



MAESTRÍA EN CIENCIAS EN INGENIERÍA AMBIENTAL

TESIS DE MAESTRÍA

Título

Caracterización de microplásticos en muestras líquidas

P R E S E N T A:

Ing. Yaneylis Méndez Hernández

Directora

Dra. Ma. Rosario González Mota

Co-director

Dr. J. Ascención Guerrero Viramontes

Asesor

Dr. Juan Reyes Luévano

Aguascalientes, Ags. 16 de enero de 2025



Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., **14/enero/2025**
Oficio No. DEPI 013/2025
Asunto: Autorización impresión tesis

C. YANEYLIS MÉNDEZ HERNÁNDEZ
PRESENTE

Los abajo firmantes, Miembros del Jurado para Examen de Grado de Maestría, hacemos **constar** que, habiendo revisado el Trabajo de Tesis desarrollado por Usted, bajo el título: **"Caracterización de microplásticos en muestras líquidas"**, hemos dictaminado que éste es de aceptarse, por lo que se autoriza su impresión.

Excelencia en Educación Tecnológica®
Ingenio, Cultura y Saber, que conducen a la Excelencia®

PRESIDENTE

DRA. MA. ROSARIO GONZÁLEZ MOTA


SECRETARIO

DR. J. ASCENSIÓN GUERRERO VIRAMONTES

VOCAL

DR. JUAN REYES LUÉVANO

ccp. Archivo
JFLH/yevo



2025
Año de
La Mujer
Indígena

Av. Adolfo López Mateos #1801. Fracc. Bona Gens
C.P. 20256 Aguascalientes, Ags. Tel. 449 910 5002 ext. 127
e-mail: jefatura.depi@aguascalientes.tecnm.mx
tecnm.mx | www.aguascalientes.tecnm.mx





Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., 15/enero/2025
Asunto: Autorización de uso de derechos

YANEYLIS MÉNDEZ HERNÁNDEZ, mayor de edad, con domicilio ubicado en **Susana 118, Bona Gens, CP 20255, Aguascalientes, Aguascalientes**, en mi calidad de titular y autor de la tesis denominada **"CARACTERIZACIÓN DE MICROPLÁSTICOS EN MUESTRAS LÍQUIDAS"** quien para todos los fines del presente documento se denominará **EL AUTOR Y/O TITULAR**, suscribo el presente documento de autorización de uso de derechos patrimoniales de autor a favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes el cual se registrará por las cláusulas siguientes:

PRIMERA – AUTORIZACIÓN: **EL AUTOR Y/O TITULAR**, mediante el presente documento autoriza la utilización de los derechos patrimoniales de autor al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, de la tesis denominada **"CARACTERIZACIÓN DE MICROPLÁSTICOS EN MUESTRAS LÍQUIDAS"**, a través del Repositorio Institucional del Tecnológico Nacional de México (en lo sucesivo TecNM) y en el Repositorio Nacional, que puede ser consultado en la liga electrónica: (www.repositorionacionalcti.mx/).

SEGUNDA – OBJETO: Por medio del presente escrito, **EL AUTOR Y/O TITULAR** autoriza al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, a través del Repositorio Institucional del TecNM y en el Repositorio Nacional para que de conformidad con la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, use los derechos del documento antes referido, con fines exclusivamente académicos.

TERCERA – TERRITORIO: Los derechos aquí autorizados se dan sin limitación geográfica o territorial alguna.

CUARTA – ALCANCE: La presente autorización se da tanto para formato o soporte material, y se extiende a la utilización en medio óptico, magnético, electrónico, en red, mensajes de datos o similar conocido o por conocer, del ejemplar o número respectivo de la publicación.

QUINTA – EXCLUSIVIDAD: La autorización de uso aquí establecida no implica exclusividad en favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes. Por lo tanto, **EL AUTOR Y/O TITULAR** en su carácter de autor de la obra objeto del presente documento se reserva el derecho de publicar directamente, u otorgar a cualquier tercero, autorizaciones de uso similares o en los mismos términos aquí acordados.



2025
Año de
La Mujer
Indígena

Av. Adolfo López Mateos #1801. Fracc. Bona Gens
C.P. 20256 Aguascalientes, Ags. Tel. 449 910 5002 ext. 127
e-mail: jefatura.depi@aguascalientes.tecnm.mx
tecnm.mx | www.aguascalientes.tecnm.mx





Instituto Tecnológico de Aguascalientes
División de Estudios de Posgrado e Investigación

SEXTA – DERECHOS MORALES (Créditos y mención): La Autorización de los derechos antes mencionados no implica la cesión de los derechos morales sobre los mismos por cuanto en conformidad con lo establecido en los artículos 18, 19, 20, 21, 22 y 23 de la Ley Federal de Derechos de Autor, dada la cuenta que estos derechos son inalienables, imprescriptibles, irrenunciables e inembargables. Por lo tanto, los mencionados derechos seguirán radicados en cabeza de EL AUTOR Y/O TITULAR, y siempre deberá mencionarse su nombre cuando se utilice la obra.

SÉPTIMA – AUTORÍA: EL AUTOR Y/O TITULAR, declara y ratifica que el material objeto de la presente fue realizada por él o por ella sin violar o usurpar derechos de Propiedad Intelectual de terceros.

ATENTAMENTE

Excelencia en Educación Tecnológica®

Ingenio, Cultura y Saber, que conducen a la Excelencia

Vo.Bo.

YANEYLIS MÉNDEZ HERNÁNDEZ
AUTOR DE LA TESIS

DRA. MA. ROSARIO GONZÁLES MOTA
DIRECTOR DE LA TESIS

ccp. Archivo



2025
Año de
La Mujer
Indígena

Av. Adolfo López Mateos #1801. Fracc. Bona Gens
C.P. 20256 Aguascalientes, Ags. Tel. 449 910 5002 ext. 127
e-mail: jefatura.depi@aguascalientes.tecnm.mx
tecnm.mx | www.aguascalientes.tecnm.mx



Instituto Tecnológico
de Aguascalientes





DEDICATORIA

A MI FAMILIA POR SU APOYO INCONDICIONAL QUE HA
SIDO MI FORTALEZA SIEMPRE,
A MI ESPOSO POR CREER EN MI INCLUSO CUANDO YO DUDABA,
A AQUELLAS PERSONAS QUE CREEN EN LO GRANDIOSO DE HACER
UN SUEÑO REALIDAD,
A MI CUBA BELLA Y TODOS MIS FORMADORES EN LO PROFESIONAL Y
PERSONAL POR HACERME LA PERSONA QUE HOY SOY,
A MI MEXICO LINDO Y QUERIDO, Y SU GENTE POR ABRIRME LAS PUERTAS DE
SU HOGAR.



AGRADECIMIENTOS

En primer lugar, agradezco infinitamente a mi familia por todo el apoyo incondicional ante la difícil decisión que fue aceptar estudios lejos de mi país y seres queridos. Gracias por su confianza, amor, esfuerzo y su inagotable apoyo emocional durante todo este proceso, gracias porque sin ustedes no lo hubiese logrado.

A mi esposo, por su paciencia, amor y confianza en todo momento. Gracias por soportarme en mis días de estrés, por apoyarme, animarme, guiarme y por admirar mi esfuerzo siempre, gracias por creer que lo lograría, incluso más que yo. Gracias por tu compañía en estos años complicados por estar ambos lejos de casa, gracias por tanto amor y comprensión, en fin, gracias por todo lo bueno y lo malo que nos ha tocado enfrentar en estos dos años, sin ti no lo hubiera conseguido.

Agradezco a todo el Consejo de profesores de la MCIA y al TecNM / Instituto Tecnológico de Aguascalientes por darme la oportunidad de formar parte de su comunidad, gracias por sus enseñanzas y profesionalismo. Especialmente agradezco a mis directores de proyecto, la Dra. Rosario González Mota y el Dr. J. Ascención Guerrero Viramontes por adoptarme con tanto cariño y por tanto aprendizaje adquirido, gracias por guiarme siempre en los caminos de la ciencia y por proveer de los medios necesarios para el desarrollo de la investigación. Gracias por tanta confianza y por dedicar su valioso tiempo en mi formación. Gracias a mi asesor el Dr. Juan Reyes Luévano y al M.Sc. Edgar Josué Camargo Pedraza por su ayuda con la programación del proyecto en el empleo de la inteligencia artificial. Asimismo, agradezco a La Secretaría de Ciencia, Humanidades, Tecnología e Innovación (Secihti) antes CONAHCyT por la ayuda económica brindada con la beca otorgada para los estudios de esta maestría.

Finalmente, y no menos importante, agradezco a mis compañeros de la MCIA y sus familiares por tanto cariño y apoyo en las buenas y malas, gracias también a todas aquellas personas que de una forma u otra hicieron posible este logro.



RESUMEN

Los microplásticos, partículas de tamaños inferiores a 5 mm, provenientes de exfoliantes, pastas dentales, productos de belleza, detergentes, fibras textiles y/o por la degradación física/química de los macroplásticos, han generado una elevada contaminación ambiental en diferentes ecosistemas, organismos y alimentos siendo de gran repercusión social, ambiental y de salud. La presencia de microplásticos en los ecosistemas acuáticos, estuarios, playas, sistemas de agua dulce, superficie oceánica entre otros ha sido la más abundante contaminación reportada debido a la baja degradabilidad que presentan los microplásticos en agua. Para la caracterización de los microplásticos se han empleado diferentes técnicas, sin embargo, es necesario continuar desarrollando métodos robustos, ya que no existen técnicas estandarizadas para su caracterización. Este proyecto de tesis se centró en la caracterización de los microplásticos en muestras líquidas empleando un algoritmo de inteligencia artificial basado en redes neuronales convolucionales que permitió detectar, cuantificar e identificar los microplásticos presentes en muestras de agua HPLC mediante el reconocimiento de patrones de imágenes. El uso de las redes neuronales convolucionales en la caracterización de los microplásticos contribuirá en la resolución de los problemas de contaminación ambiental permitiendo monitorear su presencia en los diferentes medios acuosos.



