



**Visión artificial para la determinación de tres familias de macroinvertebrados acuáticos:
Caso de estudio quebrada La Ayurá.**

Sara Ospina Arcila

Informe de proyecto de investigación presentado para optar al título de
Ingeniera Ambiental e Ingeniera Sanitaria

Asesores

David Stephen Fernández Mc Cann, Doctor en Telecomunicaciones.

Juan Pablo Serna López, Doctor en Ingeniería Ambiental.

Néstor Jaime Aguirre Ramírez, Doctor Rer. Nat .

Universidad de Antioquia

Facultad de Ingeniería

Escuela Ambiental

Medellín, Antioquia, Colombia

2023

Cita	(Ospina Arcila, 2023)
Referencia	Ospina Arcila, S. (2023). <i>Visión artificial para la determinación de tres familias de macroinvertebrados acuáticos. Caso de estudio: quebrada La Ayurá</i> . [Proyecto de investigación].
Estilo APA 7 (2020)	Universidad de Antioquia, Medellín, Colombia.



Grupo de Investigación GEPAR y GEOLIMNA



Centro de Documentación Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano/Director: Julio Cesar Saldarriaga Molina.

Jefe departamento: Lina María Berrouet Cadavid.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Dedicado a la conservación y respeto de la vida en la ciencia.

Agradecimientos

Es complejo resumir el agradecimiento a quienes me han acompañado en este maravilloso camino.

Agradezco a mi familia, gracias a ellos he logrado ser la persona que soy el día de hoy.

A Oscar Cossio Madrid por el apoyo como auxiliar de campo, por su gran compañía en el proceso académico y por su amor, comprensión y ternura durante este proceso.

A David Fernández Mc Cann y Juan Pablo Serna López por compartirme sus conocimientos, su permanente apoyo, la paciencia, disponibilidad y su motivación para la realización del presente trabajo.

A los grupos de investigación GEPAR y GEOLIMNA por la inscripción del proyecto dentro de SIMEVAM (Sistema de Medición de Variables Ambientales) y por permitirme el uso de sus espacios.

A Macrolatinos por permitirme participar en el congreso de Guatemala 2023 mediante una ponencia sobre el trabajo realizado dentro del proyecto.

A Eliana Contreras, Daniela Cuartas y Andrés Escalante por sus conversaciones motivadoras sobre el tema de macroinvertebrados y programación.

A Daniel Dos Santos y María Celina Reynaga por compartirme información sobre IBY-4 y sobre una app para el monitoreo en ríos del Noa en Argentina.

Al historiador Carlos Gaviria Ríos de la Casa de la Cultura de Envigado por sus increíbles historias sobre la población alrededor de la quebrada La Ayurá.

A la Alcaldía de Envigado por la información de parámetros de calidad del agua y bioindicadores de la quebrada La Ayurá.

A la Universidad de Antioquia por ser la institución encargada de mi formación como profesional en el área ambiental y sanitaria.

A las enseñanzas brindadas por los docentes.

A mis amigos, Apolo y a las demás personas que han aportado a mi crecimiento académico y personal.

Tabla de contenido

Resumen	8
Abstract	9
1. Introducción	10
2. Planteamiento del problema	12
2.1. Pregunta de investigación	12
2.2. Hipótesis	12
3. Objetivos	13
3.1. Objetivo general	13
3.2. Objetivos específicos	13
4. Marco teórico	14
4.1. Macroinvertebrados acuáticos	14
4.2. Visión artificial y bases de datos de imágenes de macroinvertebrados acuáticos	15
4.3. Zona de estudio	21
7. Metodología	23
7.1. Comportamiento de AlexNet con base de datos libre	24
7.2. Construcción de la base de datos de imágenes	25
7.2.1. Muestreo de calidad del agua en la quebrada La Ayurá y elección de familias	25
7.2.2. Toma de fotografías de los organismos en estereomicroscopio	26
7.3. Entrenamiento, validación y prueba de seis modelos de redes neuronales artificiales mediante la base de datos con imágenes de estereomicroscopio	27
7.3.1. Diseño del experimento	28
7.3.2. Datos	29
7.3.3. Entrenamiento y validación	29
7.3.4. Prueba de los modelos con imágenes dentro de la base de datos	30

7.4. Prueba de los modelos mediante imágenes tomadas con el montaje de campo	30
7.4.1. Construcción del montaje de campo	30
7.4.2. Prueba con fotografías tomadas de organismos sumergidos en alcohol con montaje de campo	31
7.4.3. Prueba con fotografías tomadas de organismos vivos sumergidos en agua con montaje de campo	32
7.5. Elaboración de la interfaz de usuario	34
8. Resultados y Análisis	35
8.1. Análisis de AlexNet con bases de datos libres	35
8.2. Muestreo de calidad del agua, elección de las familias y generación de la base de datos de los organismos mediante estereomicroscopio.	36
8.3. Análisis del entrenamiento, validación y prueba inicial de las redes neuronales	39
8.4. Análisis de los resultados de las pruebas con imágenes tomadas mediante montaje de campo	41
8.5. Análisis de la interfaz de usuario	47
9. Conclusiones	49
10. Recomendaciones	51
10. Referencias	52

Lista de tablas

Tabla 1. Listado de 11 especies seleccionadas para el entrenamiento, validación y prueba de la fase inicial.	25
Tabla 2. Dimensiones de la capa de entrada de cada red neuronal.	29
Tabla 3. Entrenamiento y validación para los 3 escenarios con base de datos de libre acceso, con los diferentes escenarios para entrenamiento y validación.	35
Tabla 4. Resultados promedio de clasificación de las familias de macroinvertebrados al utilizar los diferentes escenarios.	36
Tabla 5. Parámetros fisicoquímicos tomados aguas arriba y aguas abajo de la quebrada La Ayurá.	37
Tabla 6. Familias de macroinvertebrados presentes en la quebrada La Ayurá durante 2007-2021.	37
Tabla 7. Muestra de la base de datos de imágenes de las Familias de macroinvertebrados.	38
Tabla 8. Resultados del entrenamiento y validación de los modelos – MATLAB.	39
Tabla 9. Precisión de la validación y tiempo de entrenamiento para las diferentes redes neuronales.	40
Tabla 10. Imágenes de los organismos capturadas con el montaje de campo para la prueba externa del modelo con organismos sumergidos en alcohol, con 3 formatos de captura de imagen.	41
Tabla 11. Resultados de reconocimiento de imágenes de macroinvertebrados vivos con imágenes de fotografías y videos tomadas mediante celular en formato por defecto.	45

Lista de figuras

Figura 1. Montajes para la captura de fotografías de macroinvertebrados por fuera del laboratorio.	17
Figura 2. Arquitectura de la red neuronal convolucional AlexNet.	19
Figura 3. Relación de precisión, costo computacional y eficiencia en el uso de parámetros.	20
Figura 4. Ubicación de la zona de estudio en la quebrada La Ayurá.	21
Figura 5. Fases de la Metodología de trabajo.	23
Figura 6. Fotografías de la zona de estudio.	26
Figura 7. Captura de fotografías mediante estereomicroscopio.	27
Figura 8. Imágenes tomadas mediante estereomicroscopio, recortadas mediante BoundingBox y redimensionadas.	28
Figura 9. Montaje de campo diseñado para la captura de imágenes de macroinvertebrados.	31
Figura 10. Fotografía aérea tomada mediante dron del punto ubicado aguas abajo el ecoparque El Salado.	32
Figura 11. Fotografías del uso del montaje de campo para la captura de fotografías y videos de macroinvertebrados para la evaluación final del modelo.	33
Figura 12. Matriz de confusión para prueba de las redes neuronales convolucionales con imágenes de la base de datos con estereomicroscopio.	40
Figura 13. Matriz de confusión para la prueba externa con fotografías capturadas mediante el montaje de campo en formato RAW para las 6 redes neuronales.	42
Figura 14. Matriz de confusión para la prueba externa con fotografías capturadas mediante el montaje de campo en formato FLASH para las 6 redes neuronales.	43
Figura 15. Matriz de confusión para la prueba externa con fotografías capturadas mediante el montaje de campo en formato por defecto o predeterminado por el dispositivo móvil.	43
Figura 16. Interfaz gráfica de usuario.	47
Figura 17. Uso de la aplicación BMW3	48

Resumen

Uno de los retos para el uso de los macroinvertebrados como bioindicadores de la calidad del agua es la necesidad de especialistas en taxonomía, por lo que se han venido utilizando en los últimos años algoritmos de visión artificial para realizar la clasificación de los organismos mediante imágenes. El presente trabajo utiliza técnicas de transferencia de aprendizaje, comparando los algoritmos de aprendizaje profundo AlexNet, GoogleNet, ResNet18, ResNet50, ResNet101 e InceptionV3 para la determinación de tres familias de macroinvertebrados, construyendo un banco de imágenes mediante estereomicroscopio para el entrenamiento, validación y prueba de los modelos. Posteriormente, se realizan pruebas con imágenes tomadas con un montaje de campo en diferentes formatos de imagen y estados del organismo. La base de datos fue construida con las familias Baetidae, Elmidae e Hydropsychidae, ya que poseen abundancia y presencia en un punto de la quebrada durante el periodo 2007 a 2023, en cuanto al entrenamiento y validación, se obtuvo una precisión por encima del 98,2% en todas las redes neuronales, mientras que, en la prueba dentro de la misma base de datos, todas las redes exceptuando ResNet101 lograron realizar bien la clasificación. Para la prueba con imágenes del montaje de campo, GoogleNet es modelo que posee mejores métricas en la matriz de confusión y con el cual se construyó una interfaz de usuario. Finalmente, el análisis de este modelo plantea nuevos retos para la clasificación de organismos vivos y para el procesamiento digital de las imágenes.

Palabras clave: reconocimiento de patrones, visión artificial, macroinvertebrados acuáticos, red neuronal convolucional.

Abstract

One of the challenges for the use of macroinvertebrates as bioindicators of water quality is the need for specialists in taxonomy, so in recent years artificial mimicry algorithms have been used to classify organisms using images. The present work uses transfer learning techniques, comparing the deep learning algorithms AlexNet, GoogleNet, ResNet18, ResNet50, ResNet101 and InceptionV3 for the determination of three families of macroinvertebrates, building an image bank for training, validation and testing of the models using stereomicroscopy. Subsequently, tests are performed with images taken with a field setup in different image formats and organism states. The database was constructed with the families Baetidae, Elmidae and Hydropsychidae, since they have abundance and presence in a point of the creek during the period 2007 to 2023, in terms of training and validation, an accuracy above 98.2% was obtained in all neural networks, while, in the test within the same database, all networks except ResNet101 managed to perform well the classification. For the test with images from the field assembly, GoogleNet is the model with the best metrics in the confusion matrix and with which a user interface was built. Finally, the analysis of this model poses new challenges for the classification of living organisms and for digital image processing.

Keywords: pattern recognition, computer vision, aquatic macroinvertebrates, convolutional neural network.

1. Introducción

En los monitoreos de calidad del agua se realizan estudios hidrobiológicos con el fin de evaluar el estado de contaminación, en particular, se utilizan los macroinvertebrados acuáticos como bioindicadores, ya que estos dan una respuesta a las condiciones de contaminación del agua debido a su sensibilidad a cambios en la calidad y presencia de sustancias tóxicas. Por lo tanto, el estudio de estos organismos sirve para brindar información sobre la salud del ecosistema acuático.

Algunos de los índices que utilizan bioindicadores y son utilizados en el mundo es el Biological Monitoring Working Party (BMWP), adaptado a Colombia mediante el BMWP-COL (Roldán G, 2003) para determinar el nivel de afectación de los ecosistemas acuáticos. Dicho índice utiliza 95 familias de macroinvertebrados acuáticos con una clasificación mediante puntajes de tolerancia a la contaminación.

Los limitantes para la implementación de estos índices se basan en los tiempos de evaluación, la necesidad de especialistas y la correcta determinación, por lo que se han venido desarrollando herramientas basadas en algoritmos computacionales que se encargan del reconocimiento de imágenes de grupos taxonómicos relacionados a macroinvertebrados acuáticos, utilizando métodos de visión por computador (Cruz et al., 2022), logrando identificar a los organismos con bajos porcentajes de error que pueden llegar a alcanzar el desempeño humano (Raitoharju et al., 2016). Dichos algoritmos permiten disminuir los tiempos de observación y determinación de los organismos, por lo que puede convertirse en una gran herramienta para los estudios ambientales.

Para la determinación de los macroinvertebrados, se destacan dos maneras para realizar la recolección de los organismos y su posterior análisis. El primero consiste en que los organismos son capturados de los cuerpos de agua y posteriormente se depositan en viales de plástico con alcohol y son llevados al laboratorio para su posterior clasificación. El segundo método consiste en el biomonitoreo participativo, en el cual se busca involucrar a la comunidad en la recolección de datos sobre la calidad del agua utilizando macroinvertebrados acuáticos como indicadores, por lo que en estos casos se recolectan los organismos en el cuerpo de agua y los participantes visualizan y aprenden a reconocer a los organismos en el campo, sin necesidad de sacrificarlos, por lo que esta es una alternativa interesante debido a que se reduce el daño a la fauna local y se promueve la conservación ambiental y las metodologías éticas y colaborativas. Ante estas dos

miradas, el reconocimiento de los macroinvertebrados acuáticos mediante la inteligencia artificial es una herramienta útil para la clasificación de estos organismos tanto en el laboratorio como en campo (Quintero et al., 2018).

