



**I  
N  
A  
O  
E**

**Adaptative meta-recognition for continual  
open-world object detection using drones.**

**PhD Dissertation Proposal**

by

**César Adrián Granados Bernal**

Doctoral Advisors:

**Dr. Eduardo Morales Manzanares, INAOE**

**Dr. José Martínez Carranza, INAOE**

Instituto Nacional de Astrofísica, Óptica y Electrónica

©Coordinación de Ciencias Computacionales

December, 2024

Santa María de Tonantzintla, Puebla, CP 72840



# Contents

|          |  |          |
|----------|--|----------|
| <b>1</b> | <b>Introducción</b>                                    | <b>3</b> |
| 1.1      | Justificación . . . . .                                | 6        |
| 1.2      | Planteamiento del problema . . . . .                   | 6        |
| 1.3      | Preguntas de investigación . . . . .                   | 7        |
| 1.4      | Hipótesis . . . . .                                    | 7        |
| 1.5      | Objetivo General . . . . .                             | 8        |
| 1.6      | Objetivos específicos . . . . .                        | 8        |
| 1.7      | Contribuciones esperadas . . . . .                     | 8        |
| <b>2</b> | <b>Marco teórico</b>                                   | <b>9</b> |
| 2.1      | Aprendizaje computacional (Machine learning) . . . . . | 9        |
| 2.1.1    | Aprendizaje supervisado . . . . .                      | 10       |
| 2.1.2    | Aprendizaje no supervisado . . . . .                   | 10       |
| 2.2      | Redes Neuronales Convolucionales . . . . .             | 11       |
| 2.3      | Detección de objetos . . . . .                         | 11       |
| 2.4      | Aprendizaje continuo . . . . .                         | 12       |
| 2.4.1    | Olvido catastrófico . . . . .                          | 13       |
| 2.5      | Enfoques del aprendizaje continuo . . . . .            | 13       |
| 2.5.1    | Enfoque basado en representaciones . . . . .           | 13       |
| 2.5.2    | Enfoque basado en optimización . . . . .               | 14       |

|          |   |           |
|----------|---|-----------|
| 2.5.3    | Enfoque basado en repetición . . . . .  | 14        |
| 2.6      | Reconocimiento de conjunto cerrado . . . . .  | 15        |
| 2.7      | Reconocimiento de conjunto abierto . . . . .  | 16        |
| 2.8      | Reconocimiento de mundo abierto . . . . .   | 17        |
| 2.8.1    | Meta reconocimiento . . . . .   | 17        |
| 2.9      | Detección de objetos de mundo abierto . . . . .   | 18        |
| 2.10     | Métricas de evaluación . . . . .  | 19        |
| 2.10.1   | Métricas para la detección de objetos en mundo abierto . . . . .  | 19        |
| 2.10.2   | Métrica de distancia . . . . .  | 22        |
| 2.10.3   | Modelos estadísticos paramétricos . . . . .   | 22        |
| 2.11     | Drones o <i>Unmanned Aerial Vehicle</i> (UAV) . . . . .   | 24        |
| <b>3</b> | <b>Estado del Arte</b>  | <b>24</b> |
| 3.1      | Drones o <i>Unmanned Aerial Vehicle</i> (UAV) . . . . .   | 24        |
| 3.2      | Aprendizaje de mundo abierto de detección de objetos . . . . .  | 27        |
| 3.2.1    | Aprendizaje de mundo abierto de detección de objetos con un<br>enfoque de detección de datos fuera de la distribución . . . . . | 27        |
| 3.2.2    | Aprendizaje de mundo abierto de detección de objetos bajo<br>un enfoque de meta reconocimiento . . . . .                        | 31        |
| 3.2.3    | Otros trabajos que abordan problemas puntuales en el apren-<br>dizaje de detección de objeto de mundo abierto . . . . .         | 35        |
| 3.3      | Meta reconocimiento . . . . .   | 38        |

|          |                                |           |
|----------|--------------------------------|-----------|
| <b>4</b> | <b>Metodología</b>             | <b>43</b> |
| <b>5</b> | <b>Resultados preliminares</b> | <b>45</b> |
| <b>6</b> | <b>Plan de trabajo</b>         | <b>49</b> |
|          | <b>References</b>              | <b>51</b> |

## Abstract

En los últimos años, la detección de objetos ha avanzado significativamente con el desarrollo de algoritmos de aprendizaje profundo. Sin embargo, los entornos dinámicos o de mundo abierto representan un reto para estos modelos, la variabilidad de los datos, la presencia de datos no observados y autonomía que se exige evita su rápido desarrollo. Una situación crítica para sistemas que requieren de estos algoritmos para desempeñar tareas aplicadas. Los drones, sistemas aéreos no tripulados, son una tecnología de alto impacto que requieren de estos algoritmos para aumentar su desempeño en áreas como agricultura, la vigilancia, y el monitoreo remoto. Por otro lado, el aprendizaje continuo aporta soluciones a los retos de los entornos dinámicos proporcionando las capacidades para aprender de forma continuo a partir de un flujo de datos, actualizar su conocimiento sin reentrenamiento total del modelo. Sin embargo, reconocer y rechazar nuevos objetos de forma continua durante el aprendizaje es un problema todavía no resuelto. En este sentido, el meta reconocimiento, proporcionando capacidades para evaluar la información aprendida, añadiéndola, actualizándola o rechazándola, ya que les permite a los modelos reconocer y entender la fiabilidad de sus predicciones. Por ello, campos como el aprendizaje de detección de objetos de mundo abierto integra la detección de objetos, el aprendizaje continuo y el meta reconocimiento para desarrollar sistemas inteligentes con capacidades de adaptabilidad en entornos de mundo abierto. No obstante, los avances se han centrado esencialmente en la segmentación de posibles objetos conocidos y desconocidos y aproximaciones desde distintas técnicas de clasificación. Sin embargo, problemas como el aprendizaje continuo de objetos y la adaptabilidad de los sistemas de meta reconocimiento se abordan escasamente. Un problema relevante para áreas como los drones y sistemas que interactuar en estos entornos. Por lo tanto, en esta propuesta, se pretende abordar el problema de la adaptabilidad de los modelos de meta reconocimiento para modelos de aprendizaje continuo de detección de objetos de mundo abierto y su integración con drones.

Palabras clave: Aprendizaje Continuo, Aprendizaje en Mundo Abierto, Metareconocimiento, Reconocimiento de Conjuntos Abiertos, Aprendizaje Automático

# 1 Introducción

En los últimos años, la detección de objetos ha avanzado significativamente con el desarrollo conjunto de algoritmos de aprendizaje profundo y redes neuronales artificiales especializadas en el procesamiento de datos con múltiples dimensiones como las redes neuronales convolucionales [22]. Estas técnicas se desempeñan con alta precisión en tareas de detección de objetos cuando se conoce con anterioridad el conjunto de objetos observables, existe un entorno invariante o controlado y asistencia para optimizar y solucionar situaciones desconocidas por los modelos como agregar nuevos objetos, rechazar muestras inconsistentes y reconocer nuevos objetos. Sin embargo, los entornos dinámicos o de mundo abierto representan un reto mucho mayor, donde se debe considerar recurso, eficiencia, escalabilidad, autonomía, el aprendizaje a partir de un flujo de dato continuo, variabilidad de los datos, presencia de datos no observados y estrategias de aprendizaje no supervisadas[26].

Los drones, sistemas aéreos no tripulados, son una tecnología de alto impacto que pueden realizar tareas de forma autónoma en áreas como la agricultura, la vigilancia, supervisión de tráfico e infraestructura y el monitoreo remoto [42, 5, 13]. Así mismo, pueden extender su capacidades al adaptar algoritmos inteligentes como los modelos de aprendizaje profundo. Sin embargo, los sistemas actuales de aprendizaje profundo para drones operan bajo las restricciones de los entornos controlados o conjunto cerrado, es decir, con total conocimiento de sus tareas, supervisión constante para su optimización y aprendizaje de nuevas tareas, e invarianza de las tareas que realizan. Esto ocasiona que sus capacidades para operar de forma autónoma en entornos de mundo abierto se encuentren limitadas y presenten retos relevantes [21]. Uno reto relevante, es desarrollar algoritmos inteligentes de detección de objetos de mundo abierto, que permite a los drones adaptarse a entornos dinámicos, aprender continuamente, reconocer y rechazar objetos de forma continua, lidiar con condiciones variables como la iluminación, poses, texturas, diferentes puntos de vista y

oclusiones. Así como, mejorar los sistemas de navegación y toma de decisiones. Sin embargo, la detección de objetos de mundo abierto sigue siendo un problema abierto de investigación que suma otros retos al ser implementado en drones, como recursos limitados, eficiencia, escalabilidad, auto etiquetado de muestras y aprendizaje de objetos a partir de un flujo continuo de datos [32]. Por lo tanto, integrar y abordar la detección de objetos en mundo abierto en los drones mejora la autonomía y las capacidades para realizar tareas en distintas áreas de aplicación bajo condiciones no siempre ideales.

El aprendizaje continuo aporta soluciones a los retos de los entornos dinámicos proporcionando a los modelos las capacidades para aprender de forma continuo a partir de un flujo de datos, actualizar su conocimiento sin reentrenamiento total del modelo y optimizar los recursos disponibles[3]. Sin embargo, modificar la información previamente aprendida por un modelo para agregar nueva información o para actualizar el conocimiento, puede ocasionar una pérdida drástica de información y desempeño previo. Esta situación se conoce como olvido catastrófico y se acentúa con mayor frecuencia en redes neuronales artificiales [41]. Entonces, el aprendizaje continuo proporciona medios para llevar el aprendizaje continuo de objetos en entornos de mundo abierto, pero no como una solución definitiva. Por ejemplo, el reconocer y rechazar nuevos objetos y muestras inconsistentes de forma continua durante el aprendizaje es un problema todavía no resuelto, pero necesario en los entornos de mundo abierto.

El meta reconocimiento desarrolla técnicas que permiten a los sistemas de aprendizaje profundo reconocer y entender la fiabilidad de sus predicciones. De esta manera, son capaces de evaluar la información aprendida, añadiéndola, actualizándola o incluso rechazándola cuando sea necesario [35]. Esta capacidad de adaptabilidad que ofrece el meta reconocimiento es de gran relevancia para los sistemas de aprendizaje y detección de objetos en entornos de mundo abierto, ya que su integración favorece la autonomía y robustez de los sistemas. Sin embargo,

el meta reconocimiento, aún falla en generar una representación solida para el reconocimiento, actualizar su conocimiento y opera bajo supuestos de conjunto cerrado, es decir, total conocimiento de la información a evaluar, supervisión para optimizar el modelo y grandes volúmenes de información para evaluar la fiabilidad de un sistema. Por lo que son retos que se enfrentan actualmente en el campo.

El aprendizaje de detección de objetos de mundo abierto integra la detección de objetos, el aprendizaje continuo y el meta reconocimiento para desarrollar sistemas inteligentes con capacidades de adaptabilidad en entornos de mundo abierto. Por lo que abordan los problemas del aprendizaje continuo de objetos a partir de un flujo de datos variable, el reconocimiento y categorización de nuevos objetos, y la autoevaluación de las muestras observadas [25]. Por lo tanto, abordar el aprendizaje de detección de objetos de mundo abierto, no solo mejora la precisión y la robustez de los modelos de detección de objetos, sino que también permite aplicar estas técnicas en sistemas autónomos y enfrentar de forma efectiva y eficiente situaciones altamente variables e impredecibles en escenarios del mundo abierto.

Actualmente, los avances en la detección de objetos de mundo abierto se han centrado en la segmentación de posibles objetos conocidos y desconocidos [20]; medidas de evaluación para el reconocimiento de objetos desconocidos [46]; auto etiquetado [47]; aproximaciones de distintas técnicas de clasificación [31]; y representación [15]. Sin embargo, problemas como el aprendizaje continuo de objetos, la adaptabilidad de los sistemas de meta reconocimiento para entornos de mundo abierto, el reconocimiento de nuevas muestras y nuevos objetos, así como, la integración con sistemas robótico y autónomos son abordados escasamente.

En esta propuesta, se pretende abordar el problema de la actualización del conocimiento o adaptabilidad de los modelos de meta reconocimiento para modelos de aprendizaje continuo de detección de objetos de mundo abierto y su integración con drones.

## 1.1 Justificación

Abordar el problema de actualización del conocimiento o adaptabilidad de los modelos de meta reconocimiento para modelos de aprendizaje continuo de detección de objetos de mundo abierto con drones, representa un aporte de gran relevancia. En la perspectiva de los drones, aproximaciones previas emplean modelos bajo supuestos de conjunto cerrado para abordar la autonomía en drones inteligentes. En este sentido, el desarrollo de algoritmos inteligentes de detección de objetos de mundo abierto para drones, marca un avance que extiende las capacidades de los drones para realizar tareas más complejas en una variedad de aplicaciones, dentro de las cuales el monitoreo remoto es una de las aplicaciones que más se beneficia. En la perspectiva de la inteligencia artificial, estrategias previas proponen algoritmos de aprendizaje incremental con modelos de meta reconocimiento bajo supuestos de conjunto cerrado. En este sentido, llevar a cabo el algoritmo de meta reconocimiento adaptativo para modelos de aprendizaje continuos de detección de objetos, representa un avance en la adaptabilidad de los algoritmos de detección de objetos de mundo abierto, que beneficia la fiabilidad y desempeño de los sistemas.