ÍNDICE

CAPÍTULO I. INTRODUCCIÓN	8
1.1. Planteamiento del problema.....	8
1.2. Justificación.....	8
1.3. Objetivos	9
1.3.1. Objetivo general	9
1.3.2. Objetivos específicos	9
CAPÍTULO II. MARCO TEÓRICO	10
2.1. Microplásticos	10
2.1.1. Clasificación de los MP	10
2.1.2. Tipos de plásticos	10
2.1.3. Daños ocasionados por los MP.....	13
2.2. Presencia de MP en cuerpos de agua	14
2.2.1. Ecosistemas marinos	14
2.2.2. Agua dulce	14
2.2.3. Agua embotellada	15
2.2.4. Aguas residuales de la industria textil	15
2.2.5. Aguas grises	16
2.3. Sistema óptico.....	17
2.3.1. Fuentes de iluminación	17
2.3.2. Cámaras fotográficas	18
2.4. Inteligencia artificial	20



2.4.1.	Red neuronal artificial	20
2.4.2.	Redes neuronales convolucionales.....	21
CAPÍTULO III. METODOLOGÍA.....		23
3.1.	Materiales.....	23
3.1.1.	Microplásticos	23
3.2.	Condiciones de trabajo.....	23
3.3.	Obtención de MP.....	23
3.3.1.	Molienda de los polímeros	23
3.3.2.	Separación de tamaños de los MP	24
3.4.	Preparación de soluciones con concentración conocida de MP	25
3.5.	Sistema óptico.....	26
3.6.	Sistema para la adquisición de imágenes	28
3.7.	Sistema de inteligencia artificial por CNN	28
3.7.1.	Preprocesamiento de imágenes.....	29
3.7.2.	Entrenamiento.....	29
3.7.3.	Validación.....	30
3.7.4.	Evaluación.....	30
3.8.	Detección de MP	30
3.9.	Cuantificación de MP	30
CAPÍTULO IV. RESULTADOS		32
4.1.	Imágenes de MP y de muestras de agua HPLC	32
4.2.	Modelo de estimación de intervalos de tamaño de MP	34



4.2.1.	Entrenamiento y validación de la CNN.....	34
4.2.2.	Evaluación de la CNN según intervalo de tamaños de MP	36
4.3.	Modelo de cuantificación de MP	39
4.3.1.	Entrenamiento y validación de la CNN.....	39
4.3.2.	Evaluación de la CNN conforme a la concentración de MP	41
4.4.	Modelo de estimación del tipo de material	44
4.4.1.	Entrenamiento y validación de la CNN.....	45
4.4.2.	Evaluación de la CNN según el tipo de material	46
CONCLUSIONES.....		50
REFERENCIAS BIBLIOGRÁFICAS		52



CAPÍTULO I. INTRODUCCIÓN

1.1. Planteamiento del problema

Los microplásticos (MP) provienen de diversas fuentes como exfoliantes, pastas dentales, productos de belleza y/o de la degradación física/química de los macroplásticos [1]. No obstante, han generado una situación ambiental de amplia repercusión social, ambiental y de salud relacionada con su presencia en diferentes organismos, alimentos y ecosistemas, siendo más abundantes en los ecosistemas acuáticos, estuarios, playas, sistemas de agua dulce, superficie oceánica y organismos marinos [2].

Los MP contienen aditivos, metales pesados y plastificantes, entre otros, que provocan impactos negativos no solo en el medio ambiente, sino también en los seres vivos, producto de su ingestión y toxicidad. Además, pueden adsorber en su superficie numerosos contaminantes y comportarse como vehículos de especies invasoras ocasionando mayor efecto tóxico [3].

En la caracterización de los MP se han utilizado diferentes técnicas que van desde la inspección visual, la microscopia óptica y electrónica hasta el empleo de técnicas espectroscópicas. Sin embargo, es necesario continuar desarrollando métodos robustos, ya que no existen técnicas estandarizadas para su caracterización [4]. Por lo tanto, en este proyecto se propone realizar la caracterización de MP presentes en muestras líquidas empleando un algoritmo de inteligencia artificial, basado en redes neuronales convolucionales (CNN).

1.2. Justificación

Los MP son de gran interés mundial debido a que pueden ser lo suficientemente pequeños para ser ingeridos por los animales marinos y terrestres, contaminando no solo a los animales sino también a las aguas, el suelo, el aire y los seres vivos en general [2].



Teniendo en cuenta la elevada contaminación que generan los MP en los ámbitos social, ambiental y de salud en este proyecto se propone el empleo de las CNN como herramienta avanzada que permitirá el desarrollo de técnicas más robustas para la identificación y cuantificación de MP, ayudando a su vez en la estandarización de técnicas para la caracterización de MP. Además, el uso de la inteligencia artificial podría coadyuvar en una resolución a los problemas de contaminación ambiental, sirviendo como antecedente a posteriores investigaciones que aportarían en el reconocimiento de patrones de imágenes, en la determinación de la concentración de los MP con mayor precisión y evitaría la interpretación visual y el trabajo manual [4].

1.3. Objetivos

1.3.1. Objetivo general

Caracterizar MP presentes en muestras de agua utilizando Redes Neuronales Convolucionales.

1.3.2. Objetivos específicos

- Detectar MP presentes en muestras de agua utilizando CNN.
- Cuantificar MP presentes en muestras de agua utilizando CNN.
- Determinar el intervalo de tamaño de los MP contenidos en agua utilizando CNN
- Identificar el tipo de MP en agua utilizando CNN.

CAPÍTULO II. MARCO TEÓRICO

2.1. Microplásticos

Los MP son partículas plásticas con tamaños menores a 5 mm [5]; caracterizadas por ser partículas sólidas, insolubles en agua, resistentes, flexibles y de baja degradabilidad, que se han convertido en una problemática a nivel mundial debido a su vigente amenaza en la calidad ambiental [2].

2.1.1. Clasificación de los MP

Los MP se clasifican en cuanto a su forma en cuatro clases distintas, copo, esfera, filamento y fibras, y de acuerdo con su origen pueden clasificarse en primarios o secundarios [5], [6].

- A) **MP primarios.** Los MP primarios son fabricados en este tamaño para ser utilizados en productos de belleza, exfoliantes, cremas dentífricas, geles, champús, productos de limpieza y artículos para el hogar [2]. Además, se ha reportado que el uso generalizado de impresoras 3D constituye una fuente importante de MP, liberando partículas pequeñas de alrededor de los 11,5 nm [5].
- B) **MP secundarios.** Los MP secundarios constituyen la fuente más común de contaminación debido a que se generan con la fragmentación de los macroplásticos por procesos naturales como la fotodegradación, la biodegradación, el estrés físico y las degradaciones termooxidativa y mecánica [6]. No obstante, esta fragmentación puede ocurrir antes de que los plásticos ingresen al medio ambiente, tal y como se evidencia en el caso de las fibras sintéticas liberadas durante el lavado de la ropa [5].

2.1.2. Tipos de plásticos

- **Cloruro de polivinilo (PVC):** Catalogado como el segundo material termoplástico de uso industrial, el PVC constituye uno de los polímeros sintéticos de mayor rango de

aplicaciones en sectores como la construcción, la medicina y el embalaje debido a sus destacadas propiedades elásticas. Además, se caracteriza por su versatilidad la cual le permite obtener tanto materiales rígidos como flexibles. Su desventaja más notable está ligada a su elevada inestabilidad térmica, fotoquímica y radioquímica. El PVC se sintetiza a partir de petróleo y cloruro de sodio mediante un proceso de polimerización donde estequiométricamente se encuentra compuesto por un 56,8% de cloro derivado del cloruro de sodio y un 43,2% de materiales provenientes de fuentes no renovables, como el petróleo y el gas natural [7].

- **Tereftalato de polietileno (PET):** El PET es un polímero termoplástico con alta cristalinidad, alta resistencia, ligereza y transparencia, lo que lo hace ideal para diversas aplicaciones industriales. Este polímero, además, se caracteriza por ser un material rígido y estable, resistente al desgaste, la humedad y los ataques químicos. Además, su excelente capacidad de barrera para gases como CO₂ y su aprobación para contacto con alimentos lo posicionan como un plástico versátil y sostenible. El PET es reciclable y puede transformarse mediante procesos como extrusión, inyección y soplado. Según su grado, puede usarse en fibras textiles, películas o aplicaciones de ingeniería. También se distingue por su alta viscosidad intrínseca, relacionada con la longitud de su cadena polimérica, que afecta su rigidez y propiedades finales. Así mismo, se utiliza ampliamente en envases de bebidas, alimentos, productos de limpieza y cosméticos, además de aplicaciones en fibras textiles, construcción y electrónica. Es por ello, que su capacidad para cumplir requisitos técnicos y ambientales lo convierten en un material esencial en la economía circular [8].
- **Poliestireno (PS):** Es un polímero termoplástico derivado de monómeros de estireno, reconocido por su alta rigidez y transparencia. Por otro lado, su estructura lineal facilita su proceso de moldeo, aunque tiene ciertas limitaciones, como su baja resistencia al calor, lo que lo hace inapropiado para aplicaciones que impliquen temperaturas elevadas. En términos de resistencia química, el PS soporta bien los

ácidos y bases diluidos, pero es vulnerable a solventes orgánicos como alcoholes y cetonas. También presenta baja absorción de agua, lo que lo hace adecuado para entornos con alta humedad. A pesar de su rigidez, el PS es un material frágil y quebradizo, especialmente en su forma no expandida, lo que limita su uso en aplicaciones que requieren gran resistencia al impacto. Se utiliza principalmente en la fabricación de envases desechables, empaques, componentes electrónicos, juguetes y como material aislante cuando se presenta en forma de espuma de PS. Aunque es reciclable, la tasa de reciclaje sigue siendo baja debido a las dificultades en su procesamiento y la falta de infraestructura adecuada en muchas regiones [8].