Algunos de los modelos que se utilizan para el reconocimiento de objetos mediante visión artificial consisten en técnicas de aprendizaje de máquinas de manera supervisada, como las máquinas de vectores de soporte, mientras que las técnicas de aprendizaje profundo como las redes neuronales convolucionales permiten un aprendizaje de manera no supervisada, operando mediante capas y filtros (Bianco et al., 2018), utilizando una determinada capacidad computacional y eficiencia en sus arquitecturas. Una de las herramientas utilizadas en el mundo del reconociendo de imágenes es la transferencia de aprendizaje, la cual tiene la ventaja de que no es necesario crear las redes neuronales desde cero, sino que pueden adaptarse las capas de entrada y salida de los modelos, por lo tanto, se decide comparar este tipo de redes neuronales pre entrenadas con el fin de evaluar su eficiencia y encontrar el modelo con mejor desempeño.

Bajo este escenario, el presente trabajo tiene como objetivo desarrollar un algoritmo de visión artificial para facilitar la identificación de 3 familias de macroinvertebrados acuáticos, mediante una fase preliminar para obtener consideraciones iniciales, con posteriores muestreos en la quebrada La Ayurá ubicada en el municipio de Envigado, departamento de Antioquia, Colombia, para la captura de los organismos y posterior construcción de una base de datos de imágenes para el entrenamiento, validación y prueba de los seis modelos de redes neuronales convolucionales AlexNet, GoogleNet, ResNet18, ResNet50, ResNet101 e InceptionV3, con pruebas externas obtenidas mediante fotografías tomadas mediante un montaje de campo y elaboración de la interfaz de usuario con el mejor modelo encontrado mediante métricas como la matriz de confusión.

2. Planteamiento del problema

El uso de macroinvertebrados como bioindicadores de la calidad del agua requiere de especialistas en taxonomía para su clasificación y una inversión de tiempo considerable. Sin embargo, en los últimos años se han utilizado algoritmos de visión artificial para realizar dicha clasificación mediante imágenes. En este contexto, surge la necesidad de evaluar y comparar diferentes algoritmos de deep learning mediante transferencia de aprendizaje para la clasificación de macroinvertebrados acuáticos. Considerando la alta diversidad que poseen los macroinvertebrados acuáticos, es necesario reducir los experimentos a tres familias de macroinvertebrados presentes en la quebrada La Ayurá para determinar mediante entrenamiento, validación y pruebas la eficacia de dichos algoritmos.

2.1. Pregunta de investigación

¿Cuál es el algoritmo de aprendizaje profundo que permite la clasificación más precisa de tres familias de macroinvertebrados acuáticos mediante imágenes?

2.2. Hipótesis

Los algoritmos de aprendizaje profundo evaluados permiten reconocer las imágenes de las tres familias de macroinvertebrados con alta precisión a partir de la transferencia de aprendizaje, con precisiones por encima del 90%, logrando reconocer en las pruebas las imágenes similares a las seleccionadas para el entrenamiento y validación. Al comparar los modelos de redes neuronales convolucionales, se espera que la red neuronal que posea mejor arquitectura y eficiencia computacional muestre las mejores métricas en la matriz de confusión y se construya con esta una interfaz de usuario.

3. Objetivos

3.1. Objetivo general

Desarrollar un algoritmo basado en técnicas de visión artificial que permita la determinación de tres familias de macroinvertebrados acuáticos presentes en la quebrada La Ayurá, Colombia.

3.2. Objetivos específicos

- Analizar el comportamiento de un modelo mediante imágenes externas para encontrar oportunidades de mejora en la creación de la base de datos.
- Construir una base de datos de imágenes con 3 familias de macroinvertebrados acuáticos presentes en la quebrada La Ayurá, para el entrenamiento del algoritmo.
- Determinar el modelo de reconocimiento de patrones que permita la clasificación automática de imágenes de los macroinvertebrados dentro de la base de datos.
- Realizar pruebas de los modelos con imágenes capturadas mediante un montaje de campo, con el fin de encontrar el modelo que mejor se desempeña.
- Elaborar una interfaz de usuario que permita realizar la clasificación de macroinvertebrados, utilizando el mejor modelo encontrado.

4. Marco teórico

4.1. Macroinvertebrados acuáticos

En los ríos y lagos habitan los macroinvertebrados acuáticos, los cuales son pequeños organismos que carecen de columna vertebral (invertebrados) y pueden ser vistos a simple vista (macro), con tamaños que oscilan entre 0.5 mm y 5.0 mm (Roldán, 2016). Dichos organismos poseen diferentes adaptaciones para vivir sobre la superficie del agua (Neuston), nadar libremente en la columna del agua (Necton) o vivir en el fondo adherido a vegetación, rocas y troncos (Bentos) (Álvarez, 2005). Los macroinvertebrados son visibles a simple vista, abundantes, sedentarios y con ciclos de vida relativamente largos, por lo que se consideran como los mejores bioindicadores de calidad del agua (Roldán, 2003).

Uno de los índices Bióticos que utiliza a los macroinvertebrados como bioindicadores es el Biological Monitoring Working Party (BMWP), en el cual solo es necesario llegar hasta una clasificación taxonómica de Familia y obtener datos cualitativos de presencia o ausencia (Álvarez, 2005). Este índice fue adaptado a Colombia (Zamora, 1999) mediante una clasificación de puntajes (de 1 a 10) para 95 familias de macroinvertebrados según su tolerancia a la contaminación del ambiente (BMWP/Col), en donde a mayores puntajes del índice se presenta una menor tolerancia a la contaminación (Roldán, 2003).

Una de las problemáticas para el uso de los índices biológicos es la determinación de los organismos, ya que generalmente estos estudios son realizados por expertos en taxonomía mediante el uso de atlas, guías o mediante aplicaciones que ayudan a definir características de manera manual mediante el análisis humano, como la colección didáctica creada con imágenes de giga píxeles denominada macroinvertebrates.org (Kautz et al., 2022), una app para monitoreo en ríos del Noa (Dos Santos et al., 2014), calculadora del Índice Biótico Andino (Perú) que permite realizar evaluaciones de calidad del agua y poner la tecnología al servicio de la comunidad (USAID, 2023) o Biomonitoreo Río Negro, Argentina (BIOMCI, 2023).

Para facilitar el trabajo de clasificación de los macroinvertebrados acuáticos se ha implementado el uso de la inteligencia artificial (Ärje et al., 2020b) con el fin de optimizar los tiempos de clasificación y ayudar en la determinación taxonómica.

El uso de las nuevas tecnologías y el conocimiento del uso de los macroinvertebrados como indicadores, puede ser de gran ayuda en las evaluaciones de impacto ambiental, el estudio de la degradación del hábitat, el análisis de vulnerabilidad y riesgo de acueductos veredales de Colombia en los cuales en muchos casos no se realiza el tratamiento del agua ni se utilizan mediciones de variables fisicoquímicas de la fuente de agua debido a su costo. En el caso del presente estudio la motivación del uso de la visión artificial para la determinación de los macroinvertebrados acuáticos se basa en la preservación y respeto de la vida de los organismos, con el fin de reconocerlos mediante imágenes en campo, evitando el sacrificio de estos.

4.2. Visión artificial y bases de datos de imágenes de macroinvertebrados acuáticos

El reconocimiento por visión artificial para los macroinvertebrados acuáticos, se ha utilizado en diversas investigaciones como MacroDEX (Serna López et al., 2020; Serna, 2020), el cual utiliza una comparación de algoritmos analíticos, llegando a eficiencias del 97,1% en la identificación de 4 géneros de macroinvertebrados. Además, se ha desarrollado un modelo para el reconocimiento de 2 familias de macroinvertebrados acuáticos (Quintero et al., 2018) que tiene la proyección de incluir una mayor cantidad de familias para cumplir con los objetivos de biomonitorio participativo en Panamá. Otros autores han encontrado que al realizar un enriquecimiento de datos mediante rotaciones y reflejos de las imágenes de 29 taxones de macroinvertebrados es posible mejorar los resultados de la clasificación automatizada, además de que, si se aumenta la cantidad de imágenes etiquetadas y se aplican técnicas más avanzadas de enriquecimiento de datos, las redes neuronales pueden alcanzar el desempeño de los expertos humanos (Raitoharju et al., 2016).

En cuanto a la manera de realizar el entrenamiento, se han practicado técnicas de aprendizaje profundo que se encargan de entrenar los modelos de redes neuronales convolucionales mediante transferencia de aprendizaje con imágenes previamente binarizadas (Milosavljević et al., 2021). Por el lado del tamaño de la base de datos, se ha encontrado que para obtener precisiones notables de cerca del 97%, se requiere de cerca de 15 especímenes de cada taxón, y que aumenta al 99,2% con cerca de 50 especímenes (Høye et al., 2022).

Para realizar el reconocimiento de manera automatizada es necesario de grandes cantidades de imágenes de organismos, por lo que para estudios preliminares se puede hacer uso de bases de datos como la que proporciona el Global Biodiversity Information Facility (GBIF, 2023), el cual

incluye observaciones de repositorios como INaturalist y la red de biodiversidad en Colombia desde el Sistema de Información de Biodiversidad de Colombia (SIB Colombia, 2023), sin embargo, el principal fin de estas bases de datos es el registro de presencia de especies y listas, mientras que la presencia de algunas de las fotografías no se encuentran en la mejor calidad o fondo estandarizado, y su uso se encuentra dentro de la licencia Creative Commons mediante atribución a los autores, por lo que dificulta su uso en entrenamientos en los cuales se requiere alta cantidad de imágenes.

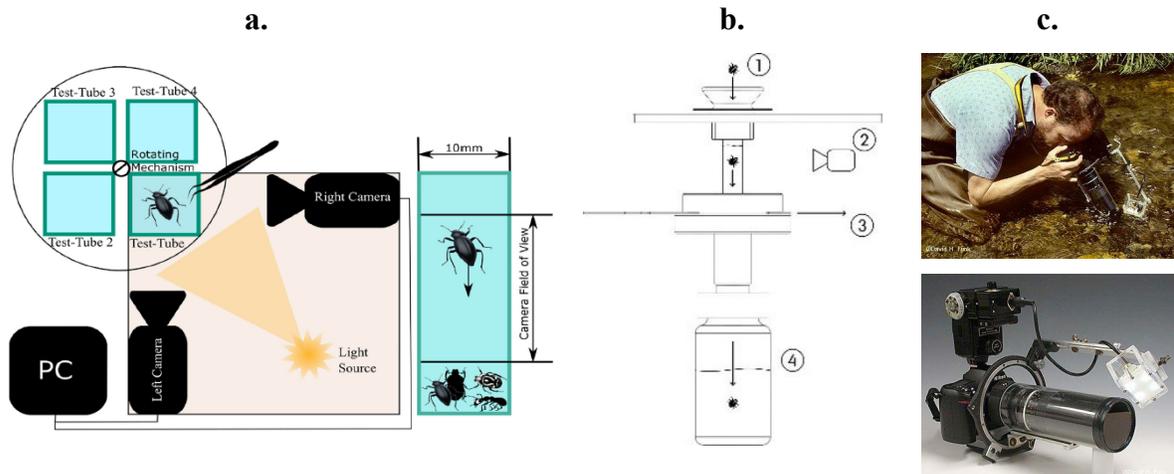
Además de las anteriores bases de datos, existen otras enfocadas en macroinvertebrados acuáticos, tales como NAAMDRC, la cual es una base de datos con más de 5000 imágenes que cubren aproximadamente el 75% de los géneros de insectos acuáticos del oeste de Mississippi en América del Norte, y las cuales son de dominio público y están disponibles para su uso sin permiso (Walters et al., 2017), sin embargo, en esta base de datos no se encuentra la cantidad adecuada de espécimen de cada taxón y se debe tener en cuenta también que algunas características biológicas varían de una región a otra, por lo que en Colombia podrían ser diferentes. En Colombia se han realizado avances en la construcción de bases de datos de imágenes en UNISANGIL mediante la plataforma "Colección Biológica - BiolCol" (Caicedo et al., 2023).

Raitoharju et al. (2018) puso a disposición una base de datos de imágenes 64 tipos de macroinvertebrados bentónicos de Finlandia, con un rango de 7 a 577 imágenes por categoría, en formato de metadatos (Raitoharju et al., 2021). Además de la creación de las imágenes, es necesario realizar un enriquecimiento de las bases de datos para ayudar a enfocar características tales como los fondos mediante la binarización de las imágenes (Raitoharju et al., 2016).

En la captura de imágenes fuera del laboratorio, varios autores han utilizado metodologías para la toma de fotografías de macroinvertebrados (**Figura 1**), como ejemplo, se han generado montajes para la toma de fotos y generación de una base de datos (Raitoharju et al., 2016), capturar de imágenes desde diferentes ángulos (Ärje, 2020a), o capturar imágenes en campo (STROUD, 2023).

Figura 1.

Montajes para la captura de fotografías de macroinvertebrados por fuera del laboratorio.



Nota. **a.** Configuración para la adquisición de imágenes para la base de datos, propuesta por Raitoharju et al. (2016). **b.** Máquina BIODISCOVER que permite captura de imágenes desde diferentes ángulos, propuesta en Árje et al. (2020a). **c.** Fotografías David H. Funk presentado por STROUD, (2023).

Dentro de las tareas de analítica de imágenes y reconocimiento de patrones más comunes se encuentran las técnicas de visión artificial con la clasificación de objetos, además de la detección y segmentación, las cuales se encargan de localizar las instancias de los objetos o clases (MathWorks, 2023a), refiriéndose a clase como cada uno de los tipos de objetos que se ingresan a los modelos, siendo este diferente a clase de la categoría taxonómica. Para realizar la clasificación se le asigna a cada imagen una clase, etiqueta o anotación, mientras que en la detección de objetos se logra identificar el rectángulo que indica la ubicación del objeto y en la segmentación se determinan los límites de las regiones de interés de la imagen.