## 1.2 Planteamiento del problema

Un modelo de meta reconocimiento con un conjunto de parámetros  $w$  que describen una función de densidad de probabilidad (FDP) asociada a una distribución de valores escalares de un objeto  $O_i$ , en cualquier instante de tiempo  $t$ , deberá poder rechazar o aceptar un nuevo valor escalar, en función de un conjunto de umbrales de confianza  $g$ , y actualizar el conjunto de parámetros  $w$  y umbrales de confianza  $g$ . Así mismo, en función de los umbrales de confianza  $g$  un modelo de aprendizaje continuo, entrenado en un conjunto de datos  $D = \{X, Y\}$ , donde  $X$  representa la imagen de entrada y  $Y$  el conjunto de etiquetas y bounding boxes asociados a objetos  $O_k = \{1, 2, \dots, n\}$ , deberá poder actualizar alguno de sus objetos conocidos  $O_k$ , o

en su caso añadir un nuevo objeto  $O_u$ . En este trabajo, se propone un modelo de meta reconocimiento que, al integrar un nuevo escalar en la distribución, se actualicen sus parámetros  $w$  a partir de una media en línea y un conjunto de datos  $D_e$ , generado mediante la recolección de muestras con el Drone. De tal manera que, al actualizar los parámetros  $w$ , la distribución de probabilidades modelada por la FDP correspondiente, se ajuste paulatinamente a la tendencia de los nuevos escalares y en función de la magnitud del cambio en los parámetros  $w$ , los umbrales confianza  $g$  serán restrictivos o permisivos. En el caso del modelo de aprendizaje continuo, se propone un modelo basado en prototipos, formados a partir de la media y covarianza de un objeto de interés, y mediante la distancia de Mahalanobis proporcione al modelo de meta reconocimiento un valor escalar a evaluar con los umbrales de confianza. En caso, de ser aceptado, el modelo basado en prototipos actualizara o creara un nuevo prototipo a partir de una media y covarianza en línea. En caso contrario, será rechazado por el modelo.

### **1.3 Preguntas de investigación**

Se presentan preguntas de investigación que llevan a la formulación de la hipótesis:

- ¿Cómo se logra la actualización continua del conocimiento (adaptabilidad) en los sistemas de detección de objetos de mundo abierto?
- ¿Cómo desarrollar un sistema de detección de objetos de mundo abierto para su uso en tareas de monitoreo con drones?

### **1.4 Hipótesis**

Integrar un modelo de meta reconocimiento con capacidades para actualizar su conocimiento a partir de nuevas observaciones en un modelo de aprendizaje continuo

de detección de objetos; mejorara significativamente, el desempeño de un modelo de detección de objetos para el monitoreo en entornos de mundo abierto con drones.

## **1.5 Objetivo General**

Desarrollar un sistema de detección de objetos de aprendizaje continuo de mundo abierto para el monitoreo con drones empleando meta reconocimiento adaptativo.

## **1.6 Objetivos específicos**

- Implementar un modelo de detección de objetos para ser adaptado a entornos de mundo abierto.
- Desarrollar el modelo de aprendizaje continuo para entornos de mundo abierto.
- Desarrollar el modelo adaptativo de meta reconocimiento para el aprendizaje continuo de detección de objetos en entornos de mundo abierto.
- Integrar el sistema de detección de objetos de aprendizaje continuo con meta reconocimiento adaptativo para el monitoreo con drones en entornos de mundo abierto.
- Evaluar el sistema de detección de objetos de aprendizaje continuo con meta reconocimiento adaptativo en el monitoreo con drones de mundo abierto.

## **1.7 Contribuciones esperadas**

Este trabajo busca generar las siguiente contribuciones:

- Una modelo de meta reconocimiento adaptativo para el aprendizaje de detección de objetos de mundo abierto.

- Un modelo de aprendizaje continuo para la detección de objetos de mundo abierto.
- Un sistema de aprendizaje continuo de detección de objetos en entornos de mundo abierto para el monitoreo con drones.

Estas contribuciones, impactarán en el conocimiento actual del área, aportando nuevo conocimiento y un punto de referencia para trabajos futuros. Otorgará otra perspectiva para abordar la detección de objetos de mundo abierto. Así como, favorecer el desarrollo de las áreas de aplicación como la robótica, los vehículos y el monitoreo autónomos.

## **2 Marco teórico**

En este capítulo se pretenden abordar los conceptos relacionados a esta tesis. Entonces, se estarán abordando conceptos como aprendizaje computacional, aprendizaje incremental-continuo, agrupamiento, reconocimiento de conjunto abierto, meta reconocimiento, redes convolucionales y drones.

### **2.1 Aprendizaje computacional (Machine learning)**

El aprendizaje computacional desarrolla algoritmos computacionales con la capacidad para aprender de la experiencia de manera automática, permitiendo a una computadora resolver problemas complejos que requieren de inteligencia [37].

Este campo comprende tres enfoques principales por los cuales una computadora es capaz de aprender de la experiencia: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo. No obstante, para fines de este trabajo, solo se describirán los dos primeros.

### 2.1.1 Aprendizaje supervisado

Son algoritmos que aprenden a modelar una función capaz de mapear un espacio de características de entrada a un espacio predefinido de etiquetas o clases de salida [28, 27]. Esta función modelada, se conoce como clasificador, y es capaz de generaliza nuevas instancias no observadas pero conocidas de características de entrada y las relaciona a un espacio conocido de etiquetas o clases de salida [6].

$$h(x) : X \rightarrow Y \quad (1)$$

Then  $h(x)$  is a model that  $h(x) \in B$  and  $B \subset H$  is the hipotetic space of the model. The model  $h(x)$  maps a feature vector  $x \in X \subseteq \mathbb{R}^d$  to a target  $y \in Y \subseteq \mathbb{R}$  in a learning process that use a set of training data  $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$ .

### 2.1.2 Aprendizaje no supervisado

Son algoritmos que aprenden a modelar estructuras probabilísticas para relacionar entre sí muestras de patrones y atributos de entrada semejantes, en representaciones conjuntas de salida [11, 17]. Las estructuras probabilísticas asumen una distribución probabilística subyacente desconocida e independiente respecto a otras estructuras que puede ser estimada y diferenciada a partir de las muestras de entrada [7].

$$P(x; G) = \sum_y P(y; G) * P(x|y; G) \quad (2)$$

Then  $P(x; G)$  is a model that  $P(x; G) \in B$  and  $B \subset H$  is the hipotetic space of the model. The model  $P(x; G)$  with a feature vector  $x \in X \subseteq \mathbb{R}^d$  and parameters  $G \subseteq \mathbb{R}^d$  of a probability distribution  $P(X)$  finds the most probably target, given the sum of probabilities of  $y \in Y \subseteq \mathbb{R}^{[0,1]}$  and parameters  $G$  with the conditional probability  $P(x|y; G)$ .

## 2.2 Redes Neuronales Convolucionales

Es una red neuronal artificial con capacidades para trabajar con muestras multidimensionales mediante operaciones de convolución, procesamiento y análisis. Son utilizadas en tareas de visión por computadora debido a su capacidad para capturar características espaciales y patrones en los datos de manera eficiente. Principalmente se conforman de dos etapas, una fase de convolución y reducción de dimensiones, y una fase de procesamiento y clasificación [12]. Así mismo, las redes neuronales convolucionales se componen de tres capas esenciales:

- Capa de convolución: Está capa se encarga de extraer características locales mediante operaciones de convolución con kernels. La convolución consiste en operaciones matemáticas que transforman dos funciones en una tercera. El kernel, es una matriz de coeficientes que actúan como filtro para extraer un tipo específico de características sobre las muestras de entrada y da como resultado una matriz de características relevantes nombrado mapa de características.
- Capa de agrupación: Está capa preprocesa y reducen la dimensionalidad de los mapas de características, conservando la información más importante.
- Capas completamente conectadas: Son capas que procesan la información para llevar a cabo la clasificación de los objetos.

## 2.3 Detección de objetos

La detección de objetos es un área de la visión por computadora y aprendizaje computacional que desarrolla algoritmos capaces reconocer, localizar y clasificar objetos presentes en una imagen o video [51]. Principalmente se afrontan problemas de escala, oclusión, ruido y eficiencia.

- Escala: Los objetos de una misma clase cambian su tamaño de acuerdo con

la cercanía con la que se encuentren respecto al sensor de visión. Estas variaciones representan una confusión para los algoritmos de visión, ya que son erróneamente reconocidos como objetos de una clase diferente.

- **Oclusión:** Los sensores de visión capturan una perspectiva bidimensional de los objetos presentes en un entorno tridimensional. Esta abstracción ocasiona que los objetos presentes en las imágenes se solapen unos con otros, ocasionando pérdidas de información del entorno observable.
- **Ruido:** Los sensores de visión se encuentran en constante interacción con los entornos de la realidad, los cuales presentan condiciones altamente variables de iluminación, deformación, perspectiva y orientación, ocasionando que los algoritmos de visión no puedan reconocer muestras de una clase de objetos conocidos.
- **Eficiencia:** Los algoritmos de visión pueden suponer una carga computacional fuerte para los sistemas conforme el número de objetos que se desea detectar aumenta en una imagen o video, por ello, llevar a cabo optimizaciones sobre estos algoritmos resulta de un gran interés para el área.

## **2.4 Aprendizaje continuo**

El aprendizaje continuo es otro término para incremental y lifelong learning, su fragmentación se puede atribuir a usos y expresiones del lenguaje. A diferencia de otros enfoques, se busca que los modelos puedan realizar tareas de aprendizaje a partir de un flujo de datos continuo en el tiempo. Para fines de este trabajo, el aprendizaje incremental-continuo se define como: un sistema que desempeña una secuencia de  $N$  tareas de aprendizaje constante ( $T_1, T_2, T_3, \dots, T_n$ ) que son distintas unas de otras en términos de cambios en las distribuciones de datos subyacentes. En cualquier momento, el sistema debe ser capaz de identificar instancias no conocidas

de datos de forma robusta, rechazar otras o postergarlas como posibles instancias de aprendizaje de futuras tareas. [26].

### **2.4.1 Olvido catastrófico**

Es la pérdida drástica y en ocasiones definitiva del desempeño de un modelo para llevar a cabo tareas previamente aprendidas cuando se está aprendiendo de forma continua nuevas tareas, como consecuencia de un desbalance en la estabilidad-plasticidad del modelo. Es el problema central al que se enfrenta el aprendizaje continuo y la causa de que los modelos con el tiempo se vuelven obsoletos.

## **2.5 Enfoques del aprendizaje continuo**

Se pueden agrupar cinco enfoques principales para abordar el problema del olvido catastrófico: Enfoque basado en repetición, Enfoque basado en representaciones, Enfoque basado en arquitecturas y Enfoque basado en optimización [41]. No obstante, para fines de este trabajo se detallará el enfoque utilizado, el cual aborda un enfoque principal y colateralmente uno o varios de los enfoques presentes

### **2.5.1 Enfoque basado en representaciones**

#### **Continual pre-training o meta-training**

Emplea el uso de modelos preentrenados con una gran cantidad de datos para reaprovechar las representaciones generadas. A partir de estas representaciones, se establecen condiciones y restricciones de aprendizaje, lo que permiten extender sus capacidades de adaptabilidad a nuevas muestras y tareas. Entonces, se genera un pseudo modelo sobre el modelo preentrenado que rige el aprendizaje de nuevas tareas, actualización de tareas previas y validación de muestras [41].

## 2.5.2 Enfoque basado en optimización

### Meta learning

A diferencia de enfoques que buscan el reentrenamiento, la fragmentación de los modelos neuronales para abordar múltiples tareas y la transferencia de información de la forma maestro-estudiante. El meta aprendizaje, entrena un modelo con capacidades de adaptación, establece restricciones y condiciones de aprendizaje, de tal manera que pueda responder rápidamente al aprendizaje de nuevas tareas y condiciones de aprendizaje con poca información [41].

## 2.5.3 Enfoque basado en repetición

Emplean memorias estáticas y dinámicas para almacenar ejemplos representativos de las tareas que realizaron, en el momento en que se aprende una nueva tarea, se emplea estos buffers para reentrenar el modelo ligeramente sobre las tareas pasadas, de tal forma que, en modelos como las redes neuronales artificiales, los parámetros internos se modifiquen contemplando ambas tareas. En modelos basados en instancias, los prototipos funcionan como espacios de memorias en donde se conservan únicamente los ejemplos más representativos y garantizan un desempeño establecido sobre las tareas previas. Existen tres tipos de aproximaciones, experience replay, generative replay y feature replay:

### Experience replay

Aproximan una solución al problema del olvido catastrófico reservando un espacio físico de memoria para un conjunto de ejemplos de tareas previamente aprendidas. Cuando se aprende una nueva tarea, se mezclan ejemplos de tareas previas durante el entrenamiento de la nueva tarea. Esta mezcla puede ser por selección aleatoria de ejemplos o por el ejemplo que mejor represente a la clase. Y el número de ejemplos que se almacenan de tareas previas, se escoge de acuerdo con las limitaciones de almacenamiento o de forma arbitraria. Recientemente, con los problemas de

privacidad que puede conllevar el almacenar información que puede llegar a ser sensible, este método ha cambiado sus aproximaciones para ser libres de ejemplos. Y para ello knowledge distillation y prototipos basados en la media de los ejemplos se han posicionado como aproximaciones eficientes [19, 49].

