %, un valor de exactitud máxima de 89.88 % y mínima de 87.77 %; además, el rango intercuartil es 0.7222. El espacio de datos más pequeño utilizado, corresponde a 2 características seleccionadas de la base de datos, por el algoritmo mRMR. A partir de aquí, la clasificación del modelo DT alcanza 82.47 % de mediana, valores máximo y mínimo de exactitud de 83.61 % y 81.38 % respectivamente; el rango intercuartil es 0.8333.

Con la Máquina de Soporte Vectorial (SVM) se tiene la distribución de la Figura 5.10d. El algoritmo ReliefF selecciona un espacio de datos con 6 características. Por consiguiente, se tiene un alto porcentaje de clasificación, con una mediana equivalente a 91.80 %, valor máximo y mínimo de 92.55 % y 91.16 %, además de que el 50 % de los datos se agrupan en un rango intercuartil de 0.3889. Por su parte, el algoritmo NCA elige 5 características que proporcionan una mediana de 91.13 %, con un valor máximo de exactitud al detectar la posición de curvatura del 91.88 % y un valor mínimo no excepcional de 90.33 %; asimismo, se tiene un valor atípico en 90.27 % y el rango intercuartil es de 0.4444. El algoritmo mRMR permite que el modelo SVM logre una mediana de clasificación de 82.86 %, un máximo de 83.61 % y mínimo de 82.27 %, el rango intercuartil corresponde a 0.4444. Esto con 2 características seleccionadas.

Los resultados para el modelo de clasificación de K-Vecinos más Próximos corresponde



**Figura 5.10.** Gráfico de cajas para cada modelo: Análisis Discriminante (DA), Bayesiano Ingenuo (NB), Árbol de Decisión (DT), Máquinas de Soporte Vectorial (SVM) y K-Vecinos más Próximos (KNN); para un número de repeticiones de 50.

la Figura 5.10e. Con las 8 características que proporciona el algoritmo ReliefF, facilita que el clasificador obtenga una mediana de exactitud equivalente al 90.61 %; además, valores máximo y mínimo de 91.61 % y 90 % al detectar correctamente la curvatura. El rango intercuartil es

dé 0.3889. Luego de usar las 3 características resultantes con el algoritmo NCA, se tiene el mayor porcentaje de exactitud de este trabajo al detectar la posición angular en el dedo índice robótico. La distribución de los resultados muestran una mediana de 92.38 %, con un valor de exactitud máximo de 92.88 % y un mínimo no excepcional de 91.83 %; a su vez, un valor mínimo atípico en 91.33 % y un rango intercuartil dé 0.3333. Al utilizar las 2 características del algoritmo mRMR, KNN alcanza una mediana de exactitud del 82.30 %, máximo valor de precisión de 83.11 % y mínimo de 81.55 %; de igual manera un rango intercuartil dé 0.5556.

Estos resultados de repetibilidad exponen la estadística descriptiva de los datos y proporcionan una herramienta para conocer el algoritmo de selección de características, que proporciona a los modelos de clasificación el mejor desempeño. Por ende, con el algoritmo NCA y el modelo de clasificación KNN se aumenta en un 90 %, la exactitud en la detección de la posición de curvatura. Así también, el tiempo de cómputo en el proceso del procesamiento de las imágenes disminuye, ya que solo es necesario el cálculo de 3 características para lograr este valor de exactitud. Estas corresponden a las características de los momentos de color calculadas en la banda G (RGB) y  $a^*$  (CIEL\*a\*b\*).

## CAPÍTULO 6

---

### Conclusiones

---

En ese trabajo se propone un sistema óptico de detección de curvatura que se aplica experimentalmente en el estudio biomecánico de la mano mediante el procesamiento de imágenes y diversas técnicas de aprendizaje automático.