Los modelos analíticos automatizados de aprendizaje de máquinas (ML) han permitido ingresar en una nueva etapa, en la cual se entrena a los computadores como si fuese un niño, considerando más importante enseñarles con ejemplos, y no mediante reglas explícitas (Janiesch et al., 2021). Las metodologías de aprendizaje computacional cada vez evolucionan a que ya no sea necesario ingresar datos de entradas y procesar la información mediante el aprendizaje humano para obtener una salida, sino que al ingresar los datos de entrada y los datos de salida al modelo de aprendizaje automático, sea posible que la máquina relacione los datos y posteriormente permita predecir los datos de salida que se obtendría con nuevos datos de entrada, como ejemplo en el ámbito de las imágenes, si se le ingresa una imagen y además la etiqueta o nombre de la clase a la que

corresponde, el modelo podrá dar a conocer la clase a la cual pertenece, con cada vez menos intervención humana. Estudios presentados desde 1999 hasta 2022 han indicado la influencia de la resolución taxonómica, características de la muestra, las imágenes y la evolución de algoritmos en la clasificación (Cruz et al., 2022).

Dentro del aprendizaje de máquinas o aprendizaje automático (ML) se encuentra el aprendizaje profundo (DL), el cual utiliza una gran cantidad de datos y se basan en redes neuronales, que en el ámbito de la visión artificial y el reconocimiento por voz se denominan redes neuronales convolucionales (CNN) (Janiesch et al., 2021). Uno de los procesos más complejos en la clasificación de imágenes es la extracción de características que ayudan al reconocimiento de patrones (Wang et al., 2021), por lo que si se comparan técnicas de machine learning como las máquinas de vectores de soporte (SVM) y las redes neuronales convolucionales (CNN), se encuentra que las primeras son útiles en datos a pequeña escala, mientras que las redes neuronales convolucionales obtienen mayor precisión en datos de gran escala.

Las redes neuronales convolucionales están compuestas de unas capas conformadas por kernels basados en la convolución para extraer las características y los perceptrones para realizar la clasificación. El perceptrón es la red neuronal más básica, que al combinarse con otros perceptrones mediante relaciones similares a las que ocurren en el cerebro humano, se forman parámetros que definen la importancia de la neurona, cada conexión entre neuronas o perceptrones tiene un peso asociado, y mediante operaciones previas en la etapa de convolución de los pesos y sesgos con las funciones de activación, entre las que se encuentran la función ReLu y softmax (Pérez, 2021) se logra la extracción de características. Para lograr dicha extracción de características se hace uso de filtros, los cuales permiten la identificación de patrones mediante convoluciones, en las cuales se van seleccionando características capa a capa, por ejemplo, “las primeras capas de la red son responsables de extraer características básicas en forma de bordes y esquinas” (Janiesch et al., 2021).

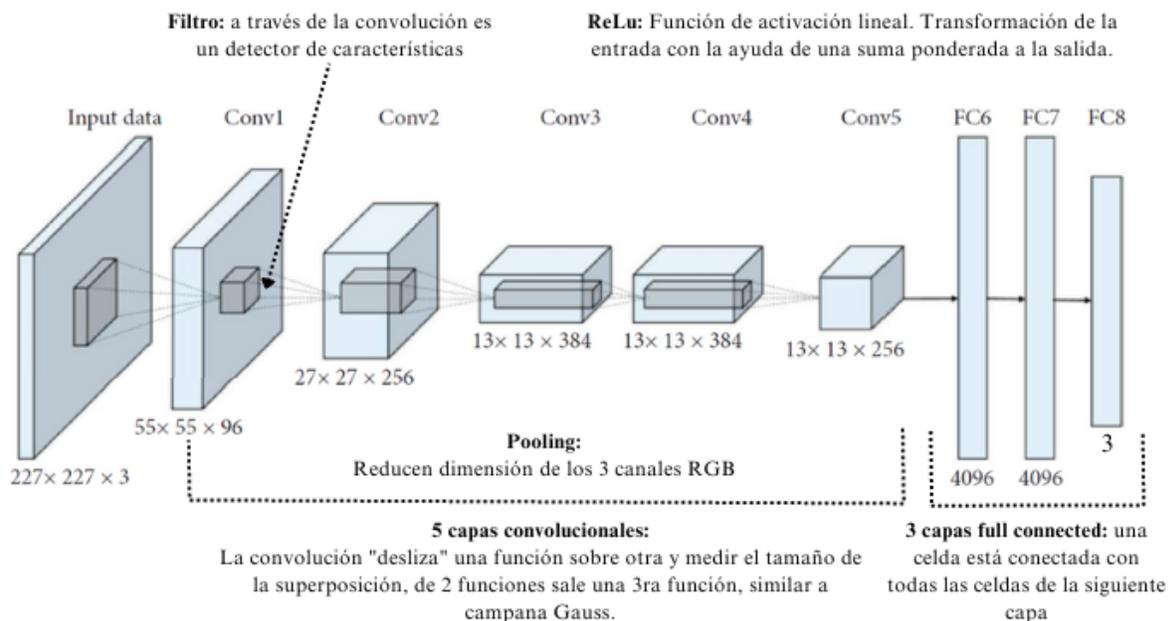
Algunos de los elementos importantes en las arquitecturas de las CNN es el pooling que permite agrupar los píxeles, el dropout para la pérdida de peso que evita el sobre ajuste u overfitting en el cual el modelo se ajusta demasiado a los valores de entrada y se vuelve casi imposible la predicción debido a que “se aprende” los datos de entrenamiento (Pérez, 2021). Además del sobre ajuste de datos puede ocurrir el sub ajuste o underfitting, debido a que el modelo no logra adaptarse muy bien a los datos, y finalmente, si no ocurre subentrenamiento o sobreentrenamiento, se genera un

comportamiento óptimo del modelo. Para realizar el análisis de información se suelen utilizar métricas de clasificación binaria con categoría positiva o negativa, y que visualmente pueden observarse mediante la matriz de confusión (Ahmed, 2019).

En algunos casos, se utilizan redes neuronales ya entrenadas y se realiza un aprendizaje por transferencia o transfer learning (Zhang et al., 2023), en el cual se adoptan redes neuronales profundas creadas por otros autores. En el caso del presente estudio se utilizan las redes neuronales mediante transfer learning, con leves cambios en la capa full connected y output de las respectivas arquitecturas. En la **Figura 2** se puede observar la arquitectura de AlexNet, la cual es considerada la primera red neuronal convolucional, al ganar el concurso de Imagenet, dicha arquitectura consta con 5 capas convolucionales, 3 capas de agrupación y 3 capas conectadas (Mohammed et al., 2023), el transfer learning permitió que el número de clases de salida del modelo fuese de 3, correspondientes a las 3 familias de macroinvertebrados respectivas.

Figura 2.

Arquitectura de la red neuronal convolucional AlexNet.

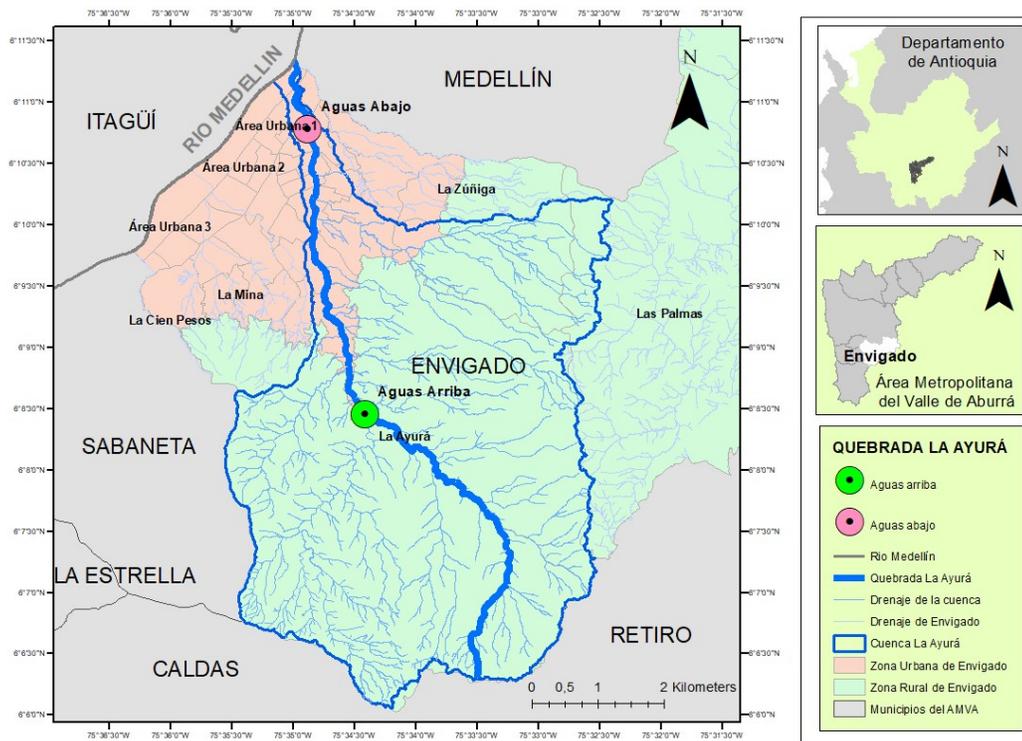


Nota: Adaptado de Mohammed et al. (2023)

4.3. Zona de estudio

Para el caso de estudio de los macroinvertebrados acuáticos, se escogió quebrada La Ayurá debido a que es considerada el corredor biológico más importante del municipio de Envigado, Antioquia, Colombia, esperando una diversidad biológica mayor que en otras quebradas del Área metropolitana del Valle de Aburra ubicadas en la zona urbana. El nacimiento de la quebrada La Ayurá se encuentra en el cerro El Astillero a 2880 m.s.n.m. y desemboca en el río Medellín (González V, 2008), en cuanto al clima, en la cuenca se presenta un comportamiento bimodal de precipitaciones, con altas frecuencias entre abril-junio y septiembre-noviembre (Naranjo et al., 2017), con temperaturas promedio de 16°C en la parte alta y 22°C en la parte baja, y una velocidad media de 0,933 m/s. La subcuenca limita con los municipios de El Retiro, Caldas y Sabaneta, cerca de un 80% del área del municipio es suelo rural, y como puede observarse en la **Figura 4**, los puntos de interés en el presente informe se ubican aguas arriba y aguas abajo de la zona urbana del municipio.

Figura 4.
Ubicación de la zona de estudio en la quebrada La Ayurá.



La quebrada La Ayurá es un símbolo de fecundidad y progreso en el municipio (Preciado, 2007), ya que es parte de usos tradicionales y del mito de la fecundidad de las mujeres que ingresan a bañarse en dicho cuerpo de agua, por lo cual ha servido de inspiración a escritores y poetas. Desde el lado ambiental, actualmente la quebrada cuenta con uso recreativo y zonas de corredores ecológicos, en donde en el punto de muestreo ubicado aguas arriba se encuentra el ecoparque El Salado. En la quebrada se han realizado estudios tales como el análisis de variables fisicoquímicas y de macroinvertebrados acuáticos (Valverde et al., 2009), la presencia de protistas en la quebrada para evaluar la calidad del agua en diferentes tramos de estudio (Aguirre et al., 2008), la aplicación de diferentes índices bióticos como el BMWP-COL mediante muestreos cualitativos y cuantitativos de macroinvertebrados acuáticos y parámetros fisicoquímicos, por medio de 3 muestreos realizados en noviembre de 2007 y enero y febrero de 2008 (González V et al., 2013) en el cual se presentó un agua de buena calidad en enero y febrero de 2008, y agua de calidad aceptable y dudosa durante noviembre de 2007. Posterior a estos años, en el año 2018-2019 se realizó una caracterización y monitoreo de la calidad del agua superficial en la quebrada La Ayurá, analizando parámetros fisicoquímicos, microbiológicos e hidrobiológicos (Secretaría de Medio Ambiente, 2019) de mediante índices como el BMWP-COL en temporada seca y húmeda, por lo que es posible realizar comparaciones espacio temporales entre la presencia de macroinvertebrados a lo largo de los años 2008-2019.

7. Metodología

Para el desarrollo metodológico del algoritmo de visión artificial que permita la determinación de tres familias de macroinvertebrados acuáticos, se siguieron una serie de pasos y procedimientos que consistieron en 5 fases, correspondiente a la fase inicial, la base de datos de imágenes, el entrenamiento, validación y prueba de los modelos, la prueba externa de los modelos y finalmente la construcción de la interfaz de usuario, como se muestra en la **Figura 5**.

Figura 5.
Fases de la Metodología de trabajo.



En la fase inicial se entrena el modelo AlexNet con imágenes de una base de datos libre, con el fin de definir parámetros para la captura de imágenes mediante estereomicroscopio, factores importantes en la generación de la base de datos y parámetros de entrenamiento.

En la segunda fase se realizó un muestreo de calidad del agua en la quebrada La Ayurá y se recolectaron organismos con el fin de analizar la presencia a lo largo de varios años en la quebrada, de manera que sea probable encontrar estos organismos cada que se realicen visitas a la quebrada (con el fin de que la cantidad de organismos no sea una limitante), con estos organismos se construye para las 3 familias una base de datos de imágenes tomadas mediante estereomicroscopio.