La densidad es una característica fundamental de todos los plásticos, la cual determina la ligereza y resistencia de los materiales para definir el campo de aplicaciones en los que se pueden emplear. De igual manera, esta propiedad indica la eficiencia que presenta el material en términos de diseño, manipulación y transporte. Por otra parte, la densidad se encuentra estrechamente vinculada con propiedades mecánicas y térmicas tales como las durabilidad, aislamiento térmico y flotabilidad. Los plásticos de alta densidad ofrecen una mayor resistencia ante el impacto y la abrasión, mientras que los plásticos de menor densidad destacan por sus buenas propiedades como aislantes, siendo útiles en aplicaciones para la electrónica y la construcción. Además, la densidad influye significativamente en la flotabilidad ya que los materiales menos densos que el agua (1g/cm^3 a 4°C) flotan, mientras que aquellos que son más densos tienden a hundirse, lo que resalta la importancia de esta propiedad tanto en aplicaciones prácticas como en la separación y el reciclaje [8].

En la Tabla 1 se muestra la densidad de los diferentes polímeros analizados en el presente estudio.

Tabla 1. Densidad de los polímeros PVC, PET, PS [9], [10].

Polímeros	Densidad
PVC	1.3-1.45 g/cm ³
PET	1.38 g/cm ³
PS	1.04-1.09 g/cm ³

2.1.3. Daños ocasionados por los MP

La ingestión de los MP puede ocurrir por numerosos organismos, entre ellos el plancton y organismos superiores como peces y mamíferos. La ingestión de los MP depende no solo de su tamaño, forma y densidad, sino también puede verse influenciada por el color. Aunque no son bien conocidos los mecanismos de toxicidad de los MP, se ha reportado que sus posibles efectos tóxicos se generan por formas diferentes: estrés causado por la ingestión, bloqueo físico, falsa saciedad, lixiviación de los aditivos de plásticos, como los plastificantes y la exposición a los contaminantes adsorbidos por MP, como los contaminantes orgánicos persistentes. Además, se han reportado que, entre los efectos directos que provocan los MP en organismos acuáticos y terrestres como aves marinas, peces y mamíferos marinos, se incluye la obstrucción del tracto digestivo y lesiones internas que provocan la disminución de la nutrición y posteriormente la inanición y muerte [5].

Los plásticos, en esencia, se caracterizan por ser inertes, no obstante, la gran mayoría contiene aditivos tales como plastificantes, retardantes de llama, colorantes y pigmentos; además, las reacciones de polimerización suelen ser incompletas lo que conlleva a que, por el fenómeno de lixiviación, monómeros, solventes y aditivos residuales sin reaccionar pueden migrar lejos de la matriz polimérica. Este proceso ocurre cuando los plásticos se exponen a condiciones adversas: contacto con líquidos, elevadas temperaturas o condiciones extremas de pH, ya sea durante su uso, en su degradación ambiental o mientras se almacenan en vertederos o cuerpos de agua. Además, algunos grupos de

plástico como el PVC, PS y el policarbonato (PC) liberan monómeros tóxicos que se relacionan con el desarrollo de anomalías reproductivas y cáncer en invertebrados, roedores y humanos. Un ejemplo de esto es la detección de partículas de PS en células de carcinoma de pulmón humano. Por otra parte, se ha demostrado que en algunos tejidos de un pez japonés se acumularon partículas de látex lo que evidenció que las partículas fueron capaces de cruzar la barrera hematoencefálica, muy importante para la función neuronal y la protección del cerebro, manifestando los potenciales riesgos para los animales y la salud de las personas [5].

2.2. Presencia de MP en cuerpos de agua

2.2.1. Ecosistemas marinos

La contaminación por MP en los ecosistemas marinos es ocasionada por diferentes fuentes que van desde la escorrentía terrestre y desechos industriales plásticos hasta los aparejos de pesca abandonados, entre otros. Las diferentes propiedades de los MP influyen en su distribución, flotabilidad y hundimiento dentro de los ecosistemas marinos lo que provoca su transferencia trófica a la biota marina. Los MP en el océano pueden adsorber y liberar tóxicos, los cuales son ingeridos por la biota marina y provocan daños internos en las especies marinas y posteriormente, los daños son transferidos a las personas, incidiendo en la alimentación y en la salud en general [11].

2.2.2. Agua dulce

La contaminación por MP en los ecosistemas acuáticos de agua dulce se presenta de manera compleja debido a la variedad de compartimientos ambientales que presentan donde se destacan las zanjas, arroyos, ríos, estuarios, estanques, represas y lagos permanentes. El vertido directo de basura, la inadecuada eliminación de los residuos y además su mala gestión provoca que los ecosistemas de agua dulce actúen como receptores, sumideros y transportadores de la contaminación microplástica. Los ríos tienen



un papel protagónico en el transporte de MP de la tierra hacia el océano, actuando como vía principal y hasta denominados como carreteras para MP [11]. Otras fuentes de MP en agua dulce incluyen el desbordamiento de alcantarillados causado por tormentas, la escorrentía superficial de tierras de cultivo y las descargas de aguas residuales provenientes de plantas de tratamiento [3].

2.2.3. Agua embotellada

La contaminación por MP en agua embotellada actualmente es un punto clave de investigación para los científicos, debido al riesgo que supone para la salud su consumo diario y en grandes cantidades. Algunos estudios encontraron MP en el 90% de 259 botellas analizadas y reportaron que la calidad de las botellas podría influir en la liberación de MP. La contaminación por MP en las aguas minerales embotelladas se encuentra fuertemente correlacionado con el pH del agua, pero sólo débilmente con la densidad plástica de la botella. Los MP provenientes de plásticos de mayor dureza provocan la liberación de fragmentos de MP de mayor tamaño, pero en menor número mientras que los MP provenientes de plásticos más deformables causan una contaminación mayor debido a que se fragmentan en tamaños muy pequeños y en mayor cantidad. Los MP por lo general, a medida que se degradan adquieren nuevas propiedades físicas y químicas, siendo dañinos para el organismo. Entre los vectores que ocasionan efectos tóxicos se encuentra el bisfenol A, algunos plastificantes como el ftalato de diisononilo y ftalato de diisodecilo, retardantes de llama y estabilizantes [12].

2.2.4. Aguas residuales de la industria textil

La industria textil utiliza una gran cantidad de agua para la elaboración de sus productos, 600 L por cada kg de textiles, generando una elevada contaminación por MP y diversos impactos negativos a los ecosistemas marinos debido a que sus efluentes sin tratamiento alteran las propiedades del agua. La presencia de fibras microplásticas y de distintos

compuestos químicos empleados como colorantes, provenientes de esta industria, son responsables de aproximadamente el 20% de la contaminación mundial del agua potable. Las fibras, por su parte, provenientes de artículos de ropa, bolsas plásticas, líneas y redes de pesca, constituyen una de las principales formas de MP que se han encontrado en el tracto gastrointestinal de los peces de agua dulce. Por otra parte, los colorantes influyen en el consumo de MP por parte de los peces, especialmente depredadores visuales y larvas de peces debida a la confusión por parte de los peces con sus presas naturales, de ahí la elevada presencia de MP en el contenido estomacal de las especies marinas. La mayoría de los MP de los textiles son liberados durante los primeros lavados; el 35% de los MP liberados en las aguas son producto del lavado de ropa sintética, mientras que el lavado de materiales sintéticos, en la actualidad, ha generado más de 14 millones de toneladas de MP que fueron a parar en el fondo de los océanos [13], [14], [15].

2.2.5. Aguas grises

Las aguas grises, aguas provenientes de las actividades domésticas excluyendo las aguas negras que contienen alto contenido fecal, poseen un elevado contenido de MP. Por ejemplo, las aguas provenientes de las lavadoras domésticas poseen una gran cantidad de fibras de materiales textiles que alcanzan ambientes acuáticos incluso después de realizarse un tratamiento ya que de una sola prenda de vestir sintética se pueden liberar más de 1900 microfibras por lavado. Además, la contaminación de las aguas también incrementa con los productos de aseo personal, ya sean pastas dentales, exfoliantes, productos de belleza, entre otros, que son fabricados con MP primarios y los mismos van a parar a los desagües, llegando a las depuradoras, las cuales presentan diferentes procesos para tratar las aguas pero muy pocos de ellos eliminan los MP; por lo que al devolver estas aguas a ríos, lagos, mares u océanos, provocan una contaminación elevada y ocasionan graves daños a las especies y ecosistemas acuáticos [16], [17].

2.3. Sistema óptico

La óptica es la ciencia que estudia las leyes y propiedades de la luz, su reflexión, refracción y absorción. Además, se refiere a los sistemas compuestos por lentes y espejos que sirve para observar imágenes u objetos agrandados que se emplea en aplicaciones cotidianas y tecnológicas [18], [19].