### **Generative replay**

El uso de ejemplos representativos para aprender tareas de forma continua y evitar el olvido catastrófico, ocasiona graves problemas de almacenamiento, que a largo plazo los vuelve inviables. Aproximaciones como el pseudo rehearsal, reducen el uso de la memoria y permiten conservar ejemplos representativos de las tareas pasadas emplean modelos generativos que permitan producir o generar ejemplos de tareas previamente aprendidas cuando se está aprendiendo una nueva tarea [38].

### **Feature replay**

Prioriza el aprendizaje de nuevas tareas estableciendo restricciones sobre el modelo de aprendizaje. En este sentido, congela o evita la modificación de parámetros en una red neuronal, que se consideran relevantes para desempeñar tareas previas. En aproximaciones recientes, un extractor de características se emplea como generador de nuevas características sobre las cuales aprender las nuevas tareas, conservando espacios independientes para cada tarea. Por lo tanto, el entrenamiento de la nueva tarea se realiza considerando estos segmentos restringidos, permitiendo desempeñar la tarea nueva y las previas [45].

## **2.6 Reconocimiento de conjunto cerrado**

Es el reconocimiento que supone que, tanto en el entrenamiento como el testeo, existe un número de tareas finitas, conocidas e invariantes. Por lo tanto, cualquier muestra que es reconocida, ya se ha observada previamente y es válida de ser asociada a una de sus tareas. El desarrollo de modelos bajo este concepto se ha desarrollado ampliamente bajo el enfoque del aprendizaje supervisado, el cual considera tareas

puntuales y previamente conocidas para para maximizar las capacidades de generalización y desempeñarse favorablemente en entornos controlados. Sin embargo, son pocos los casos en los que un entorno puede considerarse de conjunto cerrado; entonces, eventualmente empieza un proceso de degradación del desempeño en el que los modelos se vuelven obsoletos para desempeñar las tareas deseadas [36]. Existen varios motivos para entender los problemas del conjunto cerrado:

- Existe un desbalance natural de clases que fungen como ejemplos negativos que no se conocen.
- El riesgo empírico medido sobre los datos de entrenamiento es lo que normalmente se define y optimiza.
- El supuesto de un entorno estático o invariante de la realidad.
- Abstraer una representación incompleta de la realidad en un conjunto finito de datos para explicar el todo.

## **2.7 Reconocimiento de conjunto abierto**

Es el reconocimiento que supone un conocimiento limitado e insuficiente durante el aprendizaje de las tareas, ya que durante el tiempo de testeo existen una infinita cantidad de tareas desconocidas y muestras relacionadas no observadas. Por lo tanto, se debe ser capaz de actualizar el conocimiento previo de las tareas y lidiar con la incertidumbre de aquello desconocido. Los motivos que permiten entender al reconocimiento de conjunto abierto son:

- Existe un mayor número de tareas desconocidas, combinaciones y configuraciones vistas de las que se pueden encontrar en un conjunto finito de tareas conocidas [36].

- La incapacidad para lidiar con la incertidumbre presente en las tareas desconocidas ocasiona una sobre generalización de los datos de entrenamiento y la incapacidad de desempeñarse fuera de los datos conocidos y entrenados [18].

## **2.8 Reconocimiento de mundo abierto**

Es aquel reconocimiento con la capacidad para manejar la incertidumbre de aquello desconocido, detectar y aprender nuevas tareas a partir de un flujo de datos no estacionario, y gestiona y actualiza tareas previamente conocidas. Entonces, plantean sistemas de reconocimiento capaces de desenvolverse en un entorno real del mundo, en donde no solo deba contemplar el reconocimiento de conjunto abierto, sino extender sus capacidades para etiquetar el descubrimiento de nuevas clases, incrementar el total de clases conocidas y actualizarse en un mínimo de tiempo [3]. Los motivos que permiten entender al reconocimiento de conjunto abierto son:

- Los conjuntos de datos son dinámicos y no estacionarios.
- Continuamente se reconocen y añaden nuevas tareas, incluyendo la capacidad de actualizar tareas previamente aprendidas durante la etapa de aplicación.
- Se predicen tareas conocidas en un flujo de datos con una infinidad de tareas desconocidas.
- Se reconoce lo que no se ha observado o aprendido antes.
- Se tiene la capacidad para gestionar las tareas conocidas y desconocidas a través del tiempo.

### **2.8.1 Meta reconocimiento**

El meta reconocimiento se conforma por técnicas que se inspiran en la metacognición para regular la información que debe ser evaluada en un modelo de reconocimiento;

controlando y ajustando el desempeño, la información observada y el aprendizaje. Así mismo, reconocer lo desconocido y aquello que se cree que se conoce, es equivalente a identificar toda muestra que presente un comportamiento anómalo, atípico o inconsistente con la tendencia del conjunto de muestras que forman a una determinada distribución en el modelo de aprendizaje. Estos comportamientos inconsistentes, se ven reflejados como problemas de sobre confianza y baja confianza en la última capa de una red neuronal artificial. Los cuales ocurren con gran frecuencia en entornos de mundo abierto.

## **2.9 Detección de objetos de mundo abierto**

Es la capacidad de un sistema de detección de objetos para manejar la incertidumbre de aquello desconocido, detectar y aprender nuevos objetos a partir de un flujo de datos no estacionario, y gestiona y actualiza objetos previamente conocidas. Los motivos que permiten entender la detección de objetos de mundo abierto son:

- Continuamente se está reconociendo y añadiendo nuevos objetos a través del tiempo a partir de un flujo de datos no estacionario.
- Predice objetos conocidos a través de una infinidad de objetos desconocidos.
- Etiqueta nuevos objetos y actualizar los objetos aprendidos anteriormente.
- Muestras de objetos y objetos que no se han visto en la etapa de aprendizaje aparecen durante la etapa de aplicación.
- Tiempos de aprendizaje cortos y sin necesidad de reentrenamiento.

Entonces, [20] formaliza el nuevo problema de visión por computadora de detección de objetos, reconociendo tres retos que los modelos de detección de objetos deben afrontar para desempeñarse bajo un entorno de mundo abierto:

- Primero, para que los modelos se comporten de forma realista en un entorno dinámico como lo es el mundo abierto, se debe asumir que existe un conjunto de clases desconocidas que pueden encontrarse durante la inferencia.
- Segundo, el modelo entrenado previamente, es capaz de detectar instancias de clases conocidas e instancias de clases nuevas que se clasifican como desconocidas con una etiqueta designada (por ejemplo, la etiqueta cero).
- Tercero, llevar un incremento en el aprendizaje de las clases de objetos de modo que no se tenga que entrenar desde cero el modelo, utilizando del conjunto de la clase desconocida, un subconjunto de clases etiquetadas y reconocidas como de interés.

Así mismo, las métricas para evaluar el desempeño de los modelos fueron establecidas inconscientemente para enfoques de conjunto cerrado. Por lo tanto, [9] propone Wilderness Impact, una métrica de evaluación para evaluar el desempeño de los modelos desde la perspectiva de las clases conocidas de objetos en mundo abierto. Por otro lado, [46] propone integrar Unknown Detection Precision y Unknown Detection Recall dos métricas que evalúan el desempeño cuando el modelo debe evaluar clases desconocidas.

## **2.10 Métricas de evaluación**

### **2.10.1 Métricas para la detección de objetos en mundo abierto**

#### **F1-Score**

Es una métrica de evaluación que apoyada en la estimación de la precisión y recall, proporciona una medida equilibrada del desempeño del modelo entrenado. Es especialmente útil en conjuntos de datos desequilibrados, donde la cantidad de muestras positivas es mucho menor que la cantidad de muestras negativas. Un F1-score alto

indica que el modelo detecta muestras eficazmente mientras reduce la omisión y detección de muestras erróneas.

$$F1 - score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (3)$$

### **Precisión (Precision)**

La precisión mide la proporción de verdaderos positivos respecto al total de positivos predichos.

$$Precision = \frac{VP}{VP + FP} \quad (4)$$

Verdaderos Positivos (VP): es el número de muestras correctamente detectados.

Falsos Positivos (FP): es el número de muestras incorrectamente detectados.

### **Sensibilidad (Recall)**

El recall mide la proporción de verdaderos positivos respecto al total de positivos reales.

$$Recall = \frac{VP}{VP + FN} \quad (5)$$

Verdaderos Positivos (VP): es el número de muestras correctamente detectados.

Falsos Negativos (FN): es el número de muestras incorrectamente detectados.

### **Mean Average Precision (mAP)**

Es una métrica que proporciona la precisión del modelo a lo largo de distintos niveles de confianza. Para ello, se calcula la precisión y recall para varios umbrales de confianza para cada una de las clases comprendidas. Luego, esta precisión promedio de cada una de las clases comprendidas es sumada.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

N: es el número de clases aprendidas.

$AP_i$ : es la precisión promedio para cada clase  $i$  aprendida por el modelo.

### **Average Incremental Accuracy (AIA)**

Esta métrica evalúa cómo mejora o decae el rendimiento del modelo entrenado a

medida que se incorporan nuevas muestras a lo largo del tiempo. Es útil cuando se trabaja en condiciones donde se agregan nuevas muestras a clases o etiquetas continuamente.

$$AIA = \frac{1}{T} \sum_{t=1}^T a_t \quad (7)$$

T: es el número de tareas aprendidas.

$A_t$ : es la precisión por tarea.

### **Wilderness Impact (WI)**

Es la proporción de instancias desconocidas que el modelo clasifica incorrectamente como instancias conocidas. En este sentido, busca medir la capacidad del modelo para manejar la incertidumbre y variabilidad en las muestras que se observan en entornos de mundo abierto.

$$WI = \frac{FP_0}{TP_C + FP_C} \quad (8)$$

$FP_0$ : total de muestras desconocidas clasificadas como conocidas.

$TP_C$ : total de verdaderos positivos.

$FP_C$ : total de falsos positivos.

### **Unknown Detection Recall (UDR)**

Esta métrica mide el ratio de precisión para detectar clases desconocidas.

$$UDR = \frac{TP_u + FN_u^*}{TP_u + FN_u} \quad (9)$$

$TP_u$ : total de verdaderos positivos en detecciones de clase desconocidas.

$FN_u^*$ : total de muestras clasificadas erróneamente en detecciones de clase desconocidas.

$FN_u$ : total de falsos positivos en detecciones de clase desconocidas.

### **Unknown Detection Precision (UDP)**

Esta métrica mide el ratio de precisión para detectar cualquier muestra desconocida.

$$UDP = \frac{TP_u}{TP_u + FN_u^*} \quad (10)$$

$TP_u$ : total de verdaderos positivos en detecciones de clase desconocidas.

$FN_u^*$ : total de muestras clasificadas erróneamente en detecciones de clase desconocidas.

$FN_u$ : total de falsos positivos en detecciones de clase desconocidas.

### 2.10.2 Métrica de distancia

Se encarga de medir la similitud o disimilitud entre dos puntos en un espacio de características. Se emplea en la detección de conjunto abierto para determinar qué tan similares son las características de una muestra desconocida a las características de las clases conocidas. Para ello, se establece una distancia mínima como umbral de decisión para añadir o rechazar dicha muestra en una clase conocida. Las distancias empleadas son: **Distancia Euclidiana**

Es la distancia más corta entre dos puntos en un espacio euclidiano.

$$d_{\text{Euclidiana}}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (11)$$

### Distancia de Mahalanobis

Es la distancia más corta entre dos variables aleatorias en un espacio multidimensional.

$$d_{\text{Mahalanobis}}(x, y) = \sqrt{(x - y)^T S^{-1} (x - y)} \quad (12)$$

donde  $S$  es la matriz de covarianza.

### 2.10.3 Modelos estadísticos paramétricos

#### Distribución de Weibull

Empleado para modelar distribuciones de probabilidad continua, es un modelo paramétrico utilizado para analizar la confiabilidad entre la distribución de características de una

clase conocida y la distribución de características de muestras desconocidas. La distribución Weibull tiene dos parámetros:

- Parámetro de forma ( $\beta$ ): Determina la forma de la distribución. Si  $\beta < 1$ , la tasa de error decrece con el tiempo. Si  $\beta = 1$ , la tasa de error es constante. Si  $\beta > 1$ , la tasa de error aumenta con el tiempo.
- Parámetro de escala ( $\eta$ ): Establece la escala de la distribución.