Como tercera fase se eligieron 6 modelos de redes neuronales convolucionales para el entrenamiento, validación y prueba utilizando la base de datos de imágenes de estereomicroscopio. En la cuarta fase se realizaron pruebas con imágenes externas a la base de datos, en este caso se utilizó para la toma de fotografías un montaje portátil para campo, con el fin de determinar el

modelo que mejor se comporta con imágenes de los mismos organismos con que se entrenó (sumergidos en alcohol), pero con fotografías tomadas mediante un montaje de campo.

Con el fin de realizar una prueba que evidencie el comportamiento del mejor modelo elegido en el paso anterior, pero ahora con organismos vivos, se realizó otra salida a la quebrada La Ayurá con el fin de mostrarle imágenes de fotografías y videos de organismos vivos tomados con el montaje de campo al modelo que mejor se comportaba en el paso anterior. Se le ingresaron imágenes de las mismas familias de macroinvertebrados entrenadas, pero que nunca habían sido mostradas al modelo durante el proceso de entrenamiento o pruebas anteriores, esto con el fin de observar el desempeño de la mejor red neuronal encontrada ante imágenes de organismos vivos capturadas con el montaje.

Finalmente, en la quinta fase se realiza la interfaz de usuario con el modelo que presentó mejores resultados. En los siguientes apartados de la metodología se explicarán a detalle cada una de las 5 fases mencionadas anteriormente.

7.1. Comportamiento de AlexNet con base de datos libre

Uno de los planteamientos iniciales consistió en realizar el entrenamiento mediante imágenes de internet, sin embargo, se obtuvieron ciertas incertidumbres en cuanto a que, al no ser imágenes tridimensionales y no poder girar los organismos, no se podía verificar que las imágenes perteneciesen a cierta familia, además de que en algunos casos la resolución de las imágenes, el fondo, la cantidad de imágenes y los derechos de copyright generaban conflictos.

Por lo tanto, se decidió utilizar la base de datos libre de Raitoharju et al. (2018), con 3 especies de Baetidae, 5 de Elmidae y 3 Hydropsychidae, como se presenta en la **Tabla 1**, con el fin de obtener datos de entrenamiento y de características importantes al momento de generar la propia base de datos, estandarizando los parámetros de captura de imágenes, tales como el color de fondo, posiciones del organismo, entre otras, ya que como menciona Serna (2020) “La construcción de la base de datos puede ser un factor limitante al momento de incluir nuevas especies en el algoritmo”.

Tabla 1.

Listado de 11 especies seleccionadas para el entrenamiento, validación y prueba de la fase inicial.

Baetidae	Elmidae	Hydropsychidae
<i>Baetis digitatus</i>	<i>Elmis aenea (adulto)</i>	<i>Hydropsyche pellucidula</i>
<i>Baetis niger</i>	<i>Elmis aenea (larva)</i>	<i>Hydropsyche saxonica</i>
<i>Baetis rhodani</i>	<i>Limnius volckmari (adulto)</i>	<i>Hydropsyche siltalai</i>
	<i>Oulimnius tuberculatus (adulto)</i>	
	<i>Oulimnius tuberculatus (larva)</i>	

Nota: Las familias fueron seleccionadas de la base de datos de Raitoharju et al. (2018).

La red neuronal convolucional para realizar el entrenamiento es AlexNet, utilizado como línea base para el análisis del comportamiento de la base de datos.

Para el entrenamiento, validación y prueba se plantearon 3 escenarios, en los cuales se entrena el algoritmo mediante diferentes especies pertenecientes a las 3 familias de macroinvertebrados. Dichos escenarios poseen diferentes números de clases, en el primer escenario se toman las 11 especies por separado en diferentes secciones o clases para la clasificación, mientras que en el segundo escenario se elige una especie de cada familia al azar obteniendo 3 clases, y en el escenario final se combinan las 11 especies en cada una de las 3 familias a la cual pertenece cada especie, obteniendo 3 clases con una mayor cantidad de imágenes. Se tomaron 10 épocas, con 17 iteraciones por época y una tasa de aprendizaje de 0.001.

Para la prueba se le ingresan imágenes de la base de datos que fueron separadas previamente para pruebas (5%), además de realizar una prueba con imágenes externas a la base de datos, tomadas mediante el estereomicroscopio.

7.2. Construcción de la base de datos de imágenes

7.2.1. Muestreo de calidad del agua en la quebrada La Ayurá y elección de familias

Para obtener una base de datos de imágenes (dataset), fue necesario realizar un muestreo de calidad del agua con el fin de seleccionar las familias de macroinvertebrados acuáticos más representativas de la quebrada. Luego, realizando un análisis mediante estudios previos (González V, 2008; Secretaría de Medio Ambiente, 2019) y verificación de la presencia actual de las familias

en la quebrada, fue posible obtener la presencia de los organismos durante los años 2007 – 2019 - 2021.

Para la recolección de organismos se realizó una salida de campo, en la cual se tomaron especímenes en 2 puntos de la quebrada (**Figura 6**), el primero ubicado aguas arriba, cerca al ecoparque El Salado y otro punto aguas abajo, cerca de la desembocadura en el río Medellín. La metodología para muestreo consistió en utilizar una red Surber y métodos tradicionales (Roldán, 2003), depositando las muestras en recipientes o bolsas con alcohol al 70%. El muestreo comenzó en horas de la mañana en el primer tramo de la quebrada ubicada aguas arriba, realizando el registro de parámetros físicoquímicos, tal como el aforo del caudal, pH, temperatura, conductividad y oxígeno disuelto.

Figura 6.

Fotografías de la zona de estudio.



Nota: **a.** Aguas arriba, cerca al ecoparque El Salado. **b.** Aguas abajo, cerca de la desembocadura en el río Medellín.

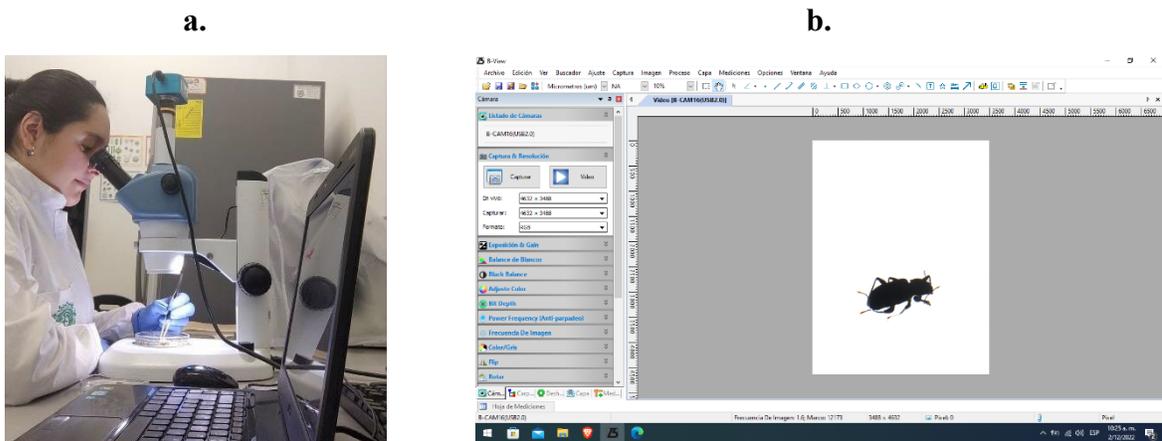
7.2.2. Toma de fotografías de los organismos en estereomicroscopio

Para realizar la captura de imágenes de los macroinvertebrados acuáticos recolectados en campo, primero se separan las muestras de acuerdo con las etiquetas y se ubican en una caja de Petri con alcohol al 70% con los organismos completamente sumergidos. Luego de esto, se estandariza la captura de la fotografía mediante el estereomicroscopio con máxima iluminación y fondo blanco (**Figura 7.b**), capturando las fotografías de los macroinvertebrados correspondientes a las 3 familias seleccionadas y posteriormente separando en 3 carpetas las respectivas imágenes.

Para la generación de la base de datos de imágenes de los organismos mediante estereomicroscopio con cámara integrada (**Figura 7.a**), se tomaron en cuenta la diferencia de tamaños de los organismos, por lo que se ubicó el carro del estereomicroscopio en su zona más alta posible con el fin de abarcar la mayor área posible, y se guardaron las imágenes en formato .tiff. Algunas de las consideraciones tenidas en cuenta son:

- El organismo debe encontrarse completo, con su estructura completa.
- Tomar fotografías dorsales, ventrales y laterales.
- Fondo blanco o azul, evitando las tonalidades verdes.
- Considerar la fase de vida del organismo: Las fases de los organismos transitan desde huevo, larva, pupa y adulto, en el caso del presente estudio se eligió la fase larval de las familias de macroinvertebrados elegidas.

Figura 7.
Captura de fotografías mediante estereomicroscopio.



Nota: **a.** Estereomicroscopio con cámara integrada. **b.** Programa B-View para cámara Boeco Germany B-CAM16.

7.3. Entrenamiento, validación y prueba de seis modelos de redes neuronales artificiales mediante la base de datos con imágenes de estereomicroscopio

La elección de las redes neuronales artificiales se realiza considerando que estuviesen en el Deep Network Designer de MATLAB (MathWorks, 2023b) y que, además, según su costo y recurso computacional pudiese ser entrenado mediante un Core i5 de 8va generación con tarjeta

gráfica básica, verificado mediante Bianco et al., (2018), eligiendo las redes neuronales AlexNet, GoogleNet, ResNet18, ResNet50, ResNet101 e InceptionV3, como se mostraba en la **Figura 3**.

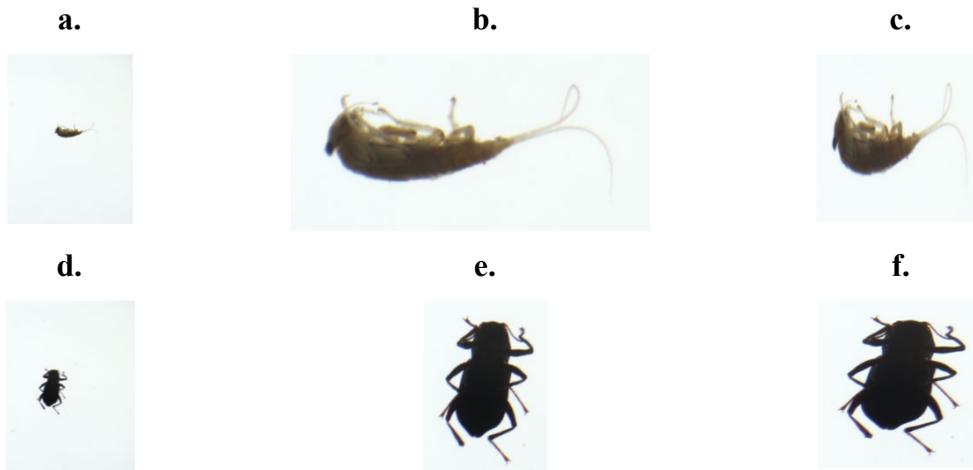
Luego de elegir el modelo, el proceso para la transferencia de aprendizaje se divide en 4 etapas para su codificación desde MATLAB, comenzando con el diseño, luego el ingreso de datos, el proceso de entrenamiento y validación, terminando con el análisis de las pruebas del comportamiento de los modelos ante imágenes nuevas mediante matriz de confusión.

7.3.1. Diseño del experimento

Para el procesamiento de la imagen se realiza un BoundingBox para realizar el recorte de la imagen con un borde externo o una distancia del 10% con respecto al organismo (**Figura 8 b y e**) y posteriormente se redimensionan las imágenes (**Figura 8 c y f**), proceso en el cual las imágenes pierden la mayoría de su resolución y en algunos casos su forma.

Figura 8.

Imágenes tomadas mediante estereomicroscopio, recortadas mediante BoundingBox y redimensionadas.



Nota: **a.** Imagen de Baetidae tomada mediante estereomicroscopio con dimensiones de 3488x4632 pixeles. **b.** Imagen de Baetidae recortada mediante BoundingBox 1507x743. **c.** Imagen de Baetidae redimensionada de 224x224 pixeles. **d.** Imagen de Elmidae capturada mediante estereomicroscopio 3488x4632. **e.** Imagen de Elmidae recortada mediante BoundingBox con dimensiones de 1061x1519 pixeles. **f.** Imagen de Elmidae con dimensiones 224x224 pixeles.

Cada red neuronal posee una capa para el ingreso de dimensiones de la imagen, por lo que se redimensionan según cada una de sus arquitecturas, como se observa en la **Tabla 2**.

Tabla 2.

Dimensiones de la capa de entrada de cada red neuronal.

	227x227x3	224x224x3	299x299x3
AlexNet		GoogleNet ResNet 18 ResNet 50 ResNet 101	Inception V3

Para el ingreso de los datos al Deep Network Designer se cambian las capas de salida del número de clases a automáticas, y la capa full connected se actualiza para que obtenga como salida las 3 clases para la clasificación que realizará cada red neuronal.

7.3.2. Datos

Para el ingreso de las imágenes al modelo, se realiza la separación de los datos, con 5% de las imágenes para pruebas, las cuales no serán ingresadas al entrenamiento del modelo. El 95% restante es utilizado para el entrenamiento y validación, en donde de ese porcentaje, se elige 70% de las imágenes para entrenamiento y 30% para validación. Con el fin de obtener una mayor cantidad de imágenes se realizó un aumento de datos con reflexión en el eje horizontal y vertical, rotación y escalado.