Este sistema está principalmente constituido por fibra estándar monomodo 630HP de funcionamiento en el espectro visible de la luz. La fibra óptica se somete a estrés mecánico externo al desplazar una etapa de translación lineal que produce curvatura en una sección de la fibra. Por consiguiente, se demuestra que la fibra funciona como un sensor ideal para estimar los cambios de curvatura en el rango de funcionamiento multimodal de 450 – 570 nm. Este comportamiento se debe al cambio en las constantes de propagación conforme aumenta el radio efectivo de curvatura, lo que provoca un aumento en el coeficiente de pérdida en la fibra y desencadena la interacción de múltiples modos que se alejan desde el núcleo al revestimiento de la fibra. Debido a las pérdidas de transmisión en este rango específico de longitud de onda, se analizó el cambio de amplitud en el espectro de luz del LED. Cuando la fibra está totalmente recta, el pico de intensidad máximo es de 550 nm y representa el color amarillo. A medida que la curvatura aumenta desde  $23,83m^{-1}$  hasta el valor de  $123,93m^{-1}$ , el pico se desplaza hacia longitudes de onda menor, alcanzando los 513 nm que es la longitud de onda del color verde.

En vista de que la curvatura presenta esta variación en la longitud de onda, las imágenes obtenidas por la cámara CCD en el sistema robótico que provienen del perfil de salida de la fibra óptica, se analizan en tres espacios de color que aportan información significativa para el color verde. La banda G del espacio de color RGB, la banda H del espacio de color HSV y la banda  $a^*$  del espacio de color CIEL\*a\*b\*. Para el sistema robótico de adquisición, se determina que la longitud ideal de fibra óptica para realizar el análisis de curvatura es de 25 mm. Con esta longitud se tiene una sensibilidad de la media estadística ante el cambio del color verde de  $0.0549 \mu/m^{-1}$  y con respecto a la desviación estándar de  $0.0257 \sigma/m^{-1}$ . Un total de 3240 imágenes se capturan a través del movimiento de flexión-extensión del dedo índice robótico en un rango de  $0^\circ - 85^\circ$  con incrementos de  $5^\circ$ . Por lo tanto, se tiene un total de 18 posiciones de curvatura y cada una cuenta con 180 imágenes. Al realizar el procesamiento de las imágenes se construye la base de datos con un total de 180 características estadísticas.

Se utiliza cinco algoritmos de aprendizaje automático para analizar y detectar automáticamente cada una de las posiciones de curvatura de la base de datos. Se obtiene una precisión del 58.33% con el algoritmo de árbol de decisión para detectar la posición angular robótica. Con la matriz de confusión se observó que aproximadamente solo el 34.2% de los datos de validación de las primeras cuatro posiciones ( $0^\circ - 15^\circ$ ) y el 40.36% de las últimas cuatro posiciones ( $70^\circ - 85^\circ$ ) se clasifican en la posición real. De manera que, para las aplicaciones biomecánicas con robótica, un grado de flexión pequeño no constituye un movimiento natural; también, los grados de curvatura muy grandes asociados a la articulación PIF, están limitados al diseño de la mano y sus piezas. Al limitar la base de datos en un rango de  $20^\circ - 65^\circ$ , se logró con el modelo de árbol de decisión un resultado de 82.66% de precisión al identificar la curvatura del sistema en un tiempo de 1.836 seg.

Para disminuir tiempo de cómputo en la etapa de procesamiento de las imágenes y la creación de la base de datos, se usa tres algoritmos de selección de características, los cuales disminuyen en gran medida el número de características irrelevantes en la base de datos. El algoritmo ReliefF proporciona seis características de la base de datos (ver Tabla 5.5), con las cuales el porcentaje de precisión aumenta a 92.81% con el modelo SVM de kernel gaussiano. El algoritmo NCA proporciona tres características (ver Tabla 5.8) con las que se obtiene el 92.88% de precisión al detectar la posición angular, con el modelo de clasificación de KNN. El algoritmo mRMR propone dos características predictoras importantes (ver Tabla 5.9), con las que se tiene un resultado de precisión del 83.61% con el modelo de árbol de decisión.

Finalmente, el desarrollo de esta investigación establece una referencia de trabajo multidisciplinario que involucra los dispositivos ópticos y el manejo de datos en una aplicación

de detección biomecánica. La base de datos analizada es creada a partir del dispositivo de fibra óptica de fácil implementación. Se demuestra que los métodos clásicos de aprendizaje de máquina obtienen resultados significativos para determinar la posición angular del dedo índice robótico.