La función de densidad de probabilidad (PDF) de la distribución Weibull se define como:

$$f(t; \beta, \eta) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^\beta} \quad (13)$$

### Modelo basado en energía

Es un modelo probabilístico que estima un valor de energía escalar a cada distribución de características de entrada. Mediante un proceso de optimización, las distribuciones de características más probables a clases conocidas tendrán una energía más baja. Esta consecuencia, permite la detección de anomalías y clases desconocidas. Se compone principalmente por una función de energía y una de probabilidad. **Función de energía**

Define el valor de energía para cada distribución de entrada de las variables.

$$E(f) = -T \log \sum_l \exp\left(\frac{-E(f, l')}{T}\right) \quad (14)$$

$E(f, l')$ : es la energía de una muestra  $f$  y su etiqueta  $l'$ .

$\sum_l$ : indica la suma sobre todas las posibles clases  $l$ .

$T$ : es la temperatura.

### Función de probabilidad

Estima las probabilidades equivalentes a la energía asignada por la distribución de Gibbs:

$$E(f; g) = -T \log \sum_{i=1}^C \exp\left(\frac{g_i(f)}{T}\right) \quad (15)$$

$E(f; g)$ : es la energía calculada para una muestra  $f$  dada la función de la red neuronal artificial  $g$ .

$T$ : es la temperatura.

$\sum_{i=1}^C$ : indica la suma sobre todas las posibles clases  $i$ .

$g_i(f)$ : Es el vector de características (o logit) resultante de la salida de una red neuronal artificial.

## **2.11 Drones o *Unmanned Aerial Vehicle* (UAV)**

Los drones, también conocidos como UAVs (Unmanned Aerial Vehicles) o RPAs (Remotely Piloted Aircraft), son aeronaves pilotadas remotamente capaces de realizar vuelos autónomos y a control remoto. Son económicos, flexibles y versátiles, y pueden equiparse con sensores térmicos, infrarrojos y de visión, así como con hardware capaz de realizar procesamiento de datos por detección remota y en tiempo real [1].

## **3 Estado del Arte**

La presente revisión de la literatura analiza los trabajos más importantes para esta investigación. En principio, se desarrolla el contexto de aplicación en drones y su importancia. Luego, su relación con la problemática de interés. Y finalmente, un análisis de las técnicas de meta reconocimiento que abordan el problema de interés.

### **3.1 Drones o *Unmanned Aerial Vehicle* (UAV)**

La inteligencia artificial (IA) amplía las capacidades de los drones, automatizando procesos, optimizando recursos, mejorando la precisión de las tareas e integrando

algoritmos avanzados de procesamiento de imágenes y aprendizaje automático para desempeñar tareas como la detección de objetos y aprendizaje por computadora en drones. Capacidades que favorecen el desempeño en tareas de seguimiento, inspección, vigilancia y monitoreo. El monitoreo remoto, es un campo emergente, requiere soluciones innovadoras y autónomas para la gestión de desastres naturales, la conservación de áreas naturales, el tráfico, reconocimiento y protección de especies.

[33] comparo tres modelos de detección de objetos para detectar y contar ciervos en entornos de bosques densos, los modelos empleados fueron la versión Yolov4 y Yolov4-tiny, y un modelo SSD. Su experimento considero evaluarlos bajo *mean average precision (mAP)*, *precision*, *recall* y *F1 score*. Como resultados relevantes, todos los modelos detectaron ciervos con un 70.45% de precisión, un puntaje de confianza del 99% y un desempeño aceptable en detección en tiempo real. De manera similar, [2] emplean una red neuronal convolucional Track R-CNN para abordar el problema del monitoreo de mamíferos herbívoros, la cual fue evaluada en segmentación, detección y seguimiento. Se llevo a cabo varios entrenamientos sobre este modelo del cual proporciona el desempeño de su mejor modelo con 68.5% sMOTSA, 79.6% MOTSA, 41% IDS, 100% en la precisión de conteo, and 87.2% MOTSP. Demostró otra opción para llevar a cabo el monitoreo de mamíferos herbívoros. Por otro lado, [43] emplean un algoritmo YOLOv8 para llevar a cabo la detección de objetos de pequeña escala. Para ello, lleva a cabo modificaciones en la arquitectura que añaden una capa de detección de objetos pequeños P2, eliminó la capa de detección de grandes objetivos P5, mejora el módulo N-SPPCSPC, DWRC2f y SEAM, así como implemento una función de pérdida NWD para abordar las problemáticas de escala. Como resultados relevantes, aumento el desempeño del modelo en un 7.1% y un 4.9% en mAP50. A demás de aumentar el desempeño del 4.0% y 1.3% en mAP50-95.

[34] emplean el uso de múltiples drones coordinados en tiempo real para recopilar datos con alta calidad y desde múltiples perspectivas para monitorear manadas

de animales gregarios. Mediante el concepto de superficie de interés maximiza la calidad de los datos recolectados. El método de evaluación que empleo, es una reconstrucción del animal mediante simulación 3D. Aunque efectivo en la recolección de datos, existen supuestos que limitan el alcance de esta propuesta. En este sentido, los animales son estáticos, se conoce en todo momento la posición de la superficie de interés y las frecuencias no son lo suficientemente altas para desempeñarse en tiempo real aceptablemente. De forma similar, [39] emplean múltiples drones en dos enfoques, la localización visual simultánea y Cartografía (V-SLAM) y la Estructura a partir del movimiento (SfM). A partir de la colaboración de drones es posible reconstruir escenas de alta calidad en tiempo real. Como resultados demuestra que el uso colaborativo de drones optimízalos tiempos de mapeo, aumenta el área de cobertura de monitoreo y permite construir modelo 3D que favorecen el uso de trayectorias. Sin embargo, la calidad de los puntos de características que emplea de forma local para usar uno u otro método impactan drásticamente en la reconstrucción y mapeo.

Entonces, las áreas de oportunidad actuales en el campo del monitoreo remoto y en general para los drones incluyen:

- Extender las capacidades de los drones para equipar diferentes sensores de manera efectiva y proporcionar un monitoreo continuo.
- Mejorar la precisión en el seguimiento, inspección, vigilancia y muestreo para una óptima recopilación y envío de datos en tiempo real a los centros de procesamiento.
- Desarrollar algoritmos inteligentes robustos ante la ausencia de sensores y en entornos dinámicos con drones.
- Los modelos de aprendizaje profundo presentan los problemas de conjunto cerrado
- Mejorar la coordinación de múltiples drones y sensores para favorecer nuevos

tipos de adquisición de datos.

En este trabajo, se aborda el desarrollo de algoritmos inteligentes robustos para el monitoreo remoto. En especial, los algoritmos de aprendizaje de detección de objetos para entornos dinámicos. De forma colateral, se aborda la precisión de los algoritmos inteligentes, monitoreo automatizado, y adquisición y procesamiento de datos.

## **3.2 Aprendizaje de mundo abierto de detección de objetos**

El aprendizaje de mundo abierto de detección de objetos plantea esencialmente un sistema bajo un enfoque de aprendizaje continuo con las capacidades para rechazar, reconocer y aprender nuevas muestras y clases de objetos a partir de un flujo constante de datos. Existen dos metodologías principales que abordan este planteamiento: aprendizaje de mundo abierto de detección de objetos con meta reconocimiento y aprendizaje de mundo abierto de detección de objetos con detección de datos fuera de la distribución.

### **3.2.1 Aprendizaje de mundo abierto de detección de objetos con un enfoque de detección de datos fuera de la distribución**

Los enfoques que abordan el problema del aprendizaje de mundo abierto de detección de objetos desde esta perspectiva extienden su conocimiento mediante un enfoque de aprendizaje incremental de ajuste fino y actualizan su conocimiento a partir de un rechazo selectivo de nuevas muestras y clases.

[23] proponen un método basado en la clasificación generativa, suponiendo distribuciones gaussianas condicionales sobre las clases y puntuaciones de confianza en diferentes niveles de red neuronal convolucionales, a partir de la distancia de Mahalanobis para detectar muestras fuera de la distribución a la par que mejora

la separabilidad de las muestras añadiendo ruido controlado sobre las muestras de entrenamiento. Dadas sus características, este método permite incorporar nuevas clases al modelo sin la necesidad de un retrenamiento.

Para estimar los parámetros del clasificador generativo calculan la media empírica de la clase y la covarianza de las muestras de entrenamiento  $\{(x_1, y_1), \dots, (x_N, y_N)\}$ :

$$\hat{\mu}_c = \frac{1}{N_c} \sum_{i:y_i=c} f(x_i), \quad \hat{\Sigma} = \frac{1}{N} \sum_c \sum_{i:y_i=c} (f(x_i) - \hat{\mu}_c)(f(x_i) - \hat{\mu}_c)^\top \quad (16)$$

En este sentido,  $N_c$  es el número de muestras de entrenamiento con la etiqueta  $c$ . Esto es equivalente a ajustar las distribuciones gaussianas condicionales a la clase con una covarianza combinada a las muestras de entrenamiento bajo el estimador de máxima verosimilitud.

La estimación de la puntuación de confianza basado en la distancia de Mahalanobis es expresada como:

$$M(\mathbf{x}) = \max_c - (f(\mathbf{x}) - \hat{\mu}_c)^\top \hat{\Sigma}^{-1} (f(\mathbf{x}) - \hat{\mu}_c) \quad (17)$$

En este sentido,  $M(\mathbf{x})$  es el puntaje de confianza para la muestra de prueba  $\mathbf{x}$ .  $f(\mathbf{x})$  es la función de características aplicada a la muestra  $\mathbf{x}$ .  $\hat{\mu}_c$  es la media estimada para la clase  $c$ .  $\hat{\Sigma}$  es la matriz de covarianza estimada compartida entre todas las clases.  $\max_c$  indica que se toma el valor máximo de distancia entre todas las clases  $c$ .

Por otro lado, en [50] se propone un método basado en Transformers con estimación de objetividad. En este sentido, utiliza un modelo deformable DETR con una cabeza de objetividad probabilística para estimar que regiones de interés son objetos y cuáles de estos objetos son conocidos y desconocidos. La objetividad es estimada suponiendo una distribución condicional gaussiana e implementando la distancia de Mahalanobis. Luego, mediante un módulo de memoria, almacena las muestras más representativas para cada objeto con el cual se entrena para estimar la nueva distribución de probabilidad de objetividad y maximizar la probabilidad de los

objetos conocidos. Entonces, para la detección de muestras de objetos desconocidas propone:

Separar las predicciones del objeto ( $o$ ) y de la clase del objeto ( $l|o$ ):

$$p(l|q) = p(l|o, q) \cdot p(o|q). \quad (18)$$

En el cual,  $l$  representa las clases,  $O$  la objetividad y  $q$  es el vector de características.

Entonces, se puede aprender por separado la existencia del objeto en sí  $p(o|q)$ , y la probabilidad de la clase del objeto  $p(l|o, q)$ . De tal manera que, la cabeza de clasificación  $p(l|o, q)$  opera bajo la suposición de que sabe si una muestra es un objeto o no, aprendiendo entonces la distribución de  $p(l|o, q)$ . Por otro lado, la cabeza de objetividad aprende a estimar la probabilidad de objetividad  $p(o|q)$  empleando Mahalanobis:

Por otro lado, la cabeza de objetividad  $f_{obj}^t(q)$  aprende a estimar la probabilidad de objetividad  $p(o|q)$  empleando mahalanobis:

$$f_{obj}^t(\mathbf{q}) = \exp(-(\mathbf{q} - \mu)^T \Sigma^{-1}(\mathbf{q} - \mu)) = \exp(-d_M(\mathbf{q})^2) \quad (19)$$

En este sentido,  $q$  representa al vector de características de una nueva muestra,  $\mu$  la media de los vectores de características asociados a una clase y  $\Sigma^{-1}$  representa la matriz de covarianza inversa.

Logrando entonces, identificar objetos desconocidos fuera del entrenamiento del modelo.

Así mismo, [31] propone un método basado en Faster R-CNN mediante cabezas de regresión y clasificación las cuales propone y separa regiones de interés con posibles objetos, estima la objetividad probabilística para cada región de interés y clasifica objetos conocidos y desconocidos del fondo. Luego, emplea un modelo de mezclas de gaussianas para estimar a que clase pertenecen los objetos conocidos y cuales a los desconocidos. Finalmente, se emplea un reentrenamiento sobre las nuevas

clases y posteriormente un fine-tuning con datos balanceados de las clases previas. Entonces, para aprender a localizar y proponer regiones que contengan posibles objetos se propone lo siguiente:

Dos cabeza de regresión  $R_{ctr}$  y  $R_{box}$ , la primera encargada de predecir el centro de una posible región de interés. Y la segunda, encargada de predecir las dimensiones de la *bounding box* respecto al centro de la posible región de interés propuesta. Evaluando su precision a partir de la fórmula siguiente:

$$centerness = \sqrt{\frac{\min(l, r)}{\max(l, r)} \times \frac{\min(t, b)}{\max(t, b)}} \quad (20)$$

Respectivamente,  $l:left$  (izquierda),  $t:top$  (arriba),  $b:bottom$  (abajo),  $r:right$  (derecha).