7.3.3. Entrenamiento y validación

Para la elección de las opciones de entrenamiento tales como la tasa de aprendizaje, época máxima y frecuencia de validación se hace uso de los resultados obtenidos en la fase inicial, configurando como estándar para la comparación de los modelos una tasa de aprendizaje inicial de 0.001, 10 épocas y una validación de frecuencia de 10. Luego de correr el modelo se obtiene la curva de aprendizaje mediante los valores de precisión del entrenamiento y de la validación, que finalmente, al exportar el modelo se obtienen los pesos de cada clase para ser utilizados en las predicciones o pruebas.

7.3.4. Prueba de los modelos con imágenes dentro de la base de datos

La evaluación del rendimiento de los modelos se realiza mediante el ingreso de las imágenes de prueba, correspondiente al 5% de las imágenes dentro de la base de datos y posteriormente graficando los resultados mediante la herramienta de matriz de confusión para analiza el porcentaje de valores acertados de clasificación para cada familia.

7.4. Prueba de los modelos mediante imágenes tomadas con el montaje de campo

7.4.1. Construcción del montaje de campo

El montaje para toma de fotografías de imágenes en campo considera como factores importantes una iluminación blanca inferior mediante aros de luz led, permitiendo que la luz viaje a través de un acrílico opaco para la difusión e iluminación de la zona en donde se encuentra la placa de Petri, con el fin de que pueda ser capturada la fotografía mediante un orificio ubicado en la parte superior, como puede observarse en la **Figura 9**.

El montaje cuenta con las ventajas de ser portable, de bajo peso, económico y pensado para posibles incidentes en campo, por lo que se le añadió una cinta para asegurar que los cajones no se abran durante su manipulación, un elástico para evitar caídas del dispositivo móvil y una zona para baterías y luces de repuesto, además de que en caso de pérdida de iluminación de lámpara de aros de luz led, puede ubicarse en su lugar una linterna de algún dispositivo móvil.

Figura 9.

Montaje de campo diseñado para la captura de imágenes de macroinvertebrados.



Nota: Elaboración propia.

7.4.2. Prueba con fotografías tomadas de organismos sumergidos en alcohol con montaje de campo

La prueba inicial realizada con imágenes tomadas mediante el montaje de campo consistió en la toma de fotografías a los mismos organismos (los organismos utilizados para la creación de la base de datos y utilizados en el entrenamiento y validación del modelo) sumergidos en alcohol y las mismas familias, pero ahora con el montaje de campo. El procedimiento incluye mantener a los organismos en alcohol y capturar las imágenes en los formatos RAW, Flash y la configuración por defecto del dispositivo celular utilizado (Xiaomi Poco X3 Pro), tratando de mantener un fondo de la imagen blanco o levemente azul, con el fin de observar el comportamiento de las redes neuronales ante imágenes de los organismos en condiciones diferentes a las de su entrenamiento. Al graficar los resultados mediante matriz de confusión es posible definir el modelo que mejor se desempeña para el análisis de las imágenes capturadas con el montaje de campo.

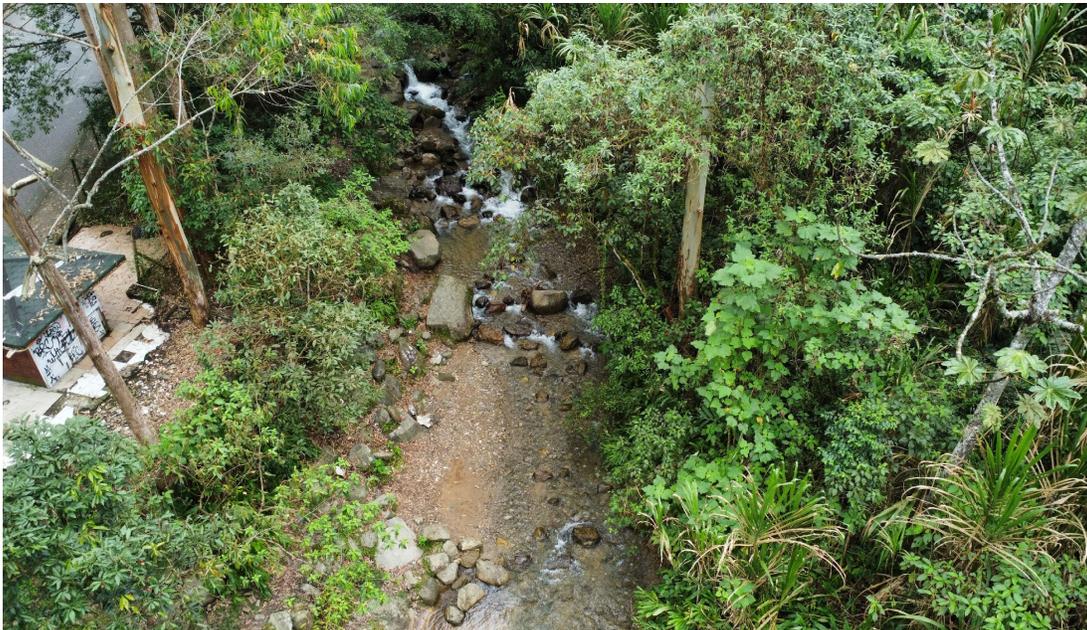
7.4.3. Prueba con fotografías tomadas de organismos vivos sumergidos en agua con montaje de campo

Para realizar la prueba externa con el fin de evaluar el comportamiento del modelo que mejor se desempeña ante las fotografías capturadas con el montaje de campo (encontrado en el apartado anterior), se realiza una salida de campo al punto ubicado aguas arriba de la quebrada La Ayurá (debido a que las familias de macroinvertebrados seleccionadas se encontraban ubicadas en el punto aguas arriba de la quebrada) con el fin de evaluar el comportamiento del modelo ante imágenes de fotografías y videos de macroinvertebrados vivos capturados mediante el montaje de campo.

Se realiza una simulación de un escenario de bio-monitoreo participativo de bajo costo, esta vez sin mediciones de parámetros fisicoquímicos y mediante una red improvisada, coladores, bandeja blanca, pinzas, recipientes, botella de agua y el montaje de campo para la toma de fotografías y videos. Inicialmente se realiza un vuelo con dron DJI Mini 2 para el reconocimiento aéreo de la zona y el registro visual de vegetación y rocas, el cual resulta atractivo como destino recreativo de la zona (**Figura 10**).

Figura 10.

Fotografía aérea del punto ubicado aguas arriba, cerca al ecoparque El Salado.



Posteriormente, se toman mediante el montaje de campo (**Figura 11**) fotografías y videos in situ de los organismos pertenecientes a las 3 familias utilizadas en el algoritmo desarrollado, considerando que la luz inferior fuese apropiada, el fondo blanco, que el agua en la que se encontraban sumergidos no tuviese muchos sedimento o restos de vegetación para evitar la adherencia de los organismos a estos y fuese de un color claro para mejor visualización.

Figura 11.

Fotografías del uso del montaje de campo para la captura de fotografías y videos de macroinvertebrados para la evaluación final del modelo.



Nota: **a.** Uso del montaje para la captura de imágenes de organismos vivos pertenecientes a las 3 familias.

b. Ubicación del montaje con uso del celular para captura de imágenes.

Luego de la toma de las imágenes de los organismos vivos, estas se ingresan al modelo que mejores resultados presentó con el fin de analizar su desempeño con las fotografías tomadas en campo, observando sus posibles fallas desde una perspectiva cualitativa, de manera que se evidencie el tipo de imágenes con las cuales presenta fallas, ya que al fin y al cabo el modelo no fue entrenado con imágenes tomadas mediante montaje de campo, y estas solo fueron utilizadas para la prueba del modelo.

7.5. Elaboración de la interfaz de usuario

La interfaz de usuario genera una aplicación llamada Biological Monitoring Working 3 (BMW3) para la clasificación de las 3 familias de macroinvertebrados, realizada mediante MATLAB App para permitir el acceso e interacción de los usuarios con el algoritmo o mejor red neuronal convolucional encontrada. En dicha interfaz se incluye el botón para interacción o carga de imagen, indicaciones de uso y espacio para observar la imagen y porcentaje de clasificación que posee la red neuronal para cada familia.

8. Resultados y Análisis

8.1. Análisis de AlexNet con bases de datos libres

En la **Tabla 3** se observan los resultados del entrenamiento, validación y pruebas del modelo mediante la base de datos de libre acceso. Para el escenario con las 11 clases separadas de macroinvertebrados que incluían a 3 especies de Baetidae, 5 de Elmidae, 3 Hydropsychidae, se obtuvo una precisión de validación en la época 10 de 81.35%.

Para el escenario de 3 clases seleccionadas al azar, se tomaron *Baetis Niger*, *Elmis Aenea* Adulto e *hydropsychidae* *Pellucidula*, realizando una detención manual al entrenamiento en la época 5 con el fin de evitar overfitting, obteniendo una precisión de validación de 98.33%.

Al combinar en una sola clase las 3 especies de Baetidae, otra con las 5 de Elmidae y otra con las 3 de Hydropsychidae, se obtuvo cerca de 700 imágenes de Baetidae, 400 de Elmidae y 200 de Hydropsychidae, realizando un stop manual en la época 5, se obtuvo un porcentaje de precisión de validación de 97.52%.

Tabla 3.

Entrenamiento y validación para los 3 escenarios con base de datos de libre acceso, con los diferentes escenarios para entrenamiento y validación.



Posteriormente, al mostrarle imágenes de prueba dentro de la base de datos y por fuera de la base de datos, se obtienen los resultados que se observan en la **Tabla 4**, en la cual se observa que, al realizar la combinación de las 11 especies en agrupaciones dentro de las 3 familias de macroinvertebrados, se obtiene un mejor rendimiento del clasificador, por lo que las siguientes pruebas de la metodología del presente informe solo separarán los datos a nivel de familia. En todos

los casos, al momento de mostrarle imágenes que no estuvieran dentro de su base de datos, con fondos e iluminación diferentes, se obtenían bajos porcentajes de clasificación. Por lo tanto, para la generación de la posterior base de datos, se considera la toma de imágenes en color blanco o un croma cercano a azul, ya que es un color que no suele tener los macroinvertebrados, mientras que el color verde presente en el fondo de la base de datos de Raitoharju et al. (2018), es un color presente en el cuerpo de este tipo de organismos.

Tabla 4.

Resultados promedio de clasificación de las familias de macroinvertebrados al utilizar los diferentes escenarios.

Tipo	11 especies separadas	3 especies al azar	11 especies juntas en las 3 familias
Precisión de validación	81.35%	98.33%	97.52%
Porcentaje promedio de la prueba con imágenes dentro de la base de datos	56.90%	100%	100%
Porcentaje promedio de la prueba con imágenes por fuera de la base de datos	1.6%	2,6%	6,5%

Para estandarizar el número de épocas para las siguientes comparaciones de modelos, se definió que con 10 épocas se lograba un alto porcentaje de validación y se obtenía un gasto de recurso computacional apropiado, sin ser necesaria la detención del entrenamiento en épocas anteriores.

8.2. Muestreo de calidad del agua, elección de las familias y generación de la base de datos de los organismos mediante estereomicroscopio.

En la **Tabla 5** se observan los resultados de los parámetros fisicoquímicos recolectados el día del muestreo, el cual se realizó en temporada de lluvias. Aguas arriba de la quebrada cerca al ecoparque El Salado se observa en general una buena calidad del agua, mientras que aguas abajo se realizan vertimientos y depósitos de sedimentos que afectan la calidad.

El pH del agua aguas arriba y aguas abajo se encuentra alrededor del neutro, y a medida que disminuye la altitud de la quebrada, la temperatura y la conductividad aumenta, mientras que el oxígeno disuelto disminuye. Cabe resaltar que el oxígeno disuelto de la muestra tomada en la parte baja es relativamente alto, el cual puede indicar la poca presencia de materia orgánica, lo cual va en contraste con el grado de contaminación visto en ese tramo de la quebrada.

Tabla 5.

Parámetros fisicoquímicos tomados aguas arriba y aguas abajo de la quebrada La Ayurá.

Parámetro / Lugar	Aguas arriba	Aguas abajo
	Coordenadas (lon-lat): -75°34'25" W 6°8'27" N	Coordenadas (lon-lat): -75°34'53" W 6°10'47" N
	Hora: 9:30 a.m.	Hora: 11:00 a.m.
pH	6,7	7,1
Temperatura (°C)	16,2	19,2
Conductividad (μS/cm)	22,8	63,6
OD (mg/L)	8,18	7,92
TDS (Sólidos disueltos totales) (mg/L)	-	63
%Sat O ₂	-	103,1
Caudal (m ³ /seg)	0,848	-

En la salida de campo se evidenció la presencia de peces del del orden de los Siluriformes y en cuanto a macroinvertebrados se encontraron organismos asociados a una buena calidad del agua en el punto ubicado aguas arriba (**Tabla 6**), ya que por ejemplo la familia Elmidae es un organismo sensible frente a los sólidos en suspensión (Dos Santos et al., 2014). Por otro lado, aguas abajo se encuentra la presencia de la familia de macroinvertebrados como Tubificidae, lo cual permite evidenciar el grado de contaminación de la quebrada en este punto.

Tabla 6.

Familias de macroinvertebrados presentes en la quebrada La Ayurá durante 2007-2021.

Zona	Orden	Familia	Periodo reportado	Puntaje BMWP-COL
Aguas arriba	Trichoptera	Hydropsychidae	2007-2021	7
	Hemíptera	Veliidae	2008-2021	8
	Ephemeroptera	Baetidae	2007-2021	7
	Coleóptera	Elmidae	2008-2021	6
Aguas abajo	Haplotáxida	Turbificidae	2007-2021	1
	Díptera	Chironomidae	2007-2021	2
	Odonata	Libellulidae	2008-2021	6

En cuanto a la presencia espaciotemporal de las familias de macroinvertebrados acuáticos presentes aguas arriba y abajo de la quebrada en los periodos de 2007 y 2021, se halla que existen familias que persisten en el tiempo debido a que poseen un ambiente favorable para su desarrollo. Entre estas familias se encuentran Baetidae, Elmidae e Hydropsychidae, las cuales son las

seleccionadas para la elaboración del presente proyecto debido a su persistencia en el tiempo y cantidad abundante en la quebrada.