2.3.1. Fuentes de iluminación

Las fuentes de iluminación son dispositivos diseñados para generar y emitir radiación electromagnética dentro del rango de la luz visible, que pueden ser de origen natural como la luz del sol o artificiales, que son diseñadas por el hombre para satisfacer las necesidades de iluminación en diversos entornos. Entre las diferentes fuentes de iluminación existentes es importante resaltar las LED y láser debido a sus aplicaciones industriales, domésticas y científicas [20], [21].

El LED (*light-emitting diode*) es un dispositivo fotónico de un material semiconductor con dos terminales que emiten luz cuando se le suministra energía eléctrica. El diodo emisor de luz se caracteriza por ser una fuente luminosa de estado sólido capaz de recibir una corriente eléctrica moderada y emitir radiación electromagnética. La fuente LED presenta múltiples aplicaciones y ventajas que la han convertido en la principal fuente de luz frente a otras fuentes convencionales. La característica más relevante es su bajo consumo de voltaje, además de su material resistente y la larga vida útil que presenta, de más de 20 años. También se destaca por tener un tiempo de conmutación muy breve, referido a nanosegundos; además, teniendo en cuenta sus características físicas, los LED presentan una forma robusta y tamaño reducido y pueden fabricarse en diferentes colores como rojo, verde, azul, amarillo, ámbar o infrarrojo, mediante elementos como el arsénico, el fósforo y el galio, de manera más definida y no emiten excesivo calor ni producen campos magnéticos [21], [22].

El láser (*Light Amplification by Stimulated Emission of Radiation*) es una fuente de luz que produce un haz estrecho a una longitud de onda específica, es decir, es monocromático y coherente. Los láseres poseen tres componentes esenciales: un medio activo (sólido, líquido o gaseoso) que emite luz, un sistema de bombeo que lo excita y una cavidad resonante formada por dos espejos. Uno de los espejos es semi-reflectante, permitiendo que parte de la luz amplificada sea emitida como un haz. El principio del láser se basa en la inversión de población y la emisión estimulada. Los láseres emiten radiación polarizada, coherente y en una dirección específica, a diferencia de otras fuentes de luz que se emite en todas direcciones de ahí que se plantea que presenta propiedades únicas. Los láseres tienen diversos usos, pues se emplean en herramientas de precisión y pueden cortar diamantes o metales gruesos, se emplean en cirugías delicadas, en comunicaciones y en señales de televisión e internet, escáneres de códigos de barra e impresoras láser, en espectrómetros, etc. [22], [23].

2.3.2. Cámaras fotográficas

Las cámaras fotográficas son dispositivos tecnológicos e instrumentos ópticos compuestos estructuralmente de una caja cerrada a la luz, un lente convergente y una película que recibe la imagen. Las cámaras fotográficas tienen como función principal la toma de imágenes o fotografías mediante el registro de la luz en un medio fotosensible. Una de las características más importantes de las cámaras fotográficas es su resolución, la cual se caracteriza por ser la densidad de un conjunto de puntos con información acerca del color y el brillo de una imagen. Otra característica de gran importancia es el tipo de lentes en las cámaras, los cuales pueden estar contruidos de diferentes materiales que permitan el paso de la luz visible, tales como acrílicos o vidrio. El empleo de lentes permite definir factores como el acercamiento a un determinado punto en la imagen, la nitidez, el ángulo de incidencia y la saturación de color. Existen diferentes tipos de cámaras que se emplean con el objetivo de capturar imágenes y videos en algunos entornos entre las que se encuentran las cámaras profesionales, cámaras industriales y cámaras web [24].

- A) **Las cámaras profesionales:** ofrecen una amplia gama de características y configuraciones avanzadas que permiten un control total sobre la captura de imágenes y videos. Además, permiten obtener imágenes de muy alta calidad debido a la presencia de sensores de alta resolución, intercambiar lentes que hacen que se logren efectos fotográficos variados en diferentes situaciones y entornos y algunas cuentan con sistemas de enfoque automático avanzados, estabilización de imagen y ráfagas de disparo rápido. Los resultados que ofrecen estas cámaras son excepcionales desde una imagen de primera categoría a detalles y nitidez nunca vistos. Presentan una óptica y megapíxeles de alta calidad, y una amplia gama de conectividad disponible que favorecerá la transferencia de imágenes a los diferentes dispositivos en los que se desee tener [25].
- B) **Las cámaras industriales:** son un elemento de los sistemas de visión artificial que se utilizan tanto para las líneas de montaje como para los sistemas de seguridad de las empresas, instituciones u organizaciones de trabajo. Además, se caracterizan por ser dispositivos resistentes, duraderos ya que se han empleado en condiciones desfavorables de elevadas temperaturas y ambientes hostiles con humedad y polvo. Estas cámaras se emplean en la toma de imágenes y análisis de datos de las industrias, proporcionando información importante para la fabricación de productos de alta calidad. Son herramientas esenciales en la inspección de la calidad de los productos ya que sirven para detectar defectos, analizar colores e inspeccionar superficies. Las cámaras industriales presentan características que avalan su importancia ya que tienen incorporadas visión en la oscuridad, resistencia ante impactos y vibraciones y protección contra explosiones [26].
- C) **Las cámaras web:** son pequeños dispositivos especializados que se conectan al ordenador y que generalmente se emplean en las videollamadas, videoconferencias, videograbación de presentaciones, vigilancia de seguridad y para transmitir en vivo. Está equipada con lente, sensor de imagen, lámpara de iluminación y caja de luz que permite mejorar su rendimiento. Las cámaras web se conectan a una computadora o

a una red de computadoras a través de conexión USB o ethernet. Las cámaras web suelen tener una resolución más baja y presentar cancelación de ruido, ajuste automático de exposición, la capacidad de grabar videos en alta definición y no poseen la opción de cambiar las lentes [27].

2.4. Inteligencia artificial

La inteligencia artificial (IA) es una rama de las ciencias informáticas encaminada a la creación de maquinarias, ordenadores y equipos de robótica que tengan el comportamiento y la habilidad de emular el raciocinio de las personas, o sea, que sean capaces de imitar las funciones cognitivas de la mente humana para la realización de tareas asociadas a su inteligencia. La IA presenta diferentes aplicaciones como es el reconocimiento de objetos y personas en imágenes o videos, diagnóstico de enfermedades, toma de decisiones, traducción automática de textos, entre otras [28].

2.4.1. Red neuronal artificial

Las redes neuronales artificiales (RNA) son modelos matemáticos que intentan simular el comportamiento del cerebro humano y del sistema nervioso ya que están basados en las redes neuronales biológicas. Las estructuras de las RNA están formadas por nodos o neuronas situados en diferentes capas. Las neuronas se conectan entre sí mediante enlaces de comunicación los cuales tienen asociados un determinado peso que representarán la información que será usada por la red para dar solución a los problemas que se presenten. Las RNA se caracterizan por ser sistemas que se adaptan a determinadas situaciones para las que previamente ya se ha entrenado, o sea que son sistemas adaptativos [29]. Las RNA presentan diversas ventajas ya que permiten el procesamiento en paralelo, es decir, procesar a la vez múltiples entradas, lo que las convierte en una herramienta muy eficiente. Además, son capaces de analizar y procesar señales, filtrar ruidos, controlar procesos, analizar datos financieros y su aprendizaje automático es tan elevado que le permite

aprender y adaptarse a los cambios en los datos de entrada, convirtiéndolas en una herramienta ideal para aquellas situaciones difíciles de predecir y donde los datos presentan fluctuaciones [30].

A) Entrenamiento de la red neuronal

El entrenamiento de una red neuronal se basa en el aprendizaje de la propia red para realizar diferentes tareas y obtener una salida deseada teniendo en cuenta el entorno que se está controlando. Dicho entrenamiento varía según el tipo de red que se esté trabajando [31]. En esta etapa, la red aprende acerca de todos sus pesos, los cuales se inicializarán con un determinado valor para así comenzar con la iteración del algoritmo y en la búsqueda de los pesos para la entrada [32].

2.4.2. Redes neuronales convolucionales

Las CNN por sus siglas en inglés, son un tipo de RNA en la cual las neuronas artificiales realizan la imitación de la corteza visual del ojo humano con el objetivo de identificar las características de entrada que le permitan detectar, identificar y clasificar imágenes u objetos. Además, su principal tarea se basa en la extracción de patrones. En las CNN las neuronas se comparten a través de filtros que permiten extraer información de las imágenes de entrada. En este tipo de redes las capas convolucionales son filtros denominados campos receptivos que se ajustan para realizar la extracción de características de una señal determinada. Cada capa constituye un bloque que vincula tres variables principales: la entrada, el peso y la salida y en ellas se evidencia como la salida de una capa se convierte en la entrada de la siguiente capa, comportándose como un proceso secuencial [29]. Las CNN no solo potencian el reconocimiento de imágenes, sino también, las tareas de visión por computadora ya que permite obtener información importante de videos, imágenes digitales u otras entradas visuales en general. La aplicación de las CNN sobre esta visión les permite a las plataformas de redes sociales sugerir sobre personas que puedan aparecer



en determinadas fotografías. No obstante, también se ha visto su aplicación en el área de la salud permitiéndole a los médicos identificar con mayor precisión tumores cancerosos en una anatomía sana. Además, las CNN permiten el procesamiento de datos en dos dimensiones y el reconocimiento de señales de voz en espectrogramas [30].

CAPÍTULO III. METODOLOGÍA

3.1. Materiales

3.1.1. Microplásticos

Los microplásticos analizados en este trabajo fueron los siguientes:

- A) PVC
- B) PET
- C) PS

3.2. Condiciones de trabajo

En el desarrollo de la presente investigación se usaron batas de laboratorio 100% de algodón y guantes de nitrilo. Además, previamente se lavaron todos los materiales utilizados con un surfactante adecuado y se enjuagaron con una solución de agua-acetona 70/30.