---

## Referencias

---

- [1] K. Van de Graaff, R. Rhees, and S. Palmer. *Schaum's Outline of Human Anatomy and Physiology, Third Edition*. Schaum's Outline Series. McGraw-Hill Education, 2009.
- [2] Ian Bullock, Júlia Borràs, and Aaron Dollar. Assessing assumptions in kinematic hand models: A review. pages 139–146, 06 2012.
- [3] Hyeonjun Park and Donghan Kim. An open-source anthropomorphic robot hand system: Hri hand. *HardwareX*, 7:e00100, 2020.
- [4] Luis Alejandro Herrera Piad. *Study of modal coupling in tapered optical fibers*. PhD thesis, Universidad de Guanajuato, Salamanca, Gto., March 2019.
- [5] G. Keiser. *Optical Fiber Communications*. McGraw-Hill Education, 2010.
- [6] E. Udd and W.B. Spillman. *Fiber Optic Sensors: An Introduction for Engineers and Scientists*. Wiley, 2011.
- [7] Stephen Hyde, Z Blum, T Landh, S Lidin, BW Ninham, S Andersson, and K Larsson. *The language of shape: the role of curvature in condensed matter: physics, chemistry and biology*. Elsevier, 1996.
- [8] Rafael C. Gonzalez and Richard E. Woods. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., USA, 2006.

- [9] Rabia Korifi, Yveline Le Dréau, Antinelli Jean Francois, Robert Valls, and Nathalie Dupuy. Ciel\*a\*b\* color space predictive models for colorimetry devices - analysis of perfume quality. *Talanta*, 104C:58–66, 01 2013.
- [10] Thorlabs. *Fiber-Coupled LED MBB1F1*, 2020.
- [11] Thorlabs. *Single Mode Fiber 630HP*, 2017.
- [12] Ocean Optics, Inc. *Fiber Optic Spectrometer USB2000*, 2001-2005.
- [13] Thorlabs. *DCx Camera Functional*, 2018.
- [14] M. Nordin and V.H. Frankel. *Basic Biomechanics of the Musculoskeletal System*. Wolters Kluwer Health/Lippincott Williams & Wilkins, 2012.
- [15] R. Tubiana, J.M. Thomine, and E. Mackin. *Examination of the Hand and Wrist*. Taylor & Francis, 1998.
- [16] Raphael Rätz, François Conti, René M. Müri, and Laura Marchal-Crespo. A novel clinical-driven design for robotic hand rehabilitation: Combining sensory training, effortless setup, and large range of motion in a palmar device. *Frontiers in Neurorobotics*, 15, 2021.
- [17] Joaquín L. Sancho-Bru, Antonio Peérez-Gonzaélez, Marta C. Mora, Beatriz E. Leoén, Margarita Vergara, José L. Iserte, Pablo J. Rodríguez-Cervantes, and Antonio Morales. Towards a realistic and self-contained biomechanical model of the hand. In Vaclav Klika, editor, *Theoretical Biomechanics*, chapter 10. IntechOpen, Rijeka, 2011.
- [18] CG Hagert. Anatomical aspects on the design of metacarpophalangeal implants. *Reconstruction surgery and traumatology*, 18:92—110, 1981.
- [19] Iyari Alejandro Nava-Téllez, Milton Carlos Elias-Espinosa, Héctor Cervantes-Culebro, and Aldo Elihu Flores-González. Parametric design of a finger rehabilitation mechanism with double action and two degrees of freedom. *Applied Sciences*, 12(21), 2022.
- [20] Yeongyu Park and Joonbum Bae. A three-dimensional finger motion measurement system of a thumb and an index finger without a calibration process. *Sensors (Basel, Switzerland)*, 20, 2020.
- [21] Haiting Di, Yatao Li, Keyu Liu, Lihua An, and Jingfeng Dong. Hand gesture monitoring using fiber-optic curvature sensors. *Appl. Opt.*, 58(29):7935–7942, Oct 2019.