Algunas de las imágenes que se obtuvieron para la base de datos de imágenes se muestran en la **Tabla 7**, mostrando la separación de las carpetas con un 5% de las imágenes para pruebas y el 95% restante para entrenamiento y validación. En total se obtuvieron 585 imágenes, con entre 165 y 220 imágenes por familia de macroinvertebrados.

Tabla 7.

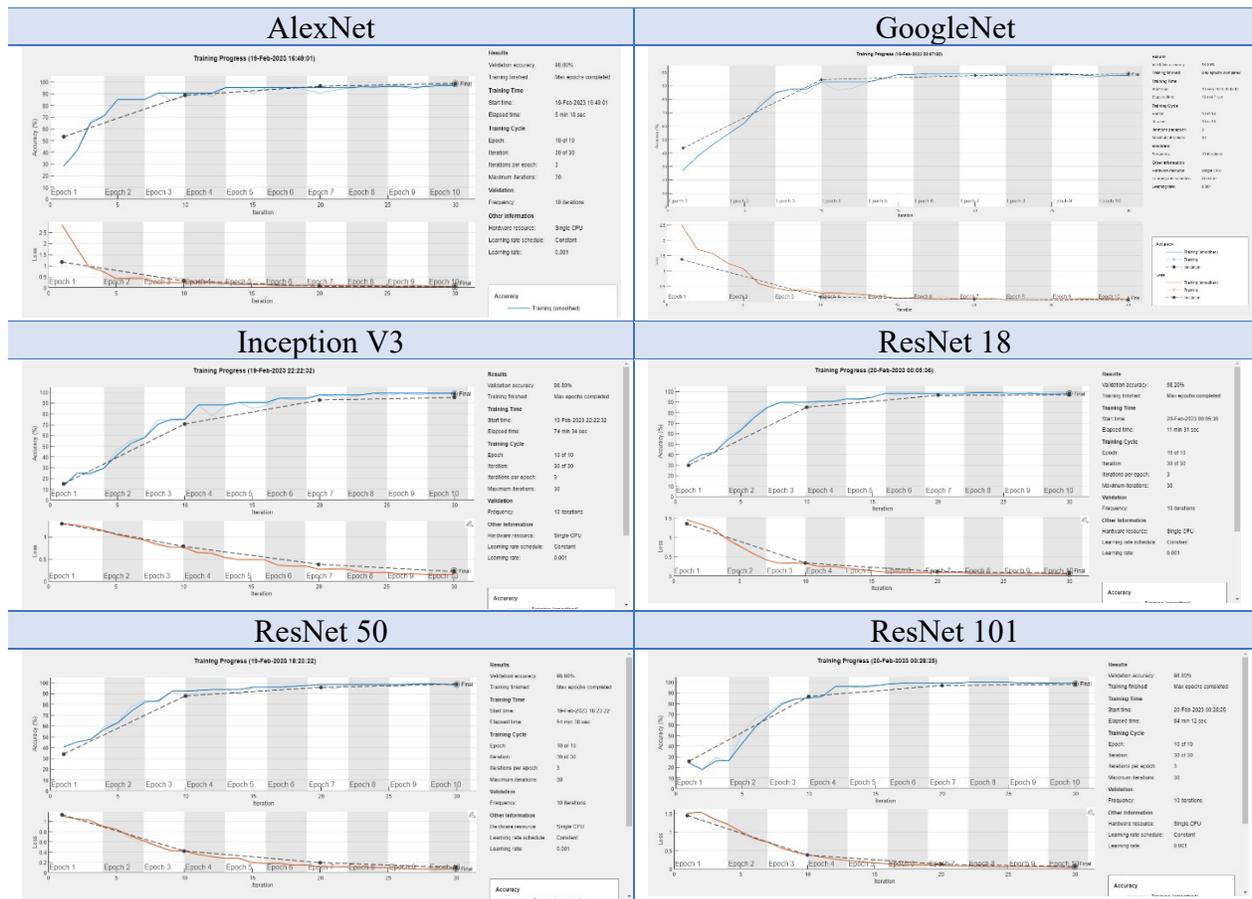
Muestra de la base de datos de imágenes de las Familias de macroinvertebrados.

Fotografías tomadas mediante estereomicroscopio			
Imagen	Baetidae	Elmidae	Hydropsychidae
Entrenamiento y Validación	 191	 210	 157
Prueba 1	 9	 10	 8
Total	200	220	165

8.3. Análisis del entrenamiento, validación y prueba inicial de las redes neuronales

Los resultados de los entrenamientos y validaciones de los modelos (**Tabla 8**) muestran que entre la época 3 y 4 ocurre una estabilización de la curva de aprendizaje, y cerca de la época 10 se llega a porcentajes de validación muy similares.

Tabla 8.
Resultados del entrenamiento y validación de los modelos – MATLAB.



Los resultados de las diferentes redes neuronales (**Tabla 9**) obtuvieron un porcentaje de validación del 98,8% exceptuando ResNet18 con 98,2%. En cuanto al tiempo de entrenamiento, en el cual influye las características de la arquitectura de cada red neuronal, se observa que AlexNet obtuvo el entrenamiento con duración más corta y ResNet101 con el periodo más largo.

Tabla 9.

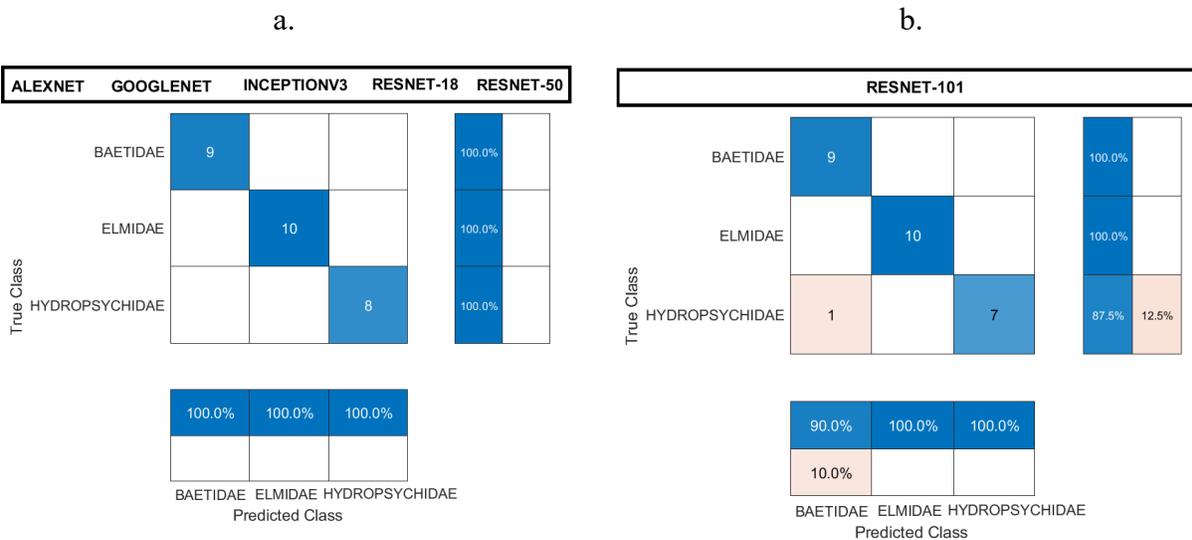
Precisión de la validación y tiempo de entrenamiento para las diferentes redes neuronales.

<i>Modelo</i>	<i>Precisión de la validación</i>	<i>Tiempo de entrenamiento</i>
<i>AlexNet</i>	98,8%	5 min 18 seg
<i>GoogleNet</i>	98,8%	12 min 1 seg
<i>ResNet 18</i>	98,2%	11 min 31 seg
<i>ResNet 50</i>	98,8%	54 min 38 seg
<i>ResNet 101</i>	98,8%	84 min 12 seg
<i>Inception V3</i>	98,8%	74 min 34 seg

Los resultados de la prueba con el 5% de las imágenes de la base de datos mediante la matriz de confusión (**Figura 12**), permiten observar la cantidad de aciertos y errores, en los cuales para AlexNet, GoogleNet, InceptionV3, ResNet18 y ResNet50 obtuvieron resultados iguales y acertados en todos los casos, mientras que para ResNet101 se presentó un resultado erróneo para la clasificación de la clase Hydropsychidae.

Figura 12.

Matriz de confusión para prueba de las redes neuronales convolucionales con imágenes de la base de datos con estereomicroscopio.



Nota: **a.** Matriz de confusión para AlexNet, GoogleNet, InceptionV3, ResNet-18 y ResNet-50 con imágenes de prueba capturadas mediante estereomicroscopio. **b.** Matriz de confusión para ResNet-101 con imágenes de prueba capturadas mediante estereomicroscopio.

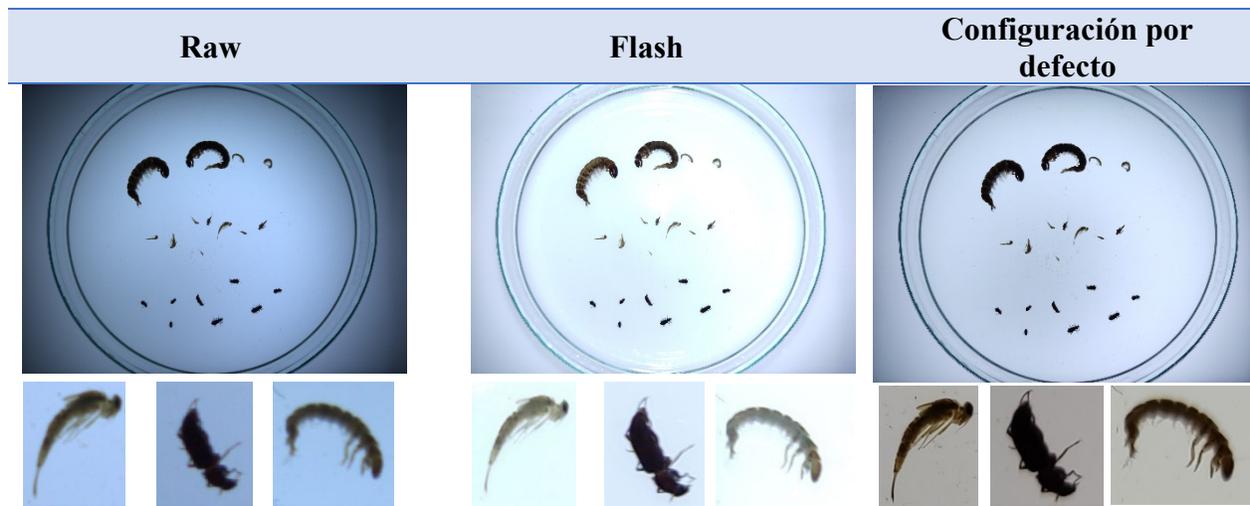
8.4. Análisis de los resultados de las pruebas con imágenes tomadas mediante montaje de campo

En la **Tabla 10** se observan las imágenes tomadas capturadas mediante el montaje de campo de los organismos sumergidos en alcohol. En cada caja de Petri se encontraban los organismos correspondientes a las 3 familias de macroinvertebrados, por lo que fue necesario realizar un recorte manual de las imágenes, obteniendo imágenes como las que se observan en la parte inferior de la **Tabla 10**.

Las mejores características para la captura de las imágenes en el formato RAW se encontraron mediante las características de mínima apertura del diafragma F:0, velocidad de obturación de S:1/50 y una sensibilidad del sensor de la cámara a la luz de ISO:50. Como veremos más adelante, las imágenes tomadas mediante flash y configuración por defecto sin ningún preprocesamiento, ayudan a mejorar la clasificación debido a las características de su fondo blanco (**Tabla 10**) y en el caso de la configuración por defecto, debido a que la definición del borde externo de la imagen es similar a las imágenes de entrenamiento, se obtuvieron mejores resultados gracias a su similitud con las imágenes tomadas en la base de datos con el estereomicroscopio.

Tabla 10.