3.3. Obtención de MP

3.3.1. Molienda de los polímeros

Los diferentes tipos de polímeros se trituraron empleando una pulverizadora de plásticos, Figura 1, y se almacenaron en cajas Petri para evitar la mezcla entre ellos.



Figura 1. Pulverizadora de plásticos.

3.3.2. Separación de tamaños de los MP

A) Tamizado

Los MP se tamizaron empleando tamices de diferentes tamaños de poro 180 μm , 150 μm , 125 μm y 75 μm , ver Figura 2, con el objetivo de separar los MP generados después de la pulverización en diferentes tamaños. Es importante mencionar que los diferentes tipos de MP se tamizaron por separado, por lo que en cada cambio de material se limpiaron correctamente los tamices para evitar la mezcla de diferentes partículas de MP. Cada tipo de MP se reservó en cajas Petri.




Figura 2. Tamizado de MP utilizando tamices de diferentes tamaños de poro: 180 μm , 150 μm , 125 μm y 75 μm .

Los tamices mostrados en la Figura 2 se limpiaron previamente mediante aire a presión para asegurar la limpieza y evitar la contaminación de los MP tamizados. Producto de esta separación de tamaños se obtuvieron diferentes intervalos que se muestran en la Figura 3.




Figura 3. Intervalos de tamaños de MP obtenidos de los diferentes tamices empleados.

B) Filtrado de MP

El tamizado obtenido del tamiz de 75 µm se sometió a un proceso de filtración a vacío con filtros de tamaños de poro de 20 µm obteniendo partículas de MP en un intervalo de tamaños de $20 \mu\text{m} < MP < 75 \mu\text{m}$. Las partículas retenidas en el filtro se recogieron y se sometieron a un secado a temperatura ambiente para eliminar toda su humedad y almacenarlas para el posterior uso.

3.4. Preparación de soluciones con concentración conocida de MP

La preparación de soluciones con concentración conocida se realizó pesando, mediante una balanza analítica OHAUS Pioneer, las diferentes masas de MP necesarias para cada una de las concentraciones conocidas ver Tabla 2. Las 16 soluciones preparadas presentaron concentraciones diferentes para cada uno de los MP empleados, variando el intervalo de tamaño de MP cada 4 concentraciones analizadas. Dicha preparación se llevó a cabo mediante el empleo de una cubeta de vidrio (Figura 4), donde se mezclaron los MP con agua HPLC en un $V = 55 \text{ mL}$ para los MP de PVC y PET y en un $V = 40 \text{ mL}$ para los MP de PS.

Tabla 2. Relación de las diferentes concentraciones de MP por intervalo de tamaño.

CONCENTRACIÓN	INTERVALOS DE TAMAÑO			
	150-180 μm	125-150 μm	75-150 μm	20-75 μm
	$c_1 = 18.18 \mu\text{g/mL}$	$c_5 = 90.90 \mu\text{g/mL}$	$c_9 = 163.63 \mu\text{g/mL}$	$c_{13} = 236.36 \mu\text{g/mL}$
	$c_2 = 36.36 \mu\text{g/mL}$	$c_6 = 109.09 \mu\text{g/mL}$	$c_{10} = 181.81 \mu\text{g/mL}$	$c_{14} = 254.54 \mu\text{g/mL}$
	$c_3 = 54.54 \mu\text{g/mL}$	$c_7 = 127.27 \mu\text{g/mL}$	$c_{11} = 200 \mu\text{g/mL}$	$c_{15} = 272.72 \mu\text{g/mL}$
	$c_4 = 72.72 \mu\text{g/mL}$	$c_8 = 145.45 \mu\text{g/mL}$	$c_{12} = 218.18 \mu\text{g/mL}$	$c_{16} = 290.90 \mu\text{g/mL}$



Figura 4. Celda de vidrio de 75 mm de alto, 50 mm de ancho, 15 mm de profundidad y una capacidad de 65 mL empleada para la preparación de las muestras.

Cada muestra preparada, MP + Agua HPLC, se agitó por un tiempo de 20 minutos para lograr una adecuada homogenización y evitar la aglomeración de MP en el menisco de la solución.

3.5. Sistema óptico

La configuración del sistema óptico consiste en una fuente de iluminación LED azul, un espejo y una cámara industrial (Figura 5).

Debido a que cada MP se comporta diferente al estar suspendido en el agua, relacionado fundamentalmente con la propiedad densidad, se incluyó en la configuración del sistema óptico, un sistema de flujo de aire proporcionado por un compresor mediante conexiones diseñadas en 3D y mangueras de látex, el cual evitó la flotabilidad de los MP en el menisco de la solución (Figura 6).





Figura 5. Sistema óptico empleado.




Figura 6. Tapa de celda, conexión de aire y mangueras de látex.

Asimismo, para evitar que los MP con mayor densidad sedimentaran en la solución, se añadió al sistema óptico, un sistema de impulsores compuesto por un agitador magnético y tres mezcladores magnéticos que permitieron que las partículas de MP estuvieran en constante movimiento dentro de la muestra. Los mezcladores magnéticos empleados fueron seleccionados con el objetivo de maximizar el área efectiva de la paleta impulsora y, además, para mantener la solución en continuo movimiento y lograr capturar diferentes imágenes en cada instante de tiempo, ver Figura 7.



Figura 7. Mezcladores magnéticos.

3.6. Sistema para la adquisición de imágenes

Para la adquisición de imágenes se utilizó un módulo de control de raspberry pi 4, como herramienta, que permitió el control y la integración automatizada de cada una de las partes del sistema: sistema de iluminación, sistema de flujo de aire, sistema de impulsores y captura de imágenes. Asimismo, se utilizó una interfaz de usuario que permitió una gestión eficiente de todos los sistemas y aportó herramientas importantes para el correcto funcionamiento del sistema. La interfaz permitió controlar la iluminación del sistema ya que presenta diferentes opciones de fuentes de iluminación a seleccionar de acuerdo con lo que se esté analizando en cada caso, permitiendo así, una mejor visibilidad de los MP en el agua. Por otra parte, esta interfaz presentó una vista previa, es decir que permitió la visualización en tiempo real de la muestra de agua HPLC + MP y además proporcionó a los usuarios un trabajo más sencillo ya que mediante esa vista previa se pudieron realizar ajustes en los diferentes sistemas y la posición de la celda para que la imagen obtenida presentara la mejor calidad posible. Otra de las cosas que permitió esta interfaz fue lo correspondiente con la automatización de la cámara ya que posibilitó una captura automática, continua y de calidad de las imágenes de interés, permitiendo de esta forma la captura de miles de imágenes que fueron necesarias para el procesamiento por las CNN.

De cada una de las muestras preparadas se tomaron 3,000 imágenes, así como de agua HPLC, que se utilizó como control. Un grupo de imágenes de agua HPLC fueron tomadas haciendo uso del sistema de flujo de aire, mientras que otras se tomaron sin utilizar el sistema de flujo de aire.

3.7. Sistema de inteligencia artificial por CNN

La CNN estuvo compuesta por tres modelos de estimación referidos a los intervalos de tamaños de MP, la cuantificación de MP y la identificación del tipo de MP.

3.7.1. Preprocesamiento de imágenes

La región de interés de las imágenes se obtuvo mediante una herramienta desarrollada en el laboratorio, que utiliza CNN y un código de Python que permitió seleccionar la región de interés, ROI, de las imágenes, así como la organización de las mismas en cuanto a sus tamaños y formatos. También, se asignaron nuevos nombres a los archivos siguiendo un esquema estructurado, con el propósito de agilizar su ordenamiento y hacer más sencilla su identificación posterior. Por otra parte, se redimensionaron las imágenes a una resolución estándar de 150x150 píxeles para asegurar uniformidad en los datos, reducir la complejidad computacional, evitar sesgos en el aprendizaje, garantizar compatibilidad con modelos predefinidos y mejorar la generalización del modelo en el aprendizaje automático. Además, se efectuó un proceso de aleatorización de las imágenes mediante ciclos de mezclado para evitar sesgos en el análisis y garantizar que los datos estuvieran distribuidos de manera equitativa, lo cual aseguró que el modelo de aprendizaje automático no se inclinara hacia patrones específicos del orden original de los datos, favoreciendo un entrenamiento más robusto y resultados generalizables. Las imágenes se dividieron en tres grupos: un conjunto de entrenamiento, validación y otro conjunto de prueba.

3.7.2. Entrenamiento

El algoritmo de inteligencia artificial, CNN, ya desarrollado fue alimentado con el 50% de las imágenes capturadas de las muestras con diferentes tamaños y concentraciones de MP, donde se ajustaron sus pesos para que la CNN aprendiera a reconocer los patrones de las imágenes. Se realizó un entrenamiento para cada modelo de estimación el cual obtuvo un buen desempeño. Esta decisión se tomó considerando los tiempos de procesamiento de las imágenes y la disponibilidad de una única GPU.

3.7.3. Validación

En la validación, como proceso simultáneo al entrenamiento, se alimentó el 25% de las imágenes capturadas inicialmente. La red una vez entrenada, propagó la información, ajustando los pesos y corrigiendo los errores hasta que la estimación arrojada mostró convergencia, es decir, que se entrenó y validó a la par hasta que se comprobó que el sistema fue capaz de reconocer por sí solo los MP en solución con agua grado HPLC.