Para la detección de muestras desconocidas, se propone una clasificación de objetividad mediante una cabeza de regresión  $F_{agnbox}$  de *bounding box* para clases agnósticas que comprenden valores entre cero y uno, y otra cabeza de regresión que mide la intersección sobre la union  $F_{iou}$ . La objetividad se estima de la siguiente forma:

$$Objectiveness = \sqrt{\sigma(R_{ctr}) \times \sigma(F_{iou})} \quad (21)$$

Finalmente, un modelo de mezcla de gaussianas es creado a partir de los puntajes producidos por la cabeza de clasificación  $F_{cls}$  para cada clase conocida. La verosimilitud más baja producida por los modelos de mezcla de gaussianas de cada clase es utilizado como umbral de pertenencia o rechazo, y en conjunto con las otras cabezas, se estima el consenso final para clasificar como clase conocida, desconocida o fondo (ruido).

### 3.2.2 Aprendizaje de mundo abierto de detección de objetos bajo un enfoque de meta reconocimiento

Son enfoques que suponen la teoría de los valores extremos (EVT), extienden su conocimiento desde un aprendizaje incremental de reentrenamiento y se prioriza el conservar el conocimiento actual, rechazando la actualización del conocimiento durante el funcionamiento de los modelos. No obstante, ocurre una etapa de selección de nuevas muestras y clases para su posterior integración.

[20] definen el problema de la detección de objetos de mundo abierto y propone un método compuesto por tres componentes esenciales. Primero, una red de regiones de propuesta modificada para reconocer objetos desconocidos. Segundo, un enfoque de aprendizaje contrastivo y prototipos para aumentar la separabilidad de las clases en el espacio latente y permitir el incremento de objetos sin pérdidas drásticas en el desempeño de objetos aprendidos previamente. Y tercero, un modelo de meta reconocimiento basado en energía para diferencia entre muestras conocidas y desconocidas. Entonces, el problema que formaliza y su propuesta es el siguiente:

1. Dado un modelo de detección de objetos  $M_c$  entrenado en un conjunto  $D^t = \{X^t, Y^t\}$  donde  $X^t$  representa la imagen de entrada y  $Y^t$  el conjunto de etiquetas y **bounding boxes** asociadas a los objetos en la imagen, en cualquier instante de tiempo  $t$  deberá detectar un conjunto de objetos conocidos  $K_t = \{1, 2, \dots, C\} \subset \mathbb{N}^+$ . No obstante, existe un conjunto de objetos  $K_u = \{C + 1, \dots\}$  que se descubrirán durante el tiempo de inferencia. Por lo tanto, en un tiempo de inferencia  $t_n$ , el modelo  $M_c$  deberá ser capaz de detectar un conjunto de objetos conocidos  $K_t$  y desconocidos  $K_u$  con su respectiva etiqueta y las coordenadas centrales de *labounding box*.

Para el primer problema, propone usar una red de propuesta de regiones (RPN), la cual mediante una cabeza de regresión  $f_{reg}$  estima la objetividad de cada region que proponga la red. Por lo tanto, genera una lista de regiones

con una objetividad asociada de la cual se selecciona aquellas con mayor puntaje y se clasifica como desconocido.

2. Dado un modelo de aprendizaje  $M_d$  con  $K_t = \{1, 2, \dots, C\}$  clases aprendidas, un conjunto de muestras  $U_t$  desconocidas son identificadas como muestras conocidas o nuevas clases. Por lo tanto, el modelo  $M_d$  debe actualizar las clases aprendidas o agregar nuevas clases sin reentrenar desde cero al modelo  $M_d$ , es decir, debe realizar un aprendizaje de forma continua. Tal que, al conjunto de clases conocidas se agreguen las nuevas clases en tiempo de inferencia  $K_{t+1} = \{C, C+1, \dots, C+n\}$ .

En el segundo problema, propone usar un enfoque de aprendizaje incremental/continuo basado en repetición en el cual almacena un conjunto balanceado de ejemplos  $N_{ex}$  por clase y hace fine-tuning en cada actualización de clases del modelo.

3. Dado un modelo de reconocimiento  $M_e$  con el conocimiento de un conjunto de objetos conocidos  $K_t = \{1, 2, \dots, C\}$ . El modelo  $M_e$  en tiempo de inferencia debe ser capaz de rechazar de forma continua potenciales fuentes de ruido de muestras conocidas o clases no conocidas. De ser el caso, asociar dichas muestras o clases válidas a una etiqueta temporal hasta su posterior integración del modelo.

En este tercer problema, propone un modelo basado en energía como modelo de reconocimiento de clases desconocidas.

$$E(f) = -T \log \sum_l \exp\left(\frac{-E(f, l')}{T}\right) \quad (22)$$

$E(f, l')$ : representa cada casilla de un vector de características de una muestra  $f$  y su etiqueta  $l'$ .

$\sum_l$ : indica la suma sobre todas las posibles clases  $l$ .

$T$ : es la temperatura.

En el cual, se busca ajustar  $T$  mediante el entrenamiento para separa los valores de energía de las clases desconocidas y conocidas. Entonces, si el valor de energía de una nueva muestra  $X_e$  supera el umbral estimado del valor de energía de las clases conocidas  $K_e$ , entonces, es una muestra desconocida  $Uk_e$ . Las condiciones son las siguiente :

$$M(X_e) = \begin{cases} \textit{known} & \text{if } X_e < K_e \\ \textit{unkown} & \text{if } X_e > K_e \end{cases} \quad (23)$$

[40] propone una versión para escenas de caminos mediante una red neuronal Faster R-CNN de tres cabezas y un enfoque de aprendizaje por curricula para entrenar al modelo de manera gradual y controlada. La primera cabeza aborda la variación de escala intraclass implementando una pérdida de regresión focal. La segunda cabeza aborda el reconocimiento de clases conocidas y desconocidas implementando un clasificador basado en energía. Y la tercera cabeza aborda el problema de la representabilidad y separabilidad de clases conocidas y desconocidas implementando un módulo nombrado mezcla de características. Así mismo, [15] propone el uso de los modelos transformers para mejorar la detección de los objetos desconocidos mediante la codificación de información contextual. En este sentido, incorpora módulos de atención deformables a múltiples escalas, un pseudo etiquetado mediante mapas de atención para calcular el puntaje de objetividad y separar posibles objetos del fondo mediante la selección de regiones de interés de objetos desconocidos. Y finalmente, con base en el puntaje de objetividad, clasificar las regiones de interés como clases conocidas y clases desconocidas. La propuesta de objetividad que propone es la siguiente:

$$s_0(b) = \frac{1}{W_b \cdot H_b} \sum_{x_b - \frac{w_b}{2}}^{x_b + \frac{w_b}{2}} \sum_{y_b - \frac{h_b}{2}}^{y_b + \frac{h_b}{2}} A_{ij} \quad (24)$$

donde,  $b$ : es la caja delimitadora con coordenadas  $x_b, y_b$  y tamaño  $w_b, h_b$ ,  $A_{ij}$ : el mapa de atención y la doble sumatoria, el valor de todas las activaciones del mapa de atencion.

De igual forma, en [44] se propone el uso de prototipos en un enfoque discriminativo de clases para abordar el problema de la detección de objetos de mundo abierto. En este sentido, se integran tres módulos en un modelo *Faster R-CNN, Proposal Embedding Aggregator (PEA)* para modelar la distribución de las clases conocidas en prototipos y reconocer a partir de la distancia muestras y clases desconocidas, *Embedding Space Compressor (ESC)* para minimizar el riesgo de solapamiento entre clases conocidas y desconocidas en el espacio latente y un clasificador de similitud coseno el cual reemplaza a la función *softmax* como función de clasificación entre clases conocidas y desconocidas. Entonces para el PEA propone modelar y estimar la distancia a las clases de la siguiente forma:

$$\mathcal{D}_d \left( \mathcal{F}(x_i)_p, \mathcal{C}^j \right) = \mathcal{F}(x_i)_p \bullet \mathcal{C}^j \quad (25)$$

En el cual,  $\mathcal{F}(x_i)$  es el vector de características de la muestra,  $\mathcal{D}_d$  representa la distancia euclidiana obtenida por el producto punto y  $\mathcal{C}^j$  representa el centro de cada prototipo asociado a una clase. La minimización del riesgo de solapamiento ESC durante el entrenamiento lo propone de la siguiente manera:

Por un lado, mediante la estimación de la probabilidad de una muestra  $x_i$  pertenezca a una clase  $j$ :

$$p_{ij}(y = j \mid x_i, \mathcal{F}, C) = \frac{e^{-D(\mathcal{F}(x_i)_p, \mathcal{C}^j)}}{\sum_{k=1}^K e^{-D(\mathcal{F}(x_i)_p, \mathcal{C}^k)}} \quad (26)$$

donde,  $\mathcal{F}(x_i)$  es el vector de características de la muestra,  $\mathcal{D}_d$  representa la distancia euclidiana obtenida por el producto punto y  $\mathcal{C}^j$  representa el centro de cada prototipo asociado a una clase.

Con su función objetivo respectivamente:

$$L_{dce}(x_i, \theta, C) = -\log p_{ij}(y = j \mid x_i, \mathcal{F}, C) \quad (27)$$

En el cual,  $\mathcal{F}$  es el vector de características de la muestra,  $j$  representa la etiqueta de una clase,  $C$  el centro del prototipo y  $x_i$  representan las características de una nueva muestra.

Y por el otro, estimando la pérdida de riesgo de espacio abierto de la siguiente forma:

$$L_{osr}(x_i, \theta, C, R) = \max\{0, D_d(\mathcal{F}(x_i)_p, C^j) - R\} \quad (28)$$

En el cual,  $x_i$  representa las muestras de entrenamiento de una etiqueta  $j$ ,  $C$  el centro de su prototipo,  $R$  un parametro de aprendizaje y  $\max$  indica que se obtendra el valor más alto entre 0 y la distancia euclidiana estimada. De tal forma que se obtiene una función objetivo general  $L_{proto} = L_{dce} + \lambda L_{osr}$  para mitigar el solapamiento.

### 3.2.3 Otros trabajos que abordan problemas puntuales en el aprendizaje de detección de objeto de mundo abierto

[47] propone el reconocimiento de nuevas clases de objetos sin intervención humana mediante el uso de un modelo Faster R-CNN para extraer regiones que contengan objetos conocidos y desconocidos, un espacio de memoria en donde se aprende mediante aprendizaje contrastivo las representaciones de los objetos desconocidos y un modelo k-means como clasificador de nuevas categorías. Así mismo, [10] propone abordar el sesgo de etiquetas en el enfoque no supervisado de la detección de objetos desconocidos, mediante la integración de dos módulos, *Reconstruction Error-based Weibull Model for Unsupervised Unknown Object Identification (REW)* y *REW-enhanced Object Localization Network (ROLNet)* en un modelo *Faster R-CNN*. En este sentido, mediante REW se lleva a cabo la selección y pseudo etiquetado de regiones de interés con objetos conocidos y desconocidos, al mismo tiempo que, mediante el uso de un autoencoder se reconstruyen las regiones propuestas en busca de errores de reconstrucción que distingan regiones de fondo y de objetos estimando una puntuación de objetividad; ROLNet, integra la puntuación de objetividad de REW para mejorar la localización de objetos desconocidos. Por otro lado, [16] propone el reconocimiento de objetos desconocidos expandiendo regiones latentes de baja densidad. Primero, mediante un enfoque de aprendizaje contrastivo, reduce la variabilidad intraclass

y aumenta la variabilidad interclase de las clases conocidas en el espacio latente. Luego, modela la probabilidad de la muestra o clase desconocida para establecer un umbral de incertidumbre con el cual expandir subespacios de baja densidad.

[46] replantea el punto de referencia de la detección de objetos de mundo abierto ante una inconsistencia metodológica. Por lo tanto, propone dos métricas para evaluar la detección de objetos desconocidos: *Unkown Detection Recall* y *Unkown Detection Precision*, 5 principios para elaborar un betchmarks y dos módulos para el reconocimiento de muestras y clases desconocidas a partir de una **red faster R-CNN**. Los cinco principios que propone son:

- **Apertura de Clases:** Durante la inferencia, pueden existir tanto clases conocidas como desconocidas, pero solo las clases conocidas están etiquetadas y se utilizan para entrenar el detector.
- **Incremento de Tareas:** Las clases conocidas aumentan en tamaño, y la tarea se desarrolla de manera incremental. **Incremento de Tareas:** Las clases desconocidas de interés se etiquetan y se añaden al conjunto de clases conocidas en la siguiente tarea.
- **Especificidad de la Anotación:** Diferentes estrategias de anotación para los conjuntos de datos de entrenamiento, validación y prueba. Durante la prueba, las instancias de clases desconocidas solo reciben una etiqueta de "desconocido" y sus correspondientes coordenadas de caja.
- **Integridad de la Etiqueta:** La información de todas las etiquetas deben estar integradas durante la prueba para una evaluación justa. Esto con el motivo de evitar falsos positivos debido a la falta de anotaciones.
- **Especificidad de los Datos:** No debe haber intersección entre los conjuntos de datos de entrenamiento, validación y prueba, y no debe haber duplicación dentro de cada conjunto de datos.

En el caso de los módulos, el primer módulo, Asesor de propuestas auxiliar (APA), favorece la localización de regiones desconocidas evaluando la objetividad de las cajas y realizando una búsqueda selectiva de posibles regiones de interés que contengan objetos desconocidos. El segundo módulo, Clasificador de expulsión específico de clase, calibra los valores de predicción tomando como referencia los valores predichos durante el entrenamiento para evitar valores de sobre confianza.