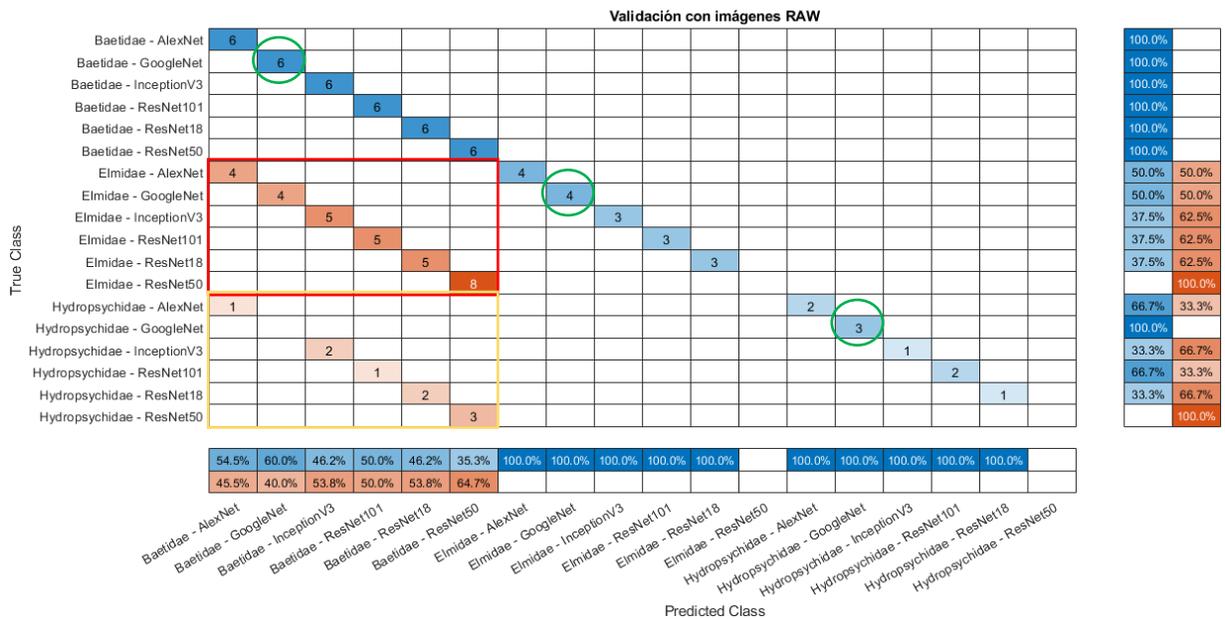
Imágenes de los organismos capturadas con el montaje de campo para la prueba externa del modelo con organismos sumergidos en alcohol, con 3 formatos de captura de imagen.



Los resultados de las pruebas obtenidas para los 6 modelos con las imágenes de la tabla anterior (**Tabla 10**), para 6 imágenes de Baetidae, 8 de Elmidae y 3 de Hydropsychidae tomadas mediante el montaje de campo en alcohol, muestran que para los resultados con el formato de captura RAW (**Figura 13**), se obtuvieron los peores resultados de clasificación, evidenciando una tendencia de los modelos a clasificar las clases no conocidas de Elmidae e Hydropsychidae como Baetidae, sin embargo, la red neuronal que mejor se desempeña es GoogleNet, en parte debido a la eficiencia con la que utiliza sus parámetros (Bianco et al., 2018).

Figura 13.

Matriz de confusión para la prueba externa con fotografías capturadas mediante el montaje de campo en formato RAW para las 6 redes neuronales.



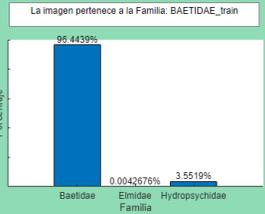
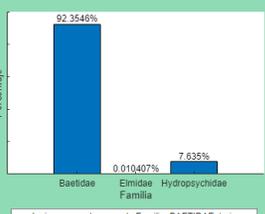
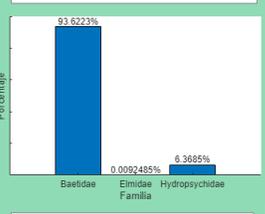
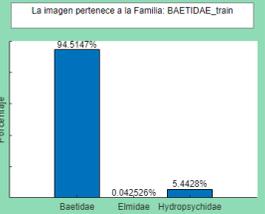
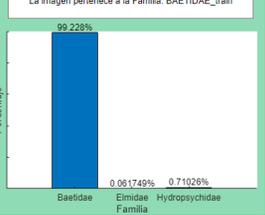
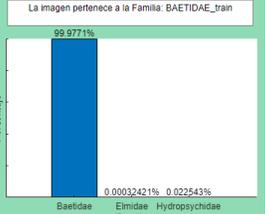
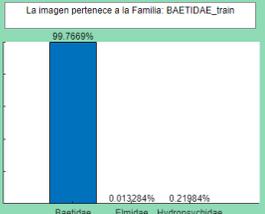
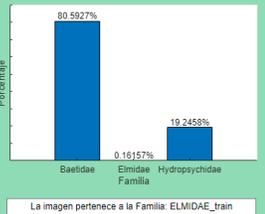
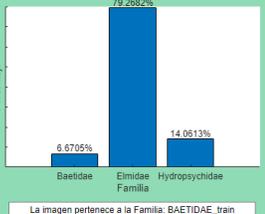
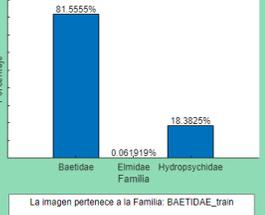
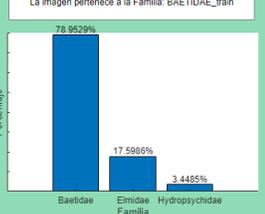
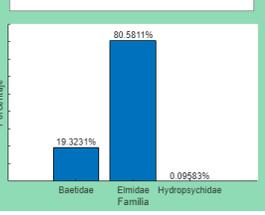
Mediante las imágenes capturadas con flash (**Figura 14**), se muestra mejoría en general en la clasificación de algunos modelos como GoogleNet, ResNet18 y ResNet50, en otros casos se obtuvieron incrementos en la clasificación de algunas familias y disminución en otras con respecto a las imágenes RAW como es el caso de InceptionV3, mientras que con AlexNet ocurrió una leve desmejora en la clasificación de una imagen con respecto a RAW. Con la red neuronal ResNet101 se obtuvieron resultados iguales para imagen con flash y RAW, obteniendo que son más las redes neuronales que mejoran la clasificación al utilizar la imagen con flash en vez de RAW, debido al color de fondo y definición de la forma externa de los organismos que se observa con este formato.

Las imágenes capturadas de los organismos mediante imágenes por defecto (**Figura 15**) obtuvieron mejoras en las redes neuronales GoogleNet, InceptionV3, ResNet18, mientras que en AlexNet, ResNet101 y ResNet50 no ocurrieron mayores diferencias. Finalmente, el total de las imágenes tomadas mediante el montaje de campo con organismos sumergidos en alcohol y formato por defecto fueron clasificadas correctamente mediante la red neuronal GoogleNet entrenada y validada con imágenes de los mismos organismos en el estereomicroscopio, siendo esta red neuronal como la considerada como el mejor algoritmo hasta el momento para la clasificación de las imágenes de laboratorio y campo.

Con el fin de analizar el comportamiento de las imágenes de prueba para la red neuronal GoogleNet ante el ingreso de imágenes de fotografías y videos de organismos vivos sumergidos en agua (evitando los pequeños sólidos que ingresan a la placa), se muestran los resultados de **la Tabla 11**, en la cual se observa de manera cualitativa el tipo de imágenes con las cuales presenta fallas el modelo. En la captura de estas imágenes se evidencia que las familias de macroinvertebrados Baetidae, Elmidae e Hydropsychidae se conservan durante el periodo 2007 a 2023, por lo que podría decirse que no han ocurrido diferencias significativas en la contaminación de la quebrada durante estos años. Además, el análisis se realiza mediante la distribución de probabilidades para cada clase a partir de las imágenes de entrada, siendo interpretada como la probabilidad de que la imagen pertenezca a cada clase, en el cual, luego de esto se genera un umbral de decisión en el cual, si el porcentaje al cual cree pertenecer una clase es mayor a las demás, se considera que una imagen pertenece a una clase determinada.

En los resultados de la **Tabla 11** se sigue observando una inclinación de las clases por la familia de organismos Baetidae, ya que 8 de las imágenes que realizaron la clasificación de manera incorrecta, indicaban que era un falso Baetidae. Además, se logra observar la necesidad de que las imágenes de prueba (capturadas con el montaje de campo) sean similares a las imágenes de entrenamiento y validación (que en este caso fueron las tomadas mediante estereomicroscopio).

Tabla 11.
Resultados de reconocimiento de imágenes de macroinvertebrados vivos con imágenes de fotografías y videos tomadas mediante celular en formato por defecto.

Familia	Imagen de Video o Fotografía	%de cada clase	Clasificación Correcta	
Baetidae		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI	
	Elmidae		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI
			<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	SI
		<p>La imagen pertenece a la Familia: ELMIDAE_train</p> 	SI	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	NO	
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> 	NO	
		<p>La imagen pertenece a la Familia: ELMIDAE_train</p> 	SI	

Hydropsychidae		<p>La imagen pertenece a la Familia: ELMIDAE_train</p> <p>99.5875%</p> <p>0.40487% 0.0075992%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	SI
			<p>La imagen pertenece a la Familia: HYDROPSYCHIDAE_train</p> <p>75.1826%</p> <p>23.9352% 0.88223%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>
		<p>La imagen pertenece a la Familia: ELMIDAE_train</p> <p>99.7142%</p> <p>0.23589% 0.049903%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	SI
		<p>La imagen pertenece a la Familia: ELMIDAE_train</p> <p>98.4446%</p> <p>10.554% 1.0014%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	SI
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> <p>98.8836%</p> <p>0.054911% 1.0615%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	NO
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> <p>92.2851%</p> <p>0.015819% 7.6991%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	NO
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> <p>97.8407%</p> <p>0.0010335% 2.1582%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	NO
		<p>La imagen pertenece a la Familia: HYDROPSYCHIDAE_train</p> <p>59.9896%</p> <p>39.9511% 0.055224%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	SI
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> <p>56.82%</p> <p>43.1707% 0.0093826%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	NO
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> <p>96.9495%</p> <p>0.24504% 2.8054%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	NO
		<p>La imagen pertenece a la Familia: HYDROPSYCHIDAE_train</p> <p>77.8715%</p> <p>22.1068% 0.02169%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	SI
		<p>La imagen pertenece a la Familia: BAETIDAE_train</p> <p>63.0777%</p> <p>36.9110% 0.010413%</p> <p>Baetidae Elmidae Hydropsychidae</p> <p>Familia</p>	NO

8.5. Análisis de la interfaz de usuario

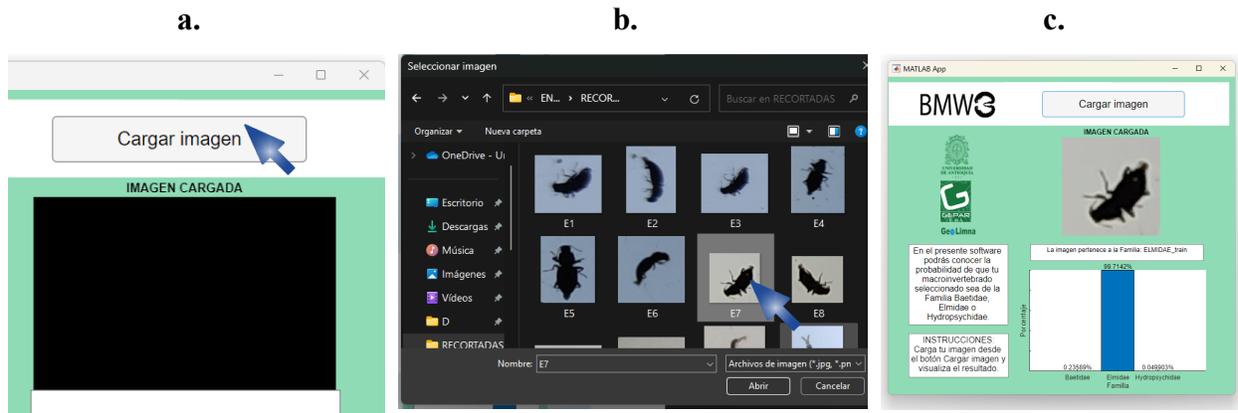
La interfaz de usuario BMW3 corresponde a un primer acercamiento al monitoreo biológico para el cálculo del índice biótico BMWP para 3 de 95 familias de macroinvertebrados mediante visión artificial. En la **Figura 16** se muestra la interfaz de usuario con la que los usuarios pueden interactuar.

Figura 16.
Interfaz gráfica de usuario.



La interfaz de usuario permite que al abrirla se ejecute MATLAB App con el fin de permitir el acceso a la información de entrenamiento del modelo GoogleNet entrenado, para que posteriormente el usuario con solo dar click en “Cargar imagen” pueda seleccionar la imagen de alguna de las 3 familias que desee clasificar (**Figura 17 a y b**) y obtener así el porcentaje de clasificación que posee la red neuronal para cada familia (**Figura 17 c**).

Figura 17.
Uso de la aplicación BMW3



Nota: **a.** Cargar imagen. **b.** Selección de la imagen. **c.** Resultado del porcentaje de clasificación.

9. Conclusiones

En una fase preliminar del proyecto, se observa que al analizar las especies de las tres familias mediante 11 categorías separadas que incluyan 3 especies de Baetidae, 5 de Elmidae, 3 Hydropsychidae, se obtuvieron resultados más bajos de clasificación que para las taxa juntas desde la categoría taxonómica de familia, además de que puede observarse la interferencia del color verde al utilizarse como fondo para la toma de las imágenes de los organismos y la calidad de la imagen.

Al realizar los muestreos de organismos en la quebrada La Ayurá, se evidencia la abundancia de las familias de macroinvertebrados Baetidae, Elmidae e Hydropsychidae durante los años 2007, 2019, 2021 y 2023 en el punto ubicado aguas arriba, por lo que no ha disminuido de manera significativa la calidad del agua en este sitio.

Una buena delimitación de características para la creación de la base de datos de imágenes capturadas mediante el estereomicroscopio con organismos sumergidos en alcohol (tales como tener fondo blanco y organismo completo), permiten obtener la clasificación total de imágenes de organismos para la prueba con imágenes de la misma base de datos, exceptuando para ResNet101.

La construcción de un montaje para la captura de imágenes de macroinvertebrados en campo requiere del análisis de aspectos tales como iluminación, formato de toma de fotografía, calidad de la cámara, portabilidad y peso del montaje, posibilidad de mojarse en campo y bajo costo en caso de utilizarse en biomonitoreos participativos.