- [22] Nazrul H. ADNAN, Wan Khairunizam, Shahriman Abu bakar, Siti Zaaba, Hazry Desa, and Mohd Aziz. The development of a low cost data glove by using flexible bend sensor for resistive interfaces. volume 2012, 04 2013.
- [23] Cristiano Pendão and Ivo Silva. Optical fiber sensors and sensing networks: Overview of the main principles and applications. *Sensors*, 22(19), 2022.
- [24] María Espinosa Bosch, Antonio Jesús Ruiz Sánchez, Fuensanta Sánchez Rojas, and Catalina Bosch Ojeda. Recent development in optical fiber biosensors. *Sensors*, 7(6):797–859, 2007.
- [25] Angela Leung, P. Mohana Shankar, and Raj Mutharasan. A review of fiber-optic biosensors. *Sensors and Actuators B: Chemical*, 125(2):688–703, 2007.
- [26] Abhishek Venkateswaran, Nageswara Lalam, Jeffrey Wuenschell, P. R. Ohodnicki Jr., Mudabbir Badar, Kevin P. Chen, Ping Lu, Yuhua Duan, Benjamin Chorpening, and Michael Buric. Recent advances in machine learning for fiber optic sensor applications. *Advanced Intelligent Systems*, 4(1):2100067, 2022.
- [27] Lei Zhao, Bei Wu, Yao Niu, Shengke Zhu, Ye Chen, Huanyang Chen, and Jin-hui Chen. Soft optoelectronic sensors with deep learning for gesture recognition. *Advanced Materials Technologies*, 7(11):2101698, 2022.
- [28] Kai Sun, Zhenming Ding, and Ziyang Zhang. Fiber directional position sensor based on multimode interference imaging and machine learning. *Appl. Opt.*, 59(19):5745–5751, Jul 2020.
- [29] Kyun Kyu Kim, InHo Ha, Min Kim, Joonhwa Choi, Phillip Won, Sungho Jo, and Seung Hwan Ko. A deep-learned skin sensor decoding the epicentral human motions. *Nature Communications*, 11(1):2149, May 2020.
- [30] David L. Quam, George B. Williams, Jeffery R. Agnew, and Patricia C. Browne. An experimental determination of human hand accuracy with a dataglove. *Proceedings of the Human Factors Society Annual Meeting*, 33(5):315–319, 1989.
- [31] G. Drew Kessler, Larry F. Hodges, and Neff Walker. Evaluation of the cyberglove as a whole-hand input device. *ACM Trans. Comput.-Hum. Interact.*, 2(4):263–283, dec 1995.
- [32] Lefan Wang, Turgut Meydan, and Paul Ieuan Williams. A two-axis goniometric sensor for tracking finger motion. *Sensors*, 17(4), 2017.

- [33] Fouzia Khan, Alper Denasi, David Barrera, Javier Madrigal, Salvador Sales, and Sarthak Misra. Multi-core optical fibers with bragg gratings as shape sensor for flexible medical instruments. *IEEE Sensors Journal*, 19(14):5878–5884, 2019.
- [34] D. Jauregui-Vazquez, J.M. Estudillo-Ayala, A. Castillo-Guzman, R. Rojas-Laguna, R. Selvas-Aguilar, E. Vargas-Rodriguez, J.M. Sierra-Hernandez, V. Guzman-Ramos, and A. Flores-Balderas. Highly sensitive curvature and displacement sensing setup based on an all fiber micro fabry–perot interferometer. *Optics Communications*, 308:289–292, 2013.
- [35] Roy J. Roesthuis, Marco Kemp, John J. van den Dobbelen, and Sarthak Misra. Three-dimensional needle shape reconstruction using an array of fiber bragg grating sensors. *IEEE/ASME Transactions on Mechatronics*, 19(4):1115–1126, 2014.
- [36] Christoff M. Heunis, Filip Šuligoj, Carlos Fambuena Santos, and Sarthak Misra. Real-time multi-modal sensing and feedback for catheterization in porcine tissue. *Sensors*, 21(1), 2021.
- [37] Paulo Roriz, António Ramos, José L. Santos, and José A. Simões. Fiber optic intensity-modulated sensors: a review in biomechanics. *Photonic Sensors*, 2(4):315–330, December 2012.
- [38] Andreas T. Augousti, Ali Raza, and Martin Graves. Design and characterization of a fiber optic respiratory plethysmograph (FORP). In Robert A. Lieberman, Halina Podbielska M.D., and Tuan Vo-Dinh, editors, *Biomedical Sensing, Imaging, and Tracking Technologies I*, volume 2676, pages 250 – 257. International Society for Optics and Photonics, SPIE, 1996.
- [39] Laura Dipietro, A.M. Sabatini, and Paolo Dario. A survey of glove-based systems and their applications. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 38:461 – 482, 08 2008.
- [40] Vinicius Pegorini, Leandro Zen Karam, Christiano Santos Rocha Pitta, Rafael Cardoso, Jean Carlos Cardozo Da Silva, Hypolito José Kalinowski, Richardson Ribeiro, Fábio Luiz Bertotti, and Tangriani Simioni Assmann. In vivo pattern classification of ingestive behavior in ruminants using fbg sensors and machine learning. *Sensors*, 15(11):28456–28471, 2015.
- [41] Leticia Avellar, Anselmo Frizera, and Arnaldo Leal-Junior. Pof smart pants: a fully portable optical fiber-integrated smart textile for remote monitoring of lower limb biomechanics. *Biomed. Opt. Express*, 14(7):3689–3704, Jul 2023.