3.7.4. Evaluación

En la evaluación, se empleó el 25% restante del total de imágenes que no fueron utilizadas en el paso de entrenamiento y validación. Estas imágenes de las muestras con concentraciones conocidas se alimentaron a la red con el objetivo de medir la precisión del sistema en la detección de MP, dando una estimación con base a lo aprendido. Además, se evaluó la confiabilidad del sistema mediante el error arrojado y realizando una comparación de los datos obtenidos con los de referencia.

3.8. Detección de MP

Al algoritmo de IA se introdujeron las imágenes de prueba para detectar MP. Dicho algoritmo permitió la detección de MP por medio de bordes y píxeles mediante la generación de los mapas de estimación que son regiones altamente probables a que pertenezcan a un MP. Además, permitió definir los bordes de esa partícula y cómo se comporta un MP en el reflejo de la luz. Con la obtención de los mapas de estimación como imágenes análogas a la muestra se logró resaltar con alta probabilidad las regiones que fueron MP afirmando la existencia de los MP en las muestras analizadas.

3.9. Cuantificación de MP

En la cuantificación de MP se empleó un modelo basado en una curva de probabilidad, por lo tanto, al algoritmo se le introdujo un vector de entrada con la concentración determinada



y se le pidió que realizara una estimación mediante su sistema de inteligencia artificial ya que aprende mediante el aspecto visual tal y como lo hace el cerebro humano. De esta forma se logró cuantificar los MP en las muestras mediante la comparación entre lo real y lo estimado.

CAPÍTULO IV. RESULTADOS

4.1. Imágenes de MP y de muestras de agua HPLC

Algunas imágenes capturadas del agua HPLC se muestran en la Figura 8, en las cuales se observa el comportamiento del agua HPLC con y sin el empleo del sistema de flujo de aire.




Figura 8. Imágenes de muestras de agua HPLC, A) sin utilizar el sistema de flujo de aire y B) utilizando el sistema de flujo de aire.

A cada una de las muestras de agua HPLC y de MP se le tomaron 3,000 imágenes para su procesamiento mediante CNN. En las Figuras 9, 10 y 11 se muestran algunas de las imágenes capturadas, del total de las 150,000 imágenes aproximadamente, para muestras con diferente concentración e intervalos de tamaño de MP.

En las imágenes de las Figuras 9, 10 y 11 se muestra el comportamiento de los diferentes MP en agua, sometidos a las condiciones del sistema empleado, comprobando que el sistema de flujo de aire y sistema de impulsores cumplieron con su función de mantener las partículas en continuo movimiento y distribuidas por toda la celda, evitando así concentraciones en el menisco de las soluciones.




Figura 9. Imágenes de MP de PVC en los cuatro intervalos de tamaño y las 16 concentraciones diferentes A) Intervalo 180-150 μm , concentración: i) 18, ii) 36, iii) 54 y iv) 72 $\mu\text{g/mL}$; B) Intervalo 150-125 μm ; concentración: i) 90, ii) 109, iii) 127 y iv) 145 $\mu\text{g/mL}$; C) Intervalo 125-75 μm ; concentración: i) 163, ii) 181, iii) 200 y iv) 218 $\mu\text{g/mL}$; D) Intervalo 75-20 μm ; concentración: i) 236, ii) 254, iii) 272 y iv) 290 $\mu\text{g/mL}$.




Figura 10. Imágenes de MP de PET en los cuatro intervalos de tamaño y las 16 concentraciones diferentes A) Intervalo 180-150 μm , concentración: i) 18, ii) 36, iii) 54 y iv) 72 $\mu\text{g/mL}$; B) Intervalo 150-125 μm ; concentración: i) 90, ii) 109, iii) 127 y iv) 145 $\mu\text{g/mL}$; C) Intervalo 125-75 μm ; concentración: i) 163, ii) 181, iii) 200 y iv) 218 $\mu\text{g/mL}$; D) Intervalo 75-20 μm ; concentración: i) 236, ii) 254, iii) 272 y iv) 290 $\mu\text{g/mL}$.




Figura 11. Imágenes de MP de PS en los cuatro intervalos de tamaño y las 16 concentraciones diferentes A) Intervalo 180-150 μm , concentración: i) 18, ii) 36, iii) 54 y iv) 72 $\mu\text{g/mL}$; B) Intervalo 150-125 μm ; concentración: i) 90, ii) 109, iii) 127 y iv) 145 $\mu\text{g/mL}$; C) Intervalo 125-75 μm ; concentración: i) 163, ii) 181, iii) 200 y iv) 218 $\mu\text{g/mL}$; D) Intervalo 75-20 μm ; concentración: i) 236, ii) 254, iii) 272 y iv) 290 $\mu\text{g/mL}$.

4.2. Modelo de estimación de intervalos de tamaño de MP

Para la estimación de intervalos de tamaño de MP se analizaron cinco categorías, los cuatro intervalos de tamaño de MP y el agua HPLC. Primeramente, se realizó un mezclado de las imágenes de agua HPLC y de todas las imágenes del mismo intervalo de tamaño para cada uno de los MP, tomando una cantidad de 10,200 imágenes por cada categoría, siendo un total de 51,000 imágenes a procesar por esta red neuronal.

4.2.1. Entrenamiento y validación de la CNN

En la etapa de entrenamiento de la CNN de las 10,200 imágenes tomadas se usaron 5,100 imágenes de cada una de las categorías para entrenar la red, dejando el restante número de imágenes para las etapas de validación y evaluación. Las etapas de entrenamiento y

validación se realizaron de manera simultánea tal y como se evidencia en las Figura 12 y Figura 13, mostrando una convergencia entre ambas etapas de la CNN.




Figura 12. Curvas de efectividad del modelo de entrenamiento y validación.

En la Figura 12 se muestran las curvas de efectividad del modelo, las cuales indican la rápida mejora en la precisión a medida que transcurrieron las épocas, estabilizándose cerca de la unidad tanto en entrenamiento como en validación con valores de *accuracy* de 0.9995 y 0.9998 respectivamente. Asimismo, se comprobó la alta efectividad del modelo tanto para la etapa de entrenamiento como la de validación mediante las curvas de pérdida (Figura 13).




Figura 13. Curvas de pérdidas del modelo de entrenamiento y validación.

La Figura 13 muestra una medida del error del modelo con valores de *training* y *validation loss* de 0.0013 y 0.0046 respectivamente. Además, permitió conocer la diferencia entre los resultados obtenidos y las predicciones reales, indicando que mientras más bajo fue el valor de pérdida, el desempeño del modelo fue mejor.

En ambas figuras se muestran patrones opuestos ya que a medida que la precisión aumenta, la pérdida disminuye a valores cercanos a cero lo que indica que el modelo optimizó su capacidad para hacer predicciones precisas. Estos resultados demostraron que tanto las imágenes generadas como su procesamiento fueron efectivos para entrenar y validar la CNN y que, además, la relación pérdida baja - alta precisión sugiere que el modelo ha logrado un aprendizaje correcto y un buen ajuste.

4.2.2. Evaluación de la CNN según intervalo de tamaños de MP

En la etapa de evaluación del modelo se realizaron estimaciones de intervalos de tamaños de MP utilizando 2,550 imágenes, que el modelo no había visto, de cada una de las categorías.

La Figura 14 muestra la estimación del intervalo de tamaño de MP para la categoría agua HPLC de cada una de las 2,550 imágenes. Además, el modelo realiza la estimación con un promedio de $1.79 \times 10^{-18} \mu\text{m}$, lo cual indica que en las muestras de agua HPLC no se detectaron partículas de MP. Estos resultados reflejan la capacidad del modelo para detectar que las muestras de agua HPLC no contienen MP.




Figura 14. Estimación de intervalo de tamaño de MP para muestras de agua HPLC.

Las estimaciones de intervalos de tamaño de MP para las cuatro categorías restantes realizadas por el modelo de CNN, tal y como se muestra en la Figura 15, indican que cada una de las categorías analizadas se mantuvieron dentro de los intervalos de tamaño definidos previamente con diferentes promedios de estimación de A) 164.93 μm , B) 137.49 μm , C) 100.02 μm y D) 47.52 μm . Las gráficas correspondientes a las categorías A), C) y D) muestran algunas estimaciones fuera de los intervalos definidos. Estas desviaciones pudieron ser causadas por errores de la experimentación o por las variaciones de la red neuronal.

En la Tabla 3 se muestra la relación entre las estimaciones realizadas por la CNN y el error que estas representaron, siendo el error global de un 0,05%, lo cual corrobora que la mayoría de las estimaciones estuvieron en los intervalos de tamaño definidos y que el desempeño del modelo fue notablemente preciso y confiable.




Figura 15. Estimación de intervalo de tamaño de MP para las categorías: A) 150-180 μm , B) 125-150 μm , C) 75-125 μm , D) 20-75 μm .

Tabla 3. Relación entre las estimaciones de intervalo de tamaño y el error arrojado.

Estimación de intervalo de tamaño de MP			
Intervalo de Tamaño (μm)	Estimaciones Correctas	Estimaciones Incorrectas	% Error
0	2550	0	0
20-75	2549	1	0.04
75-125	2549	1	0.04
125-150	2550	0	0
150-180	2446	4	0.16
Error promedio Global			0.05%

Estos resultados demuestran que tanto la experimentación como la técnica empleada para la estimación presentaron niveles de precisión elevados, convirtiéndolos en una herramienta efectiva para la caracterización de muestras de MP.

4.3. Modelo de cuantificación de MP

La cuantificación de MP se realizó analizando diecisiete categorías, es decir, dieciséis concentraciones diferentes de MP y el agua HPLC sin MP. Primeramente, se realizó un mezclado de las imágenes de agua HPLC y de todas las imágenes de la misma concentración para cada uno de los MP, analizando 3,000 imágenes por cada categoría, siendo un total de 51,000 imágenes a procesar por esta red neuronal.