Al ingresar para las pruebas externas imágenes tomadas con el montaje de campo a los modelos entrenados con imágenes de estereomicroscopio, se reducen considerablemente los resultados de la clasificación, pero se descubre que la red neuronal convolucional que mejor logra realizar esta tarea de extrapolación de base de datos de imágenes con los mismos organismos es GoogleNet, obteniendo además mejores resultados con imágenes capturadas en formato por defecto del dispositivo móvil.

Al momento de observar el comportamiento de GoogleNet entrenado y validado mediante imágenes de estereomicroscopio con organismos sumergidos en alcohol y realizando pruebas el montaje de campo con organismos vivos, se logra identificar oportunidades para la mejora del algoritmo, debido a que se obtuvieron bajos resultados en la clasificación ya que las imágenes se salían de las características con las cuales el modelo reconoció los patrones.

El diseño de una interfaz de usuario en el ámbito de la clasificación de imágenes permite facilitar la interacción de las personas con los modelos entrenados, mejorando la accesibilidad de los modelos y la interacción de estos con diferentes actores, tomadores de decisiones e investigadores, con el fin de que la comunidad pueda realizar pruebas para diferentes fines, promoviendo un enfoque más inclusivo y amplio en la aplicación práctica de los algoritmos de clasificación de imágenes.

10. Recomendaciones

Con el fin de mejorar el proceso de entrenamiento, es posible realizar el procesamiento previo de las imágenes, como por ejemplo la binarización para obtener más información sobre el borde externo de la imagen.

Para obtener mejoras en los resultados de clasificación de imágenes mediante el montaje de campo es necesario incluir en el entrenamiento y validación del modelo imágenes de organismos vivos y muertos en alta cantidades con el fin de que los filtros de las arquitecturas pueden definir automáticamente mejores pesos. Al momento de generar el banco de imágenes de organismos vivos se recomienda realizar un cultivo de organismos vivos en laboratorio para obtener una mayor cantidad de imágenes sin tener que desplazarse a la zona de estudio de manera continua.

Para el procesamiento de las imágenes en futuras ocasiones, se aconseja realizar un BoundingBox completamente simétrico y cuadrado para no generar errores en la percepción de los píxeles de la imagen. Siendo de gran importancia el preprocesamiento de la imagen al momento de ingresar los datos a las redes neuronales convolucionales, de manera que no ocurran las deformaciones en este tipo de organismos al redimensionar la imagen.

Con el fin de generar conocimiento local de los cuerpos hídricos, se recomienda el uso de montajes de campo en los biomonitoreos participativos.

El aplicativo posee potencial de convertirse en una herramienta complementaria para al análisis de calidad del agua en el biomonitoreo participativo y en análisis de calidad del agua en industrias o bocatomas rurales, sin ser necesaria la muerte de los organismos, siendo necesario que se generen bases de datos más grandes que incluyan por lo menos las 95 familias pertenecientes al BMWP-Col.

Actualmente existen redes neuronales con mayor costo computacional y que utilizan con mayor eficiencia sus parámetros, además de que existen redes no solo para la clasificación, sino para la detección mediante formas como rectángulos que ubican la clase o segmentación que definen la forma externa de dicho objeto, por lo que pueden ser de gran ayuda para la mejora de la clasificación de macroinvertebrados en tareas futuras de reconocimiento de patrones en imágenes digitales.

10. Referencias

- Aguirre, D. J., Aguirre, N. J & Caicedo, O. (2008). *Evaluación de la calidad del agua a través de los protistas en la quebrada La Ayurá en Envigado (Antioquia)*.
- Ahmed, S. (2019). *Reconocimiento de caracteres en imágenes mediante el uso de CNNs*.
- Álvarez, L. (2005). *Metodología para la utilización de los macroinvertebrados acuáticos como indicadores de la calidad del agua*. Repositorio Humboldt.
- Ärje, J., Claus Melvad, Mads Gravers Jeppesen, Sigurd Agerskov Madsen, Raitoharju, J., Rasmussen, M., Alexandros Iosifidis, Ville Tirronen, Moncef Gabbouj, Meissner, K., & Høye, T. T. (2020a). *Automatic image-based identification and biomass estimation of invertebrates*. 11(8), 922–931. <https://doi.org/10.1111/2041-210x.13428>
- Ärje, J., Raitoharju, J., Iosifidis, A., Tirronen, V., Meissner, K., Gabbouj, M., ... & Kärkkäinen, S. (2020b). *Human experts vs. machines in taxa recognition*. *Signal Processing: Image Communication*, 87, 115917.
- Bianco, R. Cadene, L. Celona and P. Napoletano. (2018). *Benchmark Analysis of Representative Deep Neural Network Architectures*. IEEE Access, vol. 6, pp. 64270-64277
- Biomonitoreo Ciudadano [BIOMCI]. (2023). *¿Qué es BIOMCI?*. <https://biomci.ar/>
- Caicedo-Chacón, L.-Y., Barón-González, H.-J., Sánchez-Pedroza, J.-C., Aguilar-Carreño, C.-A., Vega-Otálora, K.-S., & Borja-Acosta, K.-G. (2023). *BiolCol: Plataforma Tecnológica para la Difusión de la Colección Biológica de Referencia de Macroinvertebrados Acuáticos*. *Revista Facultad De Ingeniería*, 32 (64), e15525. <https://doi.org/10.19053/01211129.v32.n64.2023.15525>
- Cruz, L.D.; Lopez, D.M.; Vargas-Canas, R.; Figueroa, A.; Corrales, J.C. (2022). *Computer-Assisted Bioidentification Using Freshwater Macroinvertebrates: A Scoping Review*. *Water*, 14, 3249. <https://doi.org/10.3390/w14203249>
- Dos Santos, D. A., Reynaga, M. C. (2014). *IBY-4: Una herramienta muy simple para el biomonitoreo de ríos en el noroeste argentino*.
- Global Biodiversity Information Facility [GBIF]. (2023). *Global Biodiversity Information Facility*. <https://www.gbif.org/es>
- González, V., Caicedo, O & Aguirre, N. (2013). *Aplicación de los índices de calidad de agua NSF, DINIUS y BMWP en la quebrada La Ayurá, Antioquia, Colombia*.
- González, V. (2008). *Evaluación de la calidad del agua de la quebrada La Ayurá mediante la aplicación de índices de calidad - ICAS e índices de Bióticos*. [tesis de pregrado, Universidad de Antioquia, Medellín].
- Høye, T. T., Mads Dyrmann, Kjær, C., Nielsen, J., Bruus, M., Cecilie Mielec, Vesterdal, M. S., Bjerge, K., Sigurd Agerskov Madsen, Mads Gravers Jeppesen, & Claus Melvad. (2022). *Accurate image-based identification of macroinvertebrate specimens using deep*

- learning—How much training data is needed?* 10, e13837–e13837.
<https://doi.org/10.7717/peerj.13837>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). *Machine learning and deep learning*. 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Kautz, A. R., Louw, M., Bartley, C. M., Morse, J. W., & Wenzel, J. W. (2022). *Macroinvertebrates.org: Creating a Digital Teaching Collection of Common Freshwater Macroinvertebrates of Eastern North America*. 68(1), 28–31.
<https://doi.org/10.1093/ae/tmac012>
- Maeda-Gutiérrez, V.; Galván-Tejada, C.E.; Zanella-Calzada, L.A.; Celaya-Padilla, J.M.; Galván-Tejada, J.I.; Gamboa-Rosales, H.; Luna-García, H.; Magallanes-Quintanar, R.; Guerrero Méndez, C.A & Olvera-Olvera, C.A. (2020). *Comparison of Convolutional Neural Network Architectures for Classification of Tomato Plant Diseases*. Appl. Sci. 10, 1245.
<https://doi.org/10.3390/app10041245>
- MathWorks. (2023a). *Reconocimiento de patrones, clasificación de datos de entrada para la detección y clasificación de objetos, y la detección de defectos*. <https://bit.ly/3NWRhOs>
- MathWorks. (2023b). *Deep Network Designer*. <https://bit.ly/Deep-Network-Designer>
- Milosavljević, A. R., Đurađ Milošević, & Bratislav Predic. (2021). *Species identification for aquatic biomonitoring using deep residual cnn and transfer learning*. 20(1), 001–001.
<https://doi.org/10.22190/fuacr201118001m>
- Mohammed, Y & Nigar, M. (2023). *CNN-Based Transfer Learning for 3D Knuckle Recognition*. Advances in Multimedia, vol. 2023, Article ID 6147422, 12 pages, 2023.
<https://doi.org/10.1155/2023/6147422>
- Naranjo, X., Gutierrez, Y. (2017). *Caracterización y zonificación de susceptibilidad por movimientos en masa, en la cuenca la quebrada La Ayurá: tramo cerros astilleros: parque ecológico El Salado, municipio de Envigado: Antioquia*. [tesis de pregrado, Universidad EAFIT, Medellín]
- Pérez Ortiz de Landaluce, M. (2021). *Clasificación de imágenes mediante algoritmos de Deep Learning: Mascarillas de COVID-19*. [Trabajo Fin de Grado, Universidad de Sevilla, Sevilla].
- Preciado, B. (2007). *Fecundidad y progreso en disputa: Agua y modernización en la quebrada La Ayurá*. [tesis de pregrado, Universidad de Antioquia, Medellín].
- Quintero, C., Merchán, F., Cornejo, A., & Galán, J. S. (2018). *Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo*. KnE Engineering, 3(2), 585-596.
<https://doi.org/10.18502/keg.v3i1.1462>
- Raitoharju, J., Riabchenko, E., Ahmad, I., Iosifidis, A., Gabbouj, M., Kiranyaz, S., Tirronen, V., Arje, J., Kärkkäinen, S., Meissner, K. (2021). *FIN-Benthic*. <https://bit.ly/433ikM5>
- Raitoharju, J. R. (2018). *Benchmark database for fine-grained image classification of benthic macroinvertebrates*. Image and Vision Computing, 78, 73-83.:
<https://doi.org/10.1016/j.imavis.2018.06.005>
- Raitoharju, J., Ekaterina Riabchenko, Meissner, K., Ahmad, I., Alexandros Iosifidis, Moncef Gabbouj, & Serkan Kiranyaz. (2016). *Data Enrichment in Fine-Grained Classification of Aquatic Macroinvertebrates*. 43–48. <https://doi.org/10.1109/cvau.2016.20>
- Roldán-Pérez, G. (2016). *Los macroinvertebrados como bioindicadores de la calidad del agua: cuatro décadas de desarrollo en Colombia y Latinoamérica*. Revista de la Academia

- Colombiana de Ciencias Exactas, Físicas y Naturales, 40(155), 254–274. <https://doi.org/10.18257/raccefyn.335>
- Roldán Pérez, G. (2003). *Bioindicación de la calidad del agua en Colombia, Uso del método BMWP/Col*. Ciencia y tecnología. Medellín: Universidad de Antioquia.
- Secretaría de Medio Ambiente y Desarrollo Agropecuario de Envigado. (2019). *Diagnóstico de la calidad de las aguas superficiales en temporada seca y húmeda de las quebradas La Mina, Cien Pesos, La Ayurá, Las Palmas, Espíritu Santo, La Zuñiga, La Honda, La Hondita, La Heliodora Y La Sucia, ubicadas en El Municipio De Envigado*. Contratos N° ENV-15-30-052-18 y N° ENV-15-30-0764-19.
- Serna López, J. P., Fernández Mc Cann, D. S., Vélez Macias, F. d., & Aguirre Ramírez, N. J. (2020). *An image processing method for recognition of four aquatic macroinvertebrates genera in freshwater environments in the Andean region of Colombia*. *Environmental Monitoring and Assessment*. 192(10), 1-11.
- Serna, J. (2020). *Análisis de la estabilidad ecológica de un reo ambiente a lo largo de un gradiente altitudinal a través de los macroinvertebrados acuáticos y el procesamiento digital de imágenes*. [tesis de doctorado, Universidad de Antioquia, Medellín].
- Sistema de Información de Biodiversidad de Colombia [SIB Colombia]. (2023). *Biodiversidad para todos*. <https://biodiversidad.co/>
- STROUD Water Research Center. (2023). *David Funk, Entomologist, Photography*. <https://stroudcenter.org/people/funk/>
- USAID From the American People. (2023). *La tecnología al servicio de la comunidad*. <http://calculadora-de-abi.github.io/>
- Valverde, N. L., Caicedo, O & Aguirre, N. (2009). *Análisis de calidad de agua de la quebrada La Ayurá con base en variables fisicoquímicas y macroinvertebrados acuáticos*.
- Walters, D.M., M.A. Ford, and R.E. Zuellig. (2017). *An open-source digital reference collection for aquatic macroinvertebrates of North America*. *Freshwater Science* 36(4):693-697. DOI: 10.1086/694539.
- Wang, P., Fan, E., & Wang, P. (2021). *Comparative analysis of image classification algorithms based on traditional machine learning and deep learning*. 141, 61–67. <https://doi.org/10.1016/j.patrec.2020.07.042>
- Zamora, G. H. (1999). *Adaptación del índice BMWP para la evaluación biológica de la calidad de las aguas epicontinentales en Colombia*. *Rev Unicauca, Ciencia*, 4: 47-60.
- Zhang, J., Li, C., Yin, Y., Zhang, J., & Grzegorzec, M. (2023). *Applications of artificial neural networks in microorganism image analysis: a comprehensive review from conventional multilayer perceptron to popular convolutional neural network and potential visual transformer*. 56(2), 1013–1070. <https://doi.org/10.1007/s10462-022-10192-7>