[48] propone un método de detección de objetos de mundo abierto mediante un modelo Faster R-CNN libre de clasificación (CF-RPN) y una red de aprendizaje contrastivo a nivel de instancia (PLN). En este sentido, CF-RPN utiliza la ubicación y forma de los objetos para generar regiones de interés que contengan objetos sin sesgo de las clases conocidas. Mientras que PLN realiza el aprendizaje contrastivo a nivel de instancia mediante el uso de prototipos discriminativos para cada clase conocida.

A pesar de los avances realizados en el campo, se ha observado que predomina en las investigaciones la búsqueda de soluciones para la detección de objetos desconocidos en el fondo, primer problema planteado en el aprendizaje y detección de objetos de mundo abierto de acuerdo con [20]. Por el contrario, el segundo problema, aprendizaje incremental/continuo y tercero, detección de aquello desconocido se ha abordado superficialmente. En específico, para el segundo problema no se ha realizado verdaderamente un sistema de aprendizaje que pueda aprender continuamente a partir de un flujo de datos o lo que es igual a un aprendizaje continuo y no incremental. En este sentido, se está abordando desde un nivel de arquitectura, es decir, modificar la arquitectura de la red neuronal artificial (congelando subsecciones de la red, agregando cabezas de clasificación, etc.) cada que sea necesario realizar un incremento en el aprendizaje. En el tercer problema, se han propuesto modelos estadísticos paramétricos para el reconocimiento de aquello desconocido (nuevas muestras y nuevos objetos). Sin embargo, estos modelos siguen bajo un supuesto de conjunto cerrado; por lo tanto, son incapaces de responder ante una eventual

adaptación a entornos dinámicos. En la tabla 1, se lleva a cabo una comparación sobre el alcance de las propuestas de los modelos de aprendizaje para la detección de objetos en entornos de mundo abierto y se contrastan con la propuesta de este trabajo.

**Table 1: Comparación de diferentes métodos de aprendizaje en la detección de objetos en conjuntos abiertos**

| Autor                    | Tipo de Aprendizaje | Tipo de Aprendizaje Incremental    | Actualiza Conocimiento Previo | Detección de lo Desconocido   | Adaptabilidad a Entornos de Mundo Abierto | Rechazo o Integración |
|--------------------------|---------------------|------------------------------------|-------------------------------|-------------------------------|---|-----------------------|
| Zhou Z. et al. 2023      | Supervised          | -                                  | N                             | Cosine Similarity             | N   | R                     |
| Fang R. et al. 2023      | Unsupervised        | Incremental (exemplar-fine tuning) | N                             | Objectiveness (Weibull model) | N   | R                     |
| Pershouse D. et al. 2023 | Supervised          | Incremental (fine tuning)          | N                             | Gaussian Mixture Models       | N   | R                     |
| Yu J. et al. 2023        | Supervised          | Incremental (exemplar-fine tuning) | N                             | Cosine Similarity             | N   | R                     |
| Zohar O. et al. 2022     | Semi-supervised     | Incremental (fine tuning)          | Y                             | Objectiveness                 | Y   | I                     |
| Zheng J. et al. 2022     | Semi-supervised     | Incremental (Retraining)           | Y                             | Jaccard Index                 | N   | I                     |
| Han J. et al. 2022       | Supervised          | Incremental (Retraining)           | N                             | Jaccard Index                 | N   | R                     |
| Gupta A. et al. 2022     | Supervised          | Incremental (exemplar-fine tuning) | N                             | Objectiveness                 | N   | R                     |
| Zhao X. et al. 2022      | Supervised          | Incremental (fine tuning)          | N                             | Jaccard index                 | N   | R                     |
| Singh D. K. et al. 2021  | Supervised          | Incremental (fine tuning)          | N                             | Energy based                  | N   | R                     |
| Joseph K. J. et al. 2021 | Supervised          | Incremental (fine tuning)          | N                             | Energy based                  | N   | R                     |
| Propio                   | No supervisado      | Continuo                           | Y                             | Energía regularizada          | Y   | I                     |

### 3.3 Meta reconocimiento

En entornos con flujos de información altamente variables las capacidades para que los modelos de aprendizaje profundo y de detección de objetos aprendan una representación aceptable de los entornos de mundo abierto se vuelve un reto significativo. El ruido, las muestras no observadas y la integración de nuevas clases, ocasiona que, con el tiempo las tareas que se desempeñan favorablemente se vuelven obsoletas e incapaces de realizarse. Por lo tanto, la necesidad de evaluar y regular la información que procesan los modelos de entrenamiento posteriormente a su etapa de entrenamiento es un tema relevante hoy en día. Respecto al reconocimiento de nuevas muestras y clases, son dos problemas escasamente abordados directamente en el meta-reconocimiento. No obstante, colateralmente en problemas de aprendizaje continuo y mundo abierto son objetos de estudio.

Entonces, con relación al reconocimiento de comportamientos inconsistentes/sobre confianza; [18] proponen reconocer la sobre confianza al corregir la función softmax

con un pseudo-umbral de incertidumbre obtenido de calcular la probabilidad (softmax) máxima. Luego, es evaluada sobre las métricas *Area Under Receiver Operating Characteristic (AUROC)* y *Area Under Precision-Recall (AUPR)*.

$$Y(X_i) = \begin{cases} OOD & \text{if } \max(\text{softmax } P(x_i)) < \max(\text{softmax } P(x'_i)) \\ InDistribution & \text{if } \max(\text{softmax } P(x_i)) > \max(\text{softmax } P(x'_i)) \end{cases} \quad (29)$$

En este sentido,  $\text{softmax } P(x_i)$  representa la probabilidad más alta estimada por la función softmax para la muestra  $x_i$  en alguna de las clases,  $\text{softmax } P(x'_i)$  representa la probabilidad más alta de una muestra fuera de la distribución. Así mismo, presenta otra propuesta basada en un modulo encoder sobre el cual aprovecha la disparidad en la reconstrucción de los datos para determinar un valor fuera de la distribución. Sin embargo, la eficacia depende del correcto entrenamiento de la función *softmax* y una gran variabilidad de características en los ejemplos de una misma clase (varianza intra-clase), dos condiciones difíciles de cumplir conociendo los problemas naturales de la función *softmax* [30].

[29] proponen una versión no paramétrica del umbral de incertidumbre a partir de los rangos intercuartiles Q3 y Q1 estimados de la distribución subyacente de los valores del vector de características (logit) de la última capa para cada clase en el modelo, maximizando el rango intercuartil (IQR) mediante una constante de ajuste común T. El umbral T se define de la siguiente forma:

$$IQR = Q_3 - Q_1 \quad (30)$$

$$T = Q_3 + k \cdot IQR \quad (31)$$

En el cual, los cuartiles  $Q_1$  y  $Q_3$  se estiman a partir de la distribución de los vectores de características de la última capa (logit) para cada clase del modelo y K es un coeficiente de ajuste.

$$Y(X_i) = \begin{cases} OOD & \text{if } T_{x_i} < g(x'_i) \\ InDistribution & \text{if } T_{x_i} > g(x'_i) \end{cases} \quad (32)$$

Así mismo,  $T_{x_i}$  representa el umbral establecido a partir de una muestra de prueba asociado a una clase y  $g(x'_i)$  representa la estimación de una red neuronal artificial para una nueva muestra.

No obstante, el umbral no paramétrico depende crucialmente de que los modelos proporcionen una representación logit con una gran variabilidad de características en los ejemplos de una misma clase (varianza inter-clase), una distribución subyacente completa y espacio suficiente para el almacenamiento del conjunto de muestras con el cual estimar el umbral. Problemas aún no resueltos relacionados a las capacidades de representación/generalización y escalabilidad en los modelos.

Entonces, [8] proponen la elaboración de un umbral integrando un módulo de estimación de confianza en los modelos neuronales profundos para reconocer muestras que ocasionan sobre confianza. El módulo, es calibrado durante las etapas de entrenamiento, empleando como conjunto de entrenamiento todas las muestras erróneamente predichas como parte de una distribución determinada. En este sentido, el módulo propuesto es el siguiente:

$$c = \text{objectiveness}(x_i) \quad (33)$$

$$p'_i = c \cdot p_i + (1 - c) \cdot y_i \quad (34)$$

En el cual,  $x_i$  representa una nueva muestra,  $p'_i$  representa la probabilidad calibrada,  $p_i$  representa la probabilidad estimada para una clase,  $y_i$  la probabilidad de la distribución objetivo y  $c$  el valor de confianza estimado por la cabeza de clasificación añadida como modulo de confianza y el cual se corrige durante el entrenamiento. Por lo tanto, la detección de datos fuera de la distribución se da como:

$$Out(x_i) = \begin{cases} OOD & \text{si } c \leq \delta \\ In\ distribution & \text{si } c > \delta \end{cases} \quad (35)$$

En este sentido,  $\delta$  representa un umbral preestablecido en función de las probabilidades calibradas en  $p'_i$ . Si bien, es una propuesta robusta y capaz de ser empleada

en múltiples modelos, se desconoce si el módulo de sobre confianza cuenta con muestras suficiente para representar el abanico de muestras que ocasionen sobre confianza en las distintas distribuciones del modelo. Así mismo, la constante de ajuste B no puede garantizar que no ocurra un sobreajuste que esconda las muestras de sobre confianza no observadas como ocurre al calibrar la función *softmax*.

El calibrar las funciones de la última capa no es suficiente para abordar el problema del reconocimiento de aquello desconocido por los modelos profundos. Por tal motivo, [24] proponen maximizar la separación entre muestras de la distribución y fuera de la distribución mediante la calibración de la función softmax, el aprendizaje de una constante de temperatura T y perturbaciones en las muestras. De tal manera que, el modelo aprenda a reconocer la perturbación en las muestras; cuando ésta predomine, se reconocerá como sobre confianza. Lo que permite a los modelos ajustar la constante de calibración T en función de las perturbaciones y no de la distribución aprendida. Sin embargo, llevar a cabo la maximización del umbral T para separar muestras conocidas de desconocidas no soluciona la incapacidad para conocer todas las muestras de una distribución. Entonces, se emplea el procesamiento de datos, regularización y ajuste del umbral de temperatura como solución para el conjunto de datos conocido.

Por otro lado, [23] proponen una vertiente que supone una distribución condicional gaussiana multivariada de las distribuciones conocidas, en un modelo profundo, para modelar un clasificador generativo a partir de la distancia de Mahalanobis. Este puntaje estimado permite ser robusto para detectar muestras que no pertenecen a las distribuciones conocidas. La propuesta de Mahalanobis como clasificador para modelos profundos es la siguiente:

$$\hat{y}(\mathbf{x}) = \arg \min_c (f(\mathbf{x}) - \hat{\mu}_c)^\top \hat{\Sigma}^{-1} (f(\mathbf{x}) - \hat{\mu}_c) \quad (36)$$

Para la cual,  $f(x)$  es el vector de características de una nueva muestra,  $\hat{\mu}_c$  es la

media de los vectores de características asociados a una clase  $c$ ,  $\hat{\Sigma}^{-1}$  la matriz de covarianza de la clase  $c$  y  $\min$ , indica que se considerará la distancia más corta como parámetro para asignar una clase. Entonces, la detección se estima como:

$$Out(x_i) = \begin{cases} InDistribution & \text{if } \hat{y}(\mathbf{x}) < \delta \\ OOD & \text{if } \hat{y}(\mathbf{x}) > \delta \end{cases} \quad (37)$$

En el cual,  $\delta$  representa un umbral preestablecida de distancia mínima para ser considerado como parte de la clase y  $D_M$  es la distancia estimada resultante de la nueva muestra. Sin embargo, mahalanobis resulta sensible a la dimensionalidad y la variabilidad de cada modelo sobre la varianza interclase de sus vectores de características (logit), ocasiona una incertidumbre sobre las capacidades de generalización del método. Entonces, las capacidades de representabilidad del modelo determinan la varianza interclase de los logit, volviéndolo poco práctico como única medida de clasificación.

Como resumen, las propuestas actuales han logrado avances en la detección de datos fuera de la distribución, calibrando clasificadores para desenvolverse en entornos de mundo abierto y experimentado en técnicas cada vez más precisas. Sin embargo, estos aportes trabajan con modelos de meta reconocimiento de conjunto cerrado, es decir, requieren de supervisión para mantener los modelos en optimas condiciones y proporcionar los datos suficientes para la tarea. Esto podemos observarlo en las propuestas como la supervisión para el uso de coeficientes de ajuste T, módulos que se integración en los modelos profundos y requieren de calibración durante el entrenamiento, en un enfoque de aprendizaje supervisado y aproximaciones que requieren de un conjunto de datos preestablecido para modelar sus relaciones, como lo es la distancia de Mahalanobis.

En este trabajo, se propone una aproximación de meta reconocimiento para conjunto abierto, que emplea la distancia de Mahalanobis de forma no supervisada, actualiza los parámetros de reconocimiento del modelo de meta reconocimiento y se aumenta la separabilidad entre los datos de clases distintas a partir de una función

de energía sin la calibración del clasificador con el uso de coeficientes de ajuste como T.