4.3.1. Entrenamiento y validación de la CNN

En la etapa de entrenamiento de la CNN, se alimentaron 1,500 imágenes de cada una de las categorías para entrenar la red, dejando la cantidad de imágenes restante para las etapas de validación y evaluación. Las etapas de entrenamiento y validación se realizaron de manera simultánea.

La Figura 16 muestra las curvas que reflejan la efectividad del modelo, evidenciando una rápida mejora en la precisión conforme avanzaron las épocas, hasta estabilizarse cerca de la unidad con valores de exactitud de 0.9994 para el entrenamiento y 0.9999 para la validación. De igual manera, las curvas de pérdida, Figura 17, confirman la elevada efectividad del modelo en ambas etapas, tanto en el entrenamiento como en la validación.




Figura 16. Curvas de efectividad del modelo de entrenamiento y validación.




Figura 17. Curvas de pérdidas del modelo de entrenamiento y validación.

La Figura 17 muestra la evaluación del error del modelo con valores de pérdida para el entrenamiento y la validación de 0.0022 y 0.0014, respectivamente. Esto permitió analizar las discrepancias entre las predicciones y los resultados reales, indicando que mientras el valor de pérdida fue más bajo, el desempeño del modelo fue mejor.

En ambas figuras se observan patrones inversos ya que a medida que la precisión se incrementa, la pérdida disminuye, acercándose a cero, tal como se esperaba, lo que

significa que el modelo optimiza su capacidad para realizar predicciones precisas y que aprende adecuadamente.

4.3.2. Evaluación de la CNN conforme a la concentración de MP

Para la evaluación del modelo de cuantificación de MP se emplearon 750 imágenes, no habían sido vistas por el modelo previamente, de cada una de las categorías. A partir de estas imágenes, se realizaron estimaciones de concentraciones de MP.

En la Figura 18 se muestra la estimación de concentración para cada una de las 750 imágenes del agua HPLC.




Figura 18. Estimación de concentración de MP para muestras de agua HPLC.

La estimación muestra que en las muestras de agua HPLC no se encontraron partículas de MP, ya que la gráfica presenta una línea continua encima del eje de las abscisas con concentraciones de cero para cada una de las imágenes analizadas. Dicha estimación tuvo un promedio de 5.13×10^{-6} µg/mL, lo que indica una alta precisión del modelo al estimar y detectar concentraciones inexistentes de MP en muestras de agua.

Asimismo, se estimaron las diferentes concentraciones de MP para las categorías restantes, ver Figura 19. En la Figura 19 se muestran las gráficas de las diferentes concentraciones estimadas por el modelo, donde se observa que las curvas de estimación para cada concentración fueron relativamente cercanas a las concentraciones reales, lo cual indica que el modelo realiza la correcta estimación con elevada precisión. Por otra parte, las gráficas E, F, G, H y K mostraron fluctuaciones en los resultados de concentración, reflejando tanto la ocurrencia de errores experimentales como posibles limitaciones del modelo en esas categorías. En la Tabla 4 se muestra la información arrojada por el modelo en cuanto a la relación entre el valor real de concentración y el valor estimado, junto a los errores promedios asociados.

Tabla 4. Valores de concentración de MP reales y los estimados por el modelo.

Cuantificación Global de MP		
Concentración real ($\mu\text{g/mL}$)	Estimación Promedio ($\mu\text{g/mL}$)	Error Promedio ($\mu\text{g/mL}$)
0	5.13×10^{-06}	5.13×10^{-06}
18.18	18.18	0
36.36	36.34	0.02
54.54	54.54	0
72.72	72.73	0.01
90.9	91.04	0.14
109.9	109.62	0.28
127.27	126.94	0.33
145.45	145.88	0.43
163.63	163.63	0
181.81	181.82	0.01
200	199.90	0.10
218.18	218.17	0.01
236.36	236.30	0.06
254.54	254.44	0.10
272.72	272.82	0.10
290.9	290.86	0.04
Error promedio Global		0.10 $\mu\text{g/mL}$




Figura 19. Estimación de concentraciones de MP para las dieciséis muestras de agua HPLC + MP preparadas.

Los resultados mostrados en la Tabla 4 indican una alta similitud en los valores estimados por el modelo con los valores reales de concentración, lo cual se comprobó con el error promedio global del análisis, $0.10 \mu\text{g/mL}$. Este error muestra el desempeño altamente preciso del modelo de cuantificación de MP en muestras de agua HPLC.

La representación gráfica, Figura 20, de la información de la Tabla 4 muestra, de manera clara y precisa, la correspondencia entre los valores estimados por el modelo con los valores reales, quedando prácticamente ambas líneas superpuestas indicando que el modelo de cuantificación de MP tiene un buen ajuste y estimaciones cercanas a la real en la predicción de valores, reflejando una alta capacidad de aprendizaje y adaptación a las características de las imágenes que se alimentaron.




Figura 20. Concentraciones de MP reales y estimadas en muestras líquidas.

4.4. Modelo de estimación del tipo de material

En la estimación del tipo de material se analizaron cuatro categorías, los diferentes tipos de MP, PVC, PET, PS, y el agua HPLC. Para este análisis, primeramente, se realizó un

mezclado de las imágenes del mismo material y luego se tomaron 12,750 imágenes de cada categoría, siendo un total de 51,000 imágenes a procesar por esta red neuronal.

4.4.1. Entrenamiento y validación de la CNN

En la etapa de entrenamiento de la CNN de las 12,750 imágenes tomadas se usaron 6,375 imágenes de cada una de las categorías para entrenar la red, dejando el resto de las imágenes para las etapas de validación y evaluación. Las etapas de entrenamiento y validación fueron llevadas a cabo de manera simultánea; en las Figura 21 y Figura 22 se muestra la convergencia entre ambas etapas de la CNN.




Figura 21. Curvas de efectividad del modelo de entrenamiento y validación.

La Figura 21 muestra las curvas de efectividad del modelo, las cuales indicaron la precisión adquirida por el modelo a medida que pasaron las épocas, estabilizándose cerca de la unidad tanto en entrenamiento como en validación con valores de *accuracy* de 0.9931 y 0.9948 respectivamente. Asimismo, se comprobó la alta efectividad del modelo tanto para la etapa de entrenamiento como la de validación mediante las curvas de pérdida, ver Figura 22.




Figura 22. Curvas de pérdidas del modelo de entrenamiento y validación.

La Figura 22 muestra una medida del error del modelo con valores de *training* y *validation loss* de 0.0145 y 0.0212 respectivamente. Además, permite conocer la diferencia entre los resultados obtenidos de los resultados reales, indicando que mientras más bajo el valor de pérdida, el desempeño es mejor.

En ambas figuras se muestran patrones opuestos ya que a medida que la precisión aumenta, la pérdida disminuye, en valores cercanos a cero, lo que significa que el modelo ha optimizado su capacidad para hacer predicciones precisas. Estos resultados demuestran que tanto las imágenes generadas como su procesamiento fueron efectivos para entrenar y validar la CNN y que, además, la relación pérdida baja-alta precisión sugirieron que el modelo ha logrado un buen ajuste y aprendizaje.

4.4.2. Evaluación de la CNN según el tipo de material

En la etapa de evaluación del modelo se utilizaron 3,188 imágenes de cada una de las categorías, las cuales no habían sido vistas y se realizaron estimaciones según el tipo de material a emplear.

En la Figura 23 se muestra la gráfica de estimación para la categoría agua HPLC (0 MPs), en la cual la red estimó el tipo de MP de cada una de las 3,188 imágenes de prueba.




Figura 23. Estimación según tipo de material para muestras de agua HPLC.

La estimación realizada para el agua HPLC demostró una vez más que no se encontraron partículas de MP en el agua ya que la gráfica indica la ausencia de MP y, por ende, la imposibilidad de clasificar el tipo de MP en esa categoría.

Las estimaciones según el tipo de material para las tres restantes categorías, PVC, PET y PS se muestran en la Figura 24. Las estimaciones realizadas por el modelo de CNN indican que la mayor cantidad de las 3,188 imágenes tuvieron una adecuada correspondencia en cuanto a la clasificación del material. Sin embargo, para el PS y PET se observaron fluctuaciones que pudieran indicar que el modelo no relacionó el tipo de MP en cuestión, sin embargo, esas fluctuaciones corresponden a estimaciones incorrectas del modelo con porcentajes de error elevados tal y como se observa en la Tabla 5.

La Tabla 5 contiene los valores del comportamiento de las 3,188 estimaciones para cada categoría, evidenciando una estimación de alta precisión tanto para las imágenes de las muestras de agua HPLC como para las muestras de PVC. No obstante, las imágenes de PS y PET presentan comportamientos similares ya que arrojan errores de estimación del 15.06% y 36.24% respectivamente. En términos generales, el error promedio global alcanzado por el modelo del 12.82% reflejó un buen desempeño a pesar de la variable

precisión para algunos materiales. Estos resultados indican que es necesario optimizar el modelo de identificación de materiales para mejorar su desempeño y garantizar mayor confiabilidad en las estimaciones.




Figura 24. Estimación según tipo de material para las categorías: A) PS, B) PET C) PVC.



Tabla 5. Relación de las estimaciones correctas e incorrectas y el porcentaje de error asociado para el tipo de material.