- [42] Jung Jin Park, Woo Jin Hyun, Sung Cik Mun, Yong Tae Park, and O Ok Park. Highly Stretchable and Wearable Graphene Strain Sensors with Controllable Sensitivity for Human Motion Monitoring. *ACS Applied Materials & Interfaces*, 7(11):6317–6324, March 2015. Publisher: American Chemical Society.
- [43] Moe Amanzadeh, Saiied M. Aminossadati, Mehmet S. Kizil, and Aleksandar D. Rakić. Recent developments in fibre optic shape sensing. *Measurement*, 128:119–137, 2018.
- [44] I.A. Kapandji. *The Physiology of the Joints*. Number v. 2 in The Physiology of the Joints. Churchill Livingstone, 2007.
- [45] Lionel Birglen and Thomas Schlicht. A statistical review of industrial robotic grippers. *Robotics and Computer-Integrated Manufacturing*, 49:88–97, 2018.
- [46] Zhe Xu and Emanuel Todorov. Design of a highly biomimetic anthropomorphic robotic hand towards artificial limb regeneration. In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 3485–3492. IEEE, 2016.
- [47] Yasutomo Shimizu, Keisuke Kawaguchi, and Satoshi Kanai. Constructing mri-based 3d precise human hand models for product ergonomic assessments. 2010.
- [48] Huichan Zhao, Kevin O’Brien, Shuo Li, and Robert F. Shepherd. Optoelectronically innervated soft prosthetic hand via stretchable optical waveguides. *Science Robotics*, 1(1):eaai7529, 2016.
- [49] G.P. Agrawal. *Fiber-Optic Communication Systems*. Wiley Series in Microwave and Optical Engineering. Wiley, 2010.
- [50] Dietrich Marcuse. Curvature loss formula for optical fibers. *J. Opt. Soc. Am.*, 66(3):216–220, Mar 1976.
- [51] Ross Schermer and James Cole. Improved bend loss formula verified for optical fiber by simulation and experiment. *Quantum Electronics, IEEE Journal of*, 43:899 – 909, 11 2007.
- [52] Jesus Castrellon-Uribe. *Optical Fiber Sensors: An Overview*. 02 2012.
- [53] J.J. Carr. *Sensors and Circuits: Sensors, Transducers, and Supporting Circuits for Electronic Instrumentation, Measurement, and Control*. PTR Prentice Hall, 1993.
- [54] Luis A. Herrera-Piad, Joseph W. Haus, Daniel Jauregui-Vazquez, Yanelis Lopez-Dieguez, Julian M. Estudillo-Ayala, Juan M. Sierra-Hernandez, Juan C. Hernandez-Garcia, and