## 4 Metodología

1. Comparar los diferentes modelos de detección de objetos, aprendizaje continuo y meta reconocimiento y propuestas en drones.

Se llevara a cabo una revisión del estado del arte sobre las diferentes técnicas detección de objetos, aprendizaje continuo y meta reconocimiento, así como las diferentes aproximaciones que se presentan en drones. Luego, se buscara evaluar las técnicas de los diferentes campos para su selección y desarrollo.

2. Proponer un método de detección de objetos adaptable a un entorno de mundo abierto.

Basado en el análisis del estado del arte, se determina un método de detección de objetos que permite su adaptación a entornos de mundo abierto. Se espera que este detector funcione de manera independiente y muestre buen desempeño en la segmentación de regiones de posibles objetos.

3. Proponer un método de aprendizaje continuo para la detección de objetos en entornos de mundo abierto.

A partir de la segmentación de los objetos, se emplea un extractor de características, con el cual generar una representación de lo objetos segmentados. A partir del estudio del estado del arte, se diseña el marco general del modelo de aprendizaje continuo tomando en cuenta la representación de los objetos y la representación que necesitara el modelo de meta reconocimiento. Finalmente se desarrolla el modelo.

4. Proponer un método de meta reconocimiento para entornos de mundo abierto

El modelo de aprendizaje continuo en parte actúa como codificador que proporciona un vector de características representativo de la clase de interés. A partir de esta representación, se establece una clase prototípica considerando el promedio de las características de la clase y su matriz de covarianza. Aunado a ello, los prototipos se evalúan en diferentes métricas, para seleccionar la de mayor desempeño. En este sentido, técnicas como Mahalanobis y la función de energía modelan representaciones favorables para los modelos de meta reconocimiento. En función de estas técnicas, se espera el desarrollo de un modelo de meta reconocimiento del cual se busca sea posible actualizar sus parámetros a lo largo del tiempo del sistema.

5. Proponer una métrica de evaluación considerando las clases prototípicas para el modelo de meta-reconocimiento que permita describir los conjuntos de datos de las clases bajo una distribución probabilística.
6. Las clases prototípicas emplean métricas de distancia para evaluar la similitud entre la nueva muestra y las clases. Se propone a la distancia Mahalanobis como métricas debido a su rendimiento en espacios de características no Euclídeos. No obstante, la función de energía es otra aproximación factible que modela adecuadamente la similitud entre muestras. Con esta métrica, se espera evaluar las capacidades del modelo de meta reconocimiento para reconocer muestras y objetos desconocidos, conocidos e inconsistentes.
7. Proponer el modelo de integración del sistema de aprendizaje continuo de detección de objetos para entornos de mundo abierto con drones.

Se espera primero diseñar un marco general del modelo integrador, desarrollar las actividades de monitoreo que el dron realizara, presentar un prototipo como sistema de aprendizaje continuo de detección de objetos para entornos de mundo abierto con drones y evaluar su desempeño en las actividades de monitoreo que se designen. Así mismo, también se espera evaluar el desempeño

del sistema como modelo de aprendizaje continuo de detección de objetos para entornos de mundo abierto. Por lo tanto, se planea evaluar en medidas como F1-Score, Average Incremental Accuracy, Wilderness Impac, Unknown Detection Recall y Mean Average Precision esencialmente.

## 5 Resultados preliminares

Se llevo a cabo una primera aproximación para el modelo de aprendizaje continuo de entornos de mundo abierto tomando como modelo base a [14, 4], conformado esencialmente de un modelo de aprendizaje continuo y un modelo de meta reconocimiento, con el fin de evaluar su desempeño. En este sentido, la detección de objetos y la integración con drones no fueron considerados. Este módulo representa una parte central del modelo, y demuestra la factibilidad de un modelo de aprendizaje continuo para la detección de objetos en mundo abierto. Así mismo, se presenta un modelo de meta reconocimiento necesario para operar en entornos de mundo abierto.

El modelo de aprendizaje propuesto, lleva acabo una clasificación basada en la distancia de Mahalanobis a partir de un modelo de redes neuronales artificiales preentrenado, el cual usa como regla de clasificación la distancia más corta.

$$y^* = \arg \min_{c \in \{1, \dots, C\}} d^\Phi(\Phi(x), \mu_c^\Phi) \quad (38)$$

Tal que,  $y^*$  es la clase a la que se asigna la muestra,  $d^\Phi$  representa la distancia de Mahalanobis,  $\Phi(x)$  representa el vector de características de una red neuronal artificial y  $\mu_c^\Phi$  es el vector de características promedio asociado a una clase y que representa el prototipo de la clase. La distancia de Mahalanobis se estima a partir de una matriz de covarianza y un vector promedio asociado a la clase, las cuales se propone actualizar con cada clase nueva de la siguiente forma: Distancia de Mahalanobis

$$D_M = (\Phi(x) - \mu_c^\Phi)^T \Sigma^{-1} (\Phi(x) - \mu_c^\Phi)$$

En el cual,  $\Sigma^{-1}$  representa la inversa de la matriz de covarianza asociada a una clase.

Media y Covarianza

$$\mu_{(c+1)}^\Phi = \mu_c^\Phi + \frac{1}{n+1}(\mu_{(c+1)}^\Phi - \mu_c^\Phi) \quad (39)$$

$$\sum_{c_{(n+1)}}^\Phi = \sum_{c_n}^\Phi + \frac{(\Phi(x) - \mu_c^\Phi)(\Phi(x) - \mu_{(c+1)}^\Phi) - \sum_{c_n}^\Phi}{n+1} \quad (40)$$

En donde,  $\mu_{(c+1)}^\Phi$  representa el vector promedio de características actualizado con la nueva muestras y  $c$  representa la clase asociada.

El modelo preentrenado, recibe las muestras como entrada y proporciona los vectores de características que se emplearan para la clasificación. Previo a estimar la distancia de Mahalanobis, se emplea una regularización sobre las matrices de covarianza para evitar inestabilidad numérica, calculandola de la forma siguiente:

$$\sum_{c_{(n_{sh})}}^\Phi = \sum_{c_n}^\Phi + \alpha_1 M_1 I + \alpha_2 M_2 (1 - I) \quad (41)$$

En donde,  $M_1$  representa la varianza diagonal promedio,  $M_2$  representa el promedio fuera de la diagonal,  $\alpha_1$  y  $\alpha_2$  son coeficientes de proporcionalidad, y  $I$  representa la matriz identidad.

Una vez estimado la distancia de Mahalanobis, se lleva acabo el meta reconocimiento para determinar si la muestra observada es parte de una clase conocida por el modelo, o por el contrario, es una muestra desconocida. Por un lado, se prueba el meta reconocimiento basado en una distribución de weibull, que emplea el puntaje de la distancia de Mahalanobis para llevar a cabo sus estimaciones de la siguiente manera: A partir de la funcion de densidad de probabilidad:

$$f(x, \beta, \eta) = \frac{\beta}{\eta} \left(\frac{x}{\eta}\right)^{\beta-1} e^{-\left(\frac{x}{\eta}\right)^\beta} \quad (42)$$

Se calcula la distribución acumulada:

$$S = f(x, \beta, \eta) = 1 - e^{-\left(\frac{x}{\eta}\right)^\beta} \quad (43)$$

En este sentido,  $\eta$  representa la forma,  $\beta$  representa la escala y  $S$  es la probabilidad estimada de pertenecer a la distribución. De tal manera que, se puede estimar lo siguiente:

$$\begin{cases} OOD(Unknown) & \text{if } S < \delta_1 \\ New\ class & \text{if } \delta_2 > S > \delta_1 \\ InDistribution(known) & \text{if } S > \delta \end{cases} \quad (44)$$

En este sentido,  $\delta_1$  es un umbral preestablecido en 15% y  $\delta_2$  es un umbral preestablecido en 35%. Tanto  $\delta_1$  y  $\delta_2$  se obtuvieron de forma empírica al realizar varias pruebas de reconocimiento. En estas pruebas, se probó con umbrales de 5%, 10%, 15%, 20%, 25%, 30%, 35% y 40%. De los cuales 15% y 35%, fueron los de mejor respuesta.

Por el otro lado, se emplea el meta reconocimiento adaptativo propuesto, basado en la función de energía libre de Helmholtz, el cual transforma los puntajes de Mahalanobis en valores de energía de la forma siguiente:

$$E(D_M) = -T \log \left( e^{-\frac{D_M}{T}} \right) \quad (45)$$

En el cual,  $D_M$  es la distancia de Mahalanobis, e representa la constante de Euler y  $T$  es un coeficiente de ajuste fijado en  $T=1$ . Aunado a ello, se estima el mismo procedimiento para cualquier otra clase conocida por el modelo. Posteriormente, con los valores de energía de las clases, se estima las probabilidades correspondientes mediante la distribución de Gibbs:

$$P(y | x) = \frac{-T \log \left( e^{-\frac{D_{M_s}}{T}} \right)}{-T \log \sum_{i=0}^n e^{-\frac{D_{M_i}}{T}}} \quad (46)$$

Y de forma independiente, con los valores de energía estimados erróneamente a partir de calcular las distancias de Mahalanobis entre el vector de características de una nueva muestra y los prototipos de las clases, se modela una distribución de probabilidad de energía de anomalías mediante la función de densidad siguiente:

$$f(x, \beta) = \frac{x}{\beta^2} e^{-x^2/(2\beta^2)} \quad (47)$$

Y la funcion acumulada estimada:

$$f(x, \beta) = 1 - e^{-\frac{x^2}{2\sigma^2}} \quad (48)$$

En este sentido,  $\beta$  representa la escala y  $x$  los valores de energía. Finalmente, se emplea una corrección de probabilidades entre las probabilidades de la distribución de Gibbs y las provenientes del modelo estadístico de la manera siguiente: Corrección en la probabilidad para la clase de rechazo:

$$E_k = \sum_{j=0}^y (a_i - (a_i \cdot b_i)) \quad (49)$$

Corección en la probabilidad para las clases conocidas por el modelo:

$$E_i = b_i \cdot a_i \quad (50)$$

De tal forma que  $E_k$  y  $E_i$  son las probabilidades corregidas (ajustadas),  $b_i$  es la probabilidad acumulada del modelo estadístico de energía de anomalías 47 y  $a_i$  representa las probabilidades estimadas por la distribución de Gibbs 46. Entonces, se puede estimar lo siguiente:

$$O_{eng}(x_i) \begin{cases} InDistribution(known) & \text{if } E_k < \delta_1 \\ New class & \text{if } \delta_2 > E_k > \delta_1 \\ OOD(Unkown) & \text{if } E_k > \delta_2 \end{cases} \quad (51)$$

En este sentido,  $\delta_1$  es un umbral preestablecido en 15% y  $\delta_2$  es un umbral preestablecido en 35%. Por lo tanto, es posible rechazar y reconocer muestras para su aprendizaje. El aprendizaje y actualización de clases una vez realizado el metareconocimiento, se lleva a cabo agregando la muestra a la clase o en inicializando y agregando la muestra mediante las fórmulas [39,40].

El experimento consistió en evaluar el desempeño de aprendizaje del modelo con el modelo de aprendizaje continuo y meta reconocimiento que se presenta sobre un flujo de datos continuo y variable, como ocurriría en los entornos de mundo abierto. Para ello, se generó un flujo continuo de datos sintéticos de cinco clases

con 5,000 muestras cada una. Las primeras cuatro clases se consideran clases objetivo, y la última clase se considera clase de ruido. El modelo de aprendizaje parte inicialmente con una clase preentrenada conformada de un prototipo de media y covarianza de la clase, una clasificación basada en la distancia de Mahalanobis, una red neuronal artificial ResNet-18 preentrenada y un modelo estadístico de Weibull y basado en energía como modelos de meta reconocimiento. Las muestras se conforman de un vector de características de la clase con un tamaño de 512 de longitud. Y finalmente, el umbral de rechazo es preestablecido. El objetivo del experimento es que el modelo aprenda dentro del flujo de datos sintéticos las 3 clases restantes, actualice la clase inicial y rechace la clase de ruido. Los resultados preliminares del aprendizaje proporcionaron lo siguiente: En la tabla 2, se puede observar que los

**Table 2: Comparativa de dos modelo de meta reconocimiento para el aprendizaje continuo en mundo abierto**

| <b>Modelo</b>      | <b>Métrica</b> | <b>Rango de puntajes</b> | <b>Recall (%)</b> | <b>Specificity (%)</b> | <b>Precision (%)</b> |
|--------------------|----------------|--------------------------|-------------------|------------------------|----------------------|
| Normal             | Mahalanobis    | 25 – 18                  | 100               | 70                     | 34                   |
| Regularized        | Mahalanobis    | 20 – 15                  | 100               | 69                     | 35                   |
| Energy             | Energy         | 12 – 9                   | 87                | 100                    | 100                  |
| Regularized Energy | Energy         | 10 – 8                   | 87                | 100                    | 100                  |

modelos de meta reconocimiento basados en energía tienen intervalos más compactos de agrupación. Así mismo, de los dos modelos, el de energía mostró una mejor representación de las clases y desempeños favorables para el aprendizaje continuo de mundo abierto.