Estimación del tipo de material			
Tipo de MP	Estimaciones Correctas	Estimaciones Incorrectas	% Error
Agua HPLC (0 MP)	3188	0	0
PS	2708	480	15.06
PET	2340	848	36.24
PVC	3188	0	0
Error promedio Global			12.82%



CONCLUSIONES

El sistema óptico empleado, que consta de una cámara industrial, iluminación LED azul, espejos, sistema de flujo de aire y sistemas de impulsores, permitió la toma de imágenes con la calidad necesaria para alimentar el modelo CNN y obtener los resultados esperados. Los sistemas de flujo de aire y el sistema de impulsores permitieron la distribución homogénea de los MP en las muestras, evitando su sedimentación y manteniéndolos en movimiento constante, facilitando la captura de las imágenes, esenciales para el procesamiento por la CNN.

Durante el entrenamiento y la validación de los tres modelos de estimación analizados, la CNN mostró alta precisión con valores cercanos a 1 (0.9995, 0.9994 y 0.9931) y una adecuada convergencia entre las curvas de efectividad y de pérdida, indicando que la CNN aprendió adecuadamente.

En el modelo de estimación de intervalos de tamaños de MP, la CNN estimó correctamente los intervalos de tamaño de los MP, con un error global de solo el 0.05%, indicando la elevada precisión del modelo empleado en la determinación de tamaños.

Asimismo, para la cuantificación de MP, se obtuvieron estimaciones muy cercanas a los valores reales ya que se obtuvieron resultados consistentes y un error promedio global de 0.10 $\mu\text{g/mL}$, por lo tanto, el modelo empleado demostró su gran capacidad para detectar y estimar diferentes concentraciones de MP en muestras de agua HPLC. Estos resultados reafirman la precisión y efectividad del modelo empleado y de la inteligencia artificial como una herramienta importante para la cuantificación de MP en muestras líquidas y posteriores estudios de contaminación del agua.

Por otra parte, en la identificación del tipo de MP se obtuvieron estimaciones con adecuada correspondencia al realizar la clasificación del tipo de MP para las muestras de agua HPLC y PVC, sin embargo, para los MP de PET y PS se obtuvieron estimaciones con un



considerable porcentaje de error, teniendo como error promedio global un valor de 12.82%, lo cual indica que, aunque el modelo muestra un rendimiento sobresaliente en la identificación de MP, existieron imprecisiones para dos de los tres MP analizados. Por lo tanto, es recomendable optimizar el modelo para alcanzar mayor precisión en la identificación de diferentes tipos de MP y disminuir los errores obtenidos.

El sistema desarrollado en este proyecto trasciende el análisis de MP en agua mostrando un gran potencial para ser aplicado en diversas matrices ambientales y muestras complejas, debido a que su flexibilidad reside en la capacidad de ajustarse a distintos tipos de polímeros y condiciones analíticas, lo que lo hace apto para estudios en suelos, sedimentos, aguas residuales e incluso organismos biológicos. Asimismo, este sistema puede ser utilizado para el monitoreo de MP en productos de consumo, como alimentos y bebidas, así como en investigaciones relacionadas con la exposición humana y sus efectos sobre la salud; por lo tanto, es una herramienta que pudiera ser clave tanto para la investigación científica como para la gestión ambiental y monitoreo de la contaminación del agua por MP.



REFERENCIAS BIBLIOGRÁFICAS

- [1] C. Bollaín and D. Vicente, “Presencia de Microplásticos en aguas y su potencial impacto en la Salud Pública,” *Rev Esp Salud Pública.*, vol. 93, pp. 1–10, Aug. 2019.
- [2] A. Franco del Pino, “Presencia de Microplásticos en estaciones depuradoras de aguas residuales de la provincia de Cádiz: identificación, cuantificación y rendimiento de eliminación,” *España*, Jul. 2020.
- [3] H. Du and J. Wang, “Characterization and environmental impacts of microplastics,” Oct. 01, 2021, *Elsevier Inc.* doi: 10.1016/j.gr.2021.05.023.
- [4] L. Lv *et al.*, “A simple method for detecting and quantifying microplastics utilizing fluorescent dyes - Safranin T, fluorescein isophosphate, Nile red based on thermal expansion and contraction property,” *Environmental Pollution*, vol. 255, Sep. 2019, doi: 10.1016/j.envpol.2019.113283.
- [5] T. Rocha and A. Duarte, *Characterization and Analysis of Microplastics*, Elsevier., vol. 75. Portugal: Comprehensive Analytical Chemistry, 2017.
- [6] S. De Silva, U. Maheswari, H. Kadono, and D. Li, “Effects of microplastics on lentil (*Lens culinaris*) seed germination and seedling growth,” *Chemosphere*, vol. 303, May 2022, doi: 10.1016/j.chemosphere.2022.135162.
- [7] C. Bejarano, “Determinación de la cinética química para la degradación térmica del Policloruro de Vinilo (PVC) reciclado por medio de un tratamiento dinámico a tres tasas de calentamiento,” *Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador*, 2021. [Online]. Available: <https://www.researchgate.net/publication/360236881>
- [8] K. Ordoñez, D. Coral, J. Rodríguez, J. Diosa, and E. Mosquera, “Pirólisis del tereftalato de polietileno y poliestireno para la síntesis de nanoestructuras de carbono: una revisión bibliométrica,” *Revista UIS Ingenierías*, vol. 22, no. 2, Apr. 2023, doi: 10.18273/revuin.v22n2-2023003.



- [9] E. Camargo, “Diseño de un sistema de flujo continuo para la caracterización de microplásticos en el agua,” Maestría en Ciencias en Ingeniería Ambiental, Instituto Tecnológico de Aguascalientes, Aguascalientes, México, 2024.
- [10] S. Jefferson, “Evaluation of HDPE and PVC Pipes Used for Cross-drains in Highway Construction,” Máster en Ciencias en Ingeniería Civil, Universidad de Auburn, Auburn, Alabama, 2011.
- [11] M. Bank, *Microplastic in the Environment: Pattern and Process*. Canada: Environmental Contamination Remediation and Management, 2022. [Online]. Available: <http://www.springer.com/series/15836>
- [12] P. Zuccarello *et al.*, “Exposure to microplastics (<10 μm) associated to plastic bottles mineral water consumption: The first quantitative study,” *Water Res*, vol. 157, pp. 365–371, Jun. 2019, doi: 10.1016/j.watres.2019.03.091.
- [13] A. Bernardo, “Tratamiento de aguas residuales en una fábrica textil por oxidación avanzada (Fenton), Lima-Perú,” Carrera Profesional de Ingeniería Ambiental, Universidad Científica del Sur, Perú, 2021.
- [14] J. Ríos, “El papel del color en la ingesta de fragmentos de microplástico por el pez cebra (*Danio rerio*),” *Revista Internacional de Contaminación Ambiental*, vol. 38, pp. 371–380, 2022, doi: 10.20937/RICA.54523.
- [15] J. Duch, “El impacto de la producción textil y de los residuos en el medio ambiente,” *Parlamento Europeo*, Jun. 2023.
- [16] C. Higuera, “Microplásticos en aguas residuales y posibles medidas de control en el Gran Santiago,” Programa interfacultades, Magíster en Gestión y Planificación Ambiental, Universidad de Chile, Santiago, Chile, 2022.
- [17] S. Peláez, “Uso de la electrocoagulación como alternativa para la eliminación de microplásticos presentes en las aguas residuales urbanas,” Máster Universitario en Gestión Sostenible y Tecnologías del Agua, Escuela Politécnica Superior, 2020.
- [18] R. Serway and R. Beichner, *Física Para Ciencias e Ingeniería*, Quinta., vol. II. McGraw-Hill, 2002.



- [19] D. Malacara, "Óptica Básica," in *Fondo de Cultura Económica México*, Segunda., 2004.
- [20] S. Zafar, M. Rasheed, M. Zia, M. Anis, and M. Anjum, "'Overview of artificial lighting sources: A critical review,' *Renewable and Sustainable Energy Reviews*, pp. 199–215, 2019.
- [21] M. Guauxochitl, "'Diseño e implementación de tarjetas de prueba para dispositivos ópticos,' 2012.
- [22] L. Prat, "Dispositivos optoelectrónicos, dispositivos emisores de luz y fibras ópticas," Catalunya.
- [23] B. Alonso *et al.*, *El láser, la luz de nuestro tiempo*. Salamanca: [Globalia], 2010.
- [24] L. Mi, "Fotografía básica de Langford. Guía para fotógrafos," 2019.
- [25] M. Langford, "Langford's Advanced Photography: The guide for aspiring photographers, 9th ed," 2019.
- [26] T. Zhang, S. Lui, J. Jiang, and Y. Sun, "'Industrial camera image acquisition system based on GigE. 2017 International Conference on Computer Technology, Electronics and Communication (ICCTEC)'., 2017.
- [27] S. Song, H. Kim, J. Kim, and S. Lee, "Design and implementation of a high-performance network camera for web-based services. Multimedia Tools and Applications., 2018.
- [28] INCyTU, "Inteligencia artificial," Ciudad de México, Mar. 2018.
- [29] A. Cifuentes, E. Mendoza, M. Lizcano, A. Santrich, and S. Moreno, "Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes," Barranquilla, Colombia, Jul. 2019. [Online]. Available: <http://revistas.unisimon.edu.co/index.php/identific>
- [30] X. Basogain, "Redes Neuronales Artificiales y sus aplicaciones," Bilbao.
- [31] B. Zarco, "Clasificación de microplásticos basada en redes neuronales profundas," Las Palmas, Jun. 2020.



- [32] M. Gimenez, “Estudio y aplicación de las redes neuronales convolucionales 3D,” Escola Tècnica d’Enginyeria de Telecomunicació de BarcelonaUniversitat Politècnica de Catalunya, Barcelona, 2018.