- Roberto Rojas-Laguna. A dual modality optical fiber sensor. *Journal of Modern Optics*, 65(3):342–347, 2018.
- [55] A. Koschan and M. Abidi. *Digital Color Image Processing*. Wiley, 2008.
- [56] Shiva Soleimanizadeh, Dzulkipli Mohamad, Tanzila Saba, and Amjad Rehman. Recognition of partially occluded objects based on the three different color spaces (rgb, ycber, hsv). *3D Research*, 6, 09 2015.
- [57] Dibya Bora, Anil Gupta, and Fayaz Khan. Comparing the performance of l\*a\*b\* and hsv color spaces with respect to color image segmentation. 06 2015.
- [58] Karel Zuiderveld. *Contrast Limited Adaptive Histogram Equalization*, page 474–485. Academic Press Professional, Inc., USA, 1994.
- [59] Z.H. Zhou and S. Liu. *Machine Learning*. Springer Nature Singapore, 2021.
- [60] C.M. Bishop. *Pattern Recognition and Machine Learning*. Information Science and Statistics. Springer New York, 2016.
- [61] P. A. Lachenbruch and M. Goldstein. Discriminant analysis. *Biometrics*, 35(1):69–85, 1979.
- [62] Ildiko E. Frank and Silvia Lanteri. Classification models: Discriminant analysis, simca, cart. *Chemometrics and Intelligent Laboratory Systems*, 5(3):247–256, 1989.
- [63] Tanzeel U. Rehman, Md. Sultan Mahmud, Young K. Chang, Jian Jin, and Jaemyung Shin. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Computers and Electronics in Agriculture*, 156:585–605, 2019.
- [64] R.O. Duda, P.E. Hart, and D.G. Stork. *Pattern Classification*. Wiley, 2012.
- [65] T. Hastie, R. Tibshirani, and J.H. Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer series in statistics. Springer, 2001.
- [66] L. Breiman, J. Friedman, C.J. Stone, and R.A. Olshen. *Classification and Regression Trees*. Taylor & Francis, 1984.
- [67] C.J.C. Burges and Chris J.C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2:121–167, January 1998.
- [68] Vladimir N. Vapnik. *Statistical Learning Theory*. Wiley-Interscience, 1998.

- [69] T.M. Mitchell. *Machine Learning*. McGraw-Hill International Editions. McGraw-Hill, 1997.
- [70] Tzu-Tsung Wong and Nai Yu Yang. Dependency analysis of accuracy estimates in k-fold cross validation. *IEEE Transactions on Knowledge and Data Engineering*, 29:1–1, 08 2017.
- [71] Margherita Grandini, Enrico Bagli, and Giorgio Visani. Metrics for multi-class classification: an overview. *ArXiv*, abs/2008.05756, 2020.
- [72] Kenji Kira and Larry A. Rendell. The feature selection problem: Traditional methods and a new algorithm. In *Proceedings of the Tenth National Conference on Artificial Intelligence*, AAAI'92, page 129–134. AAAI Press, 1992.
- [73] Marko Robnik-Sikonja and Igor Kononenko. An adaptation of relief for attribute estimation in regression. page 296–304, 1997.
- [74] Marko Robnik-Sikonja and Igor Kononenko. Theoretical and empirical analysis of relief and rrelieff. *Machine Learning*, 53:23–69, 10 2003.
- [75] Wei Yang, Kuanquan Wang, and Wangmeng Zuo. Neighborhood component feature selection for high-dimensional data. *JCP*, 7:161–168, 01 2012.
- [76] Chris Ding and Hanchuan Peng. Minimum redundancy feature selection from microarray gene expression data. *Journal of bioinformatics and computational biology*, 3(2):185–205, April 2005. Place: Singapore.
- [77] Shanshan Xie, Yan Zhang, Danjv Lv, Xu Chen, Jing Lu, and Jiang Liu. A new improved maximal relevance and minimal redundancy method based on feature subset. *The Journal of Supercomputing*, 79(3):3157–3180, February 2023.
- [78] Kai Sun, Zhenming Ding, and Ziyang Zhang. Fiber directional position sensor based on multimode interference imaging and machine learning. *Appl. Opt.*, 59(19):5745–5751, Jul 2020.
- [79] Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-sne. *Journal of Machine Learning Research*, 9:2579–2605, 11 2008.