## 6 Plan de trabajo

Como conclusión, el desarrollo de modelos de aprendizaje continuo para la detección de objetos en entornos de mundo abierto con drones. Es un área de oportunidad para

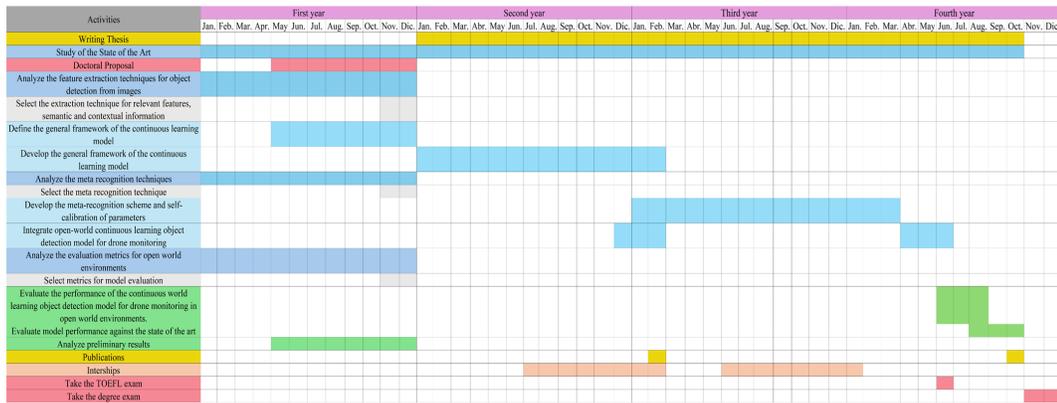


Figure 1: Plan de trabajo para los cuatro años.

realizarse avances relevantes. En especial los algoritmos de meta reconocimiento son elementos esenciales para que modelos profundos se desenvuelvan en entornos de mundo abierto. Una necesidad que cada día es mas importante. Los drones, son un ejemplo del impacto que estos modelos pueden llegar a tener en áreas aplicadas. Por otro lado, en el desarrollo de la propuesta, las pruebas iniciales de un modelo de aprendizaje continuo con meta reconocimiento de mundo abierto se desarrollo positivamente, lo que muestra la factibilidad de la propuesta. No obstante, aún es necesario conocer el alcance de su desempeño. Como avances futuros, se empezara realizarse el diseño del monitoreo y experimentos más complejos que involucren otros módulos de la propuesta.

## References

- [1] AABID, A., PARVEEZ, B., PARVEEN, N., KHAN, S. A., ZAYAN, J., AND SHAB-BIR, O. Reviews on design and development of unmanned aerial vehicle (drone) for different applications. *J. Mech. Eng. Res. Dev* 45, 2 (2022), 53–69.
- [2] BARRIOS, D. B., VALENTE, J., AND VAN LANGEVELDE, F. Monitoring mammalian herbivores via convolutional neural networks implemented on thermal uav imagery. *Computers and Electronics in Agriculture* 218 (2024), 108713.
- [3] BENDALE, A., AND BOULT, T. Towards open world recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (2015), pp. 1893–1902.
- [4] BENDALE, A., AND BOULT, T. E. Towards open set deep networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (2016), pp. 1563–1572.
- [5] BISIO, I., GARIBOTTO, C., HALEEM, H., LAVAGETTO, F., AND SCIARRONE, A. A systematic review of drone based road traffic monitoring system. *Ieee Access* 10 (2022), 101537–101555.
- [6] BURKART, N., AND HUBER, M. F. A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research* 70 (2021), 245–317.
- [7] DAYAN, P., SAHANI, M., AND DEBACK, G. Unsupervised learning. *The MIT encyclopedia of the cognitive sciences* (1999), 857–859.
- [8] DEVRIES, T., AND TAYLOR, G. W. Learning confidence for out-of-distribution detection in neural networks. *arXiv preprint arXiv:1802.04865* (2018).

- [9] DHAMIJA, A., GUNTHER, M., VENTURA, J., AND BOULT, T. The overlooked elephant of object detection: Open set. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (2020), pp. 1021–1030.
- [10] FANG, R., PANG, G., ZHOU, L., BAI, X., AND ZHENG, J. Unsupervised recognition of unknown objects for open-world object detection. *arXiv preprint arXiv:2308.16527* (2023).
- [11] GHAHRAMANI, Z. Unsupervised learning. In *Summer school on machine learning*. Springer, 2003, pp. 72–112.
- [12] GIVEN I=K, GIVEN=KEIRON, F., AND GIVEN I=R, GIVEN=RYAN, F. An introduction to convolutional neural networks.
- [13] GOMEZ, C., AND PURDIE, H. Uav-based photogrammetry and geocomputing for hazards and disaster risk monitoring—a review. *Geoenvironmental Disasters* 3 (2016), 1–11.
- [14] GOSWAMI, D., LIU, Y., TWARDOWSKI, B., AND VAN DE WEIJER, J. Fecam: Exploiting the heterogeneity of class distributions in exemplar-free continual learning. *Advances in Neural Information Processing Systems* 36 (2024).
- [15] GUPTA, A., NARAYAN, S., JOSEPH, K., KHAN, S., KHAN, F. S., AND SHAH, M. Ow-detr: Open-world detection transformer. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (2022), pp. 9235–9244.
- [16] HAN, J., REN, Y., DING, J., PAN, X., YAN, K., AND XIA, G.-S. Expanding low-density latent regions for open-set object detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2022), pp. 9591–9600.
- [17] HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J., HASTIE, T., TIBSHIRANI, R., AND FRIEDMAN, J. Unsupervised learning. *The elements of statistical learning: Data mining, inference, and prediction* (2009), 485–585.

- [18] HENDRYCKS, D., AND GIMPEL, K. A baseline for detecting misclassified and out-of-distribution examples in neural networks. *arXiv preprint arXiv:1610.02136* (2016).
- [19] HINTON, G., VINYALS, O., AND DEAN, J. Distilling the knowledge in a neural network. *arXiv preprint arXiv:1503.02531* (2015).
- [20] JOSEPH, K., KHAN, S., KHAN, F. S., AND BALASUBRAMANIAN, V. N. Towards open world object detection. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (2021), pp. 5830–5840.
- [21] LANGLEY, P. Open-world learning for radically autonomous agents. In *Proceedings of the AAAI Conference on Artificial Intelligence* (2020), vol. 34, pp. 13539–13543.
- [22] LECUN, Y., BENGIO, Y., AND HINTON, G. Deep learning. *nature* 521, 7553 (2015), 436–444.
- [23] LEE, K., LEE, K., LEE, H., AND SHIN, J. A simple unified framework for detecting out-of-distribution samples and adversarial attacks. *Advances in neural information processing systems* 31 (2018).
- [24] LIANG, S., LI, Y., AND SRIKANT, R. Enhancing the reliability of out-of-distribution image detection in neural networks. *arXiv preprint arXiv:1706.02690* (2017).
- [25] MENEZES, A. G., DE MOURA, G., ALVES, C., AND DE CARVALHO, A. C. Continual object detection: a review of definitions, strategies, and challenges. *Neural networks* 161 (2023), 476–493.
- [26] MUNDT, M., HONG, Y., PLIUSHCH, I., AND RAMESH, V. A wholistic view of continual learning with deep neural networks: Forgotten lessons and the bridge to active and open world learning. *Neural Networks* 160 (2023), 306–336.

- [27] NASTESKI, V. An overview of the supervised machine learning methods. *Horizons. b 4*, 51-62 (2017), 56.
- [28] OSISANWO, F., AKINSOLA, J., AWODELE, O., HINMIKAIYE, J., OLAKANMI, O., AKINJOBI, J., ET AL. Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)* 48, 3 (2017), 128–138.
- [29] OZBULAK, U., VAN MESSEM, A., AND DE NEVE, W. Not all adversarial examples require a complex defense: Identifying over-optimized adversarial examples with iqr-based logit thresholding. In *2019 International Joint Conference on Neural Networks (IJCNN)* (2019), IEEE, pp. 1–8.
- [30] PEARCE, T., BRINTRUP, A., AND ZHU, J. Understanding softmax confidence and uncertainty. *arXiv preprint arXiv:2106.04972* (2021).
- [31] PERSHOUSE, D., DAYOUB, F., MILLER, D., AND SÜNDERHAUF, N. Addressing the challenges of open-world object detection. *arXiv preprint arXiv:2303.14930* (2023).
- [32] QIAO, Z., PHAM, X. H., RAMASAMY, S., JIANG, X., KAYACAN, E., AND SARABAKHA, A. Continual learning for robust gate detection under dynamic lighting in autonomous drone racing, 2024.
- [33] RANČIĆ, K., BLAGOJEVIĆ, B., BEZDAN, A., IVOŠEVIĆ, B., TUBIĆ, B., VRANEŠEVIĆ, M., PEJAK, B., CRNOJEVIĆ, V., AND MARKO, O. Animal detection and counting from uav images using convolutional neural networks. *Drones* 7, 3 (2023), 179.
- [34] ROLLAND, E., GRØNTVED, K. A. R., LAPORTE-DEVYLDER, L., KLINE, J. M., CHRISTENSEN, A., AND LUNDQUIST, U. P. S. Drone swarms for animal monitoring: A method for collecting high-quality multi-perspective data. In *The*

*15th annual International Micro Air Vehicle (IMAV) conference, Bristol, UK, 2024* (2024).

- [35] SCHEIRER, W., ROCHA, A., MICHEALS, R., AND BOULT, T. Robust fusion: Extreme value theory for recognition score normalization. In *Computer Vision—ECCV 2010: 11th European Conference on Computer Vision, Heraklion, Crete, Greece, September 5-11, 2010, Proceedings, Part III 11* (2010), Springer, pp. 481–495.
- [36] SCHEIRER, W. J., DE REZENDE ROCHA, A., SAPKOTA, A., AND BOULT, T. E. Toward open set recognition. *IEEE transactions on pattern analysis and machine intelligence* 35, 7 (2012), 1757–1772.
- [37] SHARIFANI, K., AND AMINI, M. Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal* 10, 07 (2023), 3897–3904.
- [38] SHIN, H., LEE, J. K., KIM, J., AND KIM, J. Continual learning with deep generative replay. *Advances in neural information processing systems* 30 (2017).
- [39] SHUKLA, V., MORELLI, L., TRYBALA, P., REMONDINO, F., GAN, W., YU, Y., AND WANG, X. Exploring the potential of collaborative uav 3d mapping in kenyan savanna for wildlife research. *arXiv preprint arXiv:2409.15914* (2024).
- [40] SINGH, D. K., RAI, S. N., JOSEPH, K., SALUJA, R., BALASUBRAMANIAN, V. N., ARORA, C., SUBRAMANIAN, A., AND JAWAHAR, C. Order: Open world object detection on road scenes. In *Proc. NeurIPS Workshops* (2021), vol. 1, p. 3.
- [41] WANG, L., ZHANG, X., SU, H., AND ZHU, J. A comprehensive survey of continual learning: Theory, method and application. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2024).

- [42] YANG, Z., YU, X., DEDMAN, S., ROSSO, M., ZHU, J., YANG, J., XIA, Y., TIAN, Y., ZHANG, G., AND WANG, J. Uav remote sensing applications in marine monitoring: Knowledge visualization and review. *Science of The Total Environment* 838 (2022), 155939.
- [43] YE, Q., MA, M., ZHAO, X., DUAN, B., WANG, L., AND MA, D. Add-yolo: An algorithm for detecting animals in outdoor environments based on unmanned aerial imagery. *Measurement* 242 (2025), 116019.
- [44] YU, J., MA, L., LI, Z., PENG, Y., AND XIE, S. Open-world object detection via discriminative class prototype learning. *arXiv preprint arXiv:2302.11757* (2023).
- [45] ZENKE, F., POOLE, B., AND GANGULI, S. Continual learning through synaptic intelligence. In *International conference on machine learning* (2017), PMLR, pp. 3987–3995.
- [46] ZHAO, X., MA, Y., WANG, D., SHEN, Y., QIAO, Y., AND LIU, X. Revisiting open world object detection. *IEEE Transactions on Circuits and Systems for Video Technology* (2023).
- [47] ZHENG, J., LI, W., HONG, J., PETERSSON, L., AND BARNES, N. Towards open-set object detection and discovery. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2022), pp. 3961–3970.
- [48] ZHOU, Z., YANG, Y., WANG, Y., AND XIONG, R. Open-set object detection using classification-free object proposal and instance-level contrastive learning. *IEEE Robotics and Automation Letters* 8, 3 (2023), 1691–1698.
- [49] ZHU, F., ZHANG, X.-Y., WANG, C., YIN, F., AND LIU, C.-L. Prototype augmentation and self-supervision for incremental learning. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2021), pp. 5871–5880.

- [50] ZOHAR, O., WANG, K.-C., AND YEUNG, S. Prob: Probabilistic objectness for open world object detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2023), pp. 11444–11453.
- [51] ZOU, Z., CHEN, K., SHI, Z., GUO, Y., AND YE, J. Object detection in 20 years: A survey. *Proceedings of the IEEE* 111, 3 (2023), 257–276.