



INTELIGENCIA ARTIFICIAL PARA LA PROTECCIÓN **DEL MEDIO AMBIENTE Y BIODIVERSIDAD**

Herramientas Tecnológicas para
Profesionales del Medio Ambiente

INTELIGENCIA ARTIFICIAL PARA LA PROTECCIÓN DEL MEDIO AMBIENTE Y BIODIVERSIDAD

Herramientas Tecnológicas para Profesionales del Medio Ambiente

Propósito de este estudio

Este estudio tiene como propósito describir en forma general el potencial que tiene la Inteligencia Artificial, para contribuir a resolver en forma automática diversas tareas ambientales como detección y clasificación de animales y plantas silvestres, categorización de papers y noticias sobre medio ambiente, detección de residuos marinos, monitoreo de mamíferos marinos, optimización de la gestión de residuos sólidos, etc. De forma tal de incentivar a los profesionales que investigan o trabajan en medio ambiente, a explorar el uso de la Inteligencia Artificial, para la gestión de los problemas ambientales que el país y el mundo enfrenta.

Autor

MSc. Cristian Brito Martínez, Ministerio de Medio Ambiente, Chile.

Químico Ambiental de la Universidad de Chile, Magíster en Inteligencia Artificial de la Universidad Adolfo Ibáñez y Master en Ingeniería Ambiental de la Universidad de Castilla La Mancha. Posee más de 16 años de experiencia profesional en el sector privado y público, liderando la formulación, desarrollo y ejecución de estudios/proyectos tecnológicos para la gestión de riesgos ambientales, cumplimiento ambiental, remediación ambiental y conservación de la biodiversidad.

Diagramación y Diseño

Ministerio del Medio Ambiente

Julio 2021

ÍNDICE DE CONTENIDO

1. INTRODUCCIÓN	4
2. INTELIGENCIA ARTIFICIAL	5
2.1. NIVELES DE INTELIGENCIA ARTIFICIAL	7
2.2. ¿CÓMO SE VINCULA NUESTRA VIDA CON LA INTELIGENCIA ARTIFICIAL?	8
2.3. ¿CÓMO APRENDE LA INTELIGENCIA ARTIFICIAL?	9
2.4. MACHINE LEARNING Y DEEP LEARNING	10
2.5. ¿POR QUÉ SE HA EXTENDIDO EL USO DE LA INTELIGENCIA ARTIFICIAL?	11
3. CASOS DE USO DE INTELIGENCIA ARTIFICIAL EN MEDIO AMBIENTE	12
3.1. DETECCIÓN Y CLASIFICACIÓN DE ANIMALES SILVESTRES	13
3.2. CLASIFICACIÓN DE NOTICIAS Y PUBLICACIONES CIENTÍFICAS SOBRE ASUNTOS AMBIENTALES	13
3.3. DETECCIÓN DE RESIDUOS MARINOS EN ECOSISTEMAS ACUÁTICOS	14
3.4. PREDICCIÓN DE LA CALIDAD DEL AIRE	14
3.5. SIMULACIÓN EN ECOLOGÍA	14
3.6. MONITOREO DE BALLENAS	15
3.7. PREVENCIÓN DE LA CAZA FURTIVA	15
3.8. CONTROL DE LA PESCA ILEGAL, NO DECLARADA Y NO REGLAMENTADA	15
3.9. OPTIMIZACIÓN DE LAS RUTAS DE RETIRO DE RESIDUOS SÓLIDOS	16
4. IMPLEMENTANDO INTELIGENCIA ARTIFICIAL EN MEDIO AMBIENTE	17
4.1. DEFINIR EL PROBLEMA AMBIENTAL QUE SE NECESITA RESOLVER O ESTUDIAR	18
4.2. ¿CÓMO CREAR UN MODELO DE DEEP LEARNING?	18
4.3. OBTENCIÓN DE DATOS	20
4.4. AUMENTACIÓN DE DATOS	21
4.5. ¿QUÉ ARQUITECTURA ESCOGER?	21
4.6. TRANSFER LEARNING	22
4.7. ¿QUÉ FRAMEWORK ES POSIBLE UTILIZAR?	23
4.8. ¿DÓNDE OBTENER EJEMPLOS DE CÓDIGO?	24
4.9. ¿CUANTO PODER DE COMPUTO SE REQUIERE?	24
4.10. REALIZAR ENTRENAMIENTO DEL MODELO	24
4.11. VALIDAR Y PROBAR EL MODELO	25
4.12. EFECTUAR AJUSTES FINOS AL MODELO	26
4.13. COSTOS ASOCIADOS	26
5. ESTIMACIÓN DEL IMPACTO AMBIENTAL	27
6. CONSIDERACIONES ÉTICAS	28
7. SUGERENCIAS	30
BIBLIOGRAFÍA	32
ABREVIACIONES	35

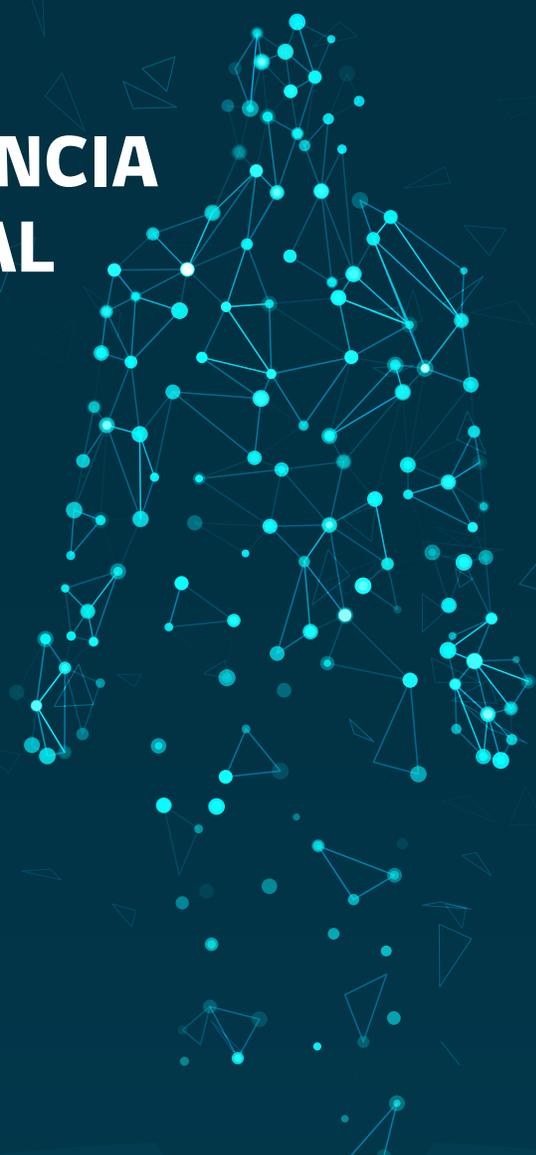
1. INTRODUCCIÓN

La humanidad enfrenta diversos problemas ambientales de carácter global como el Cambio Climático, escasez de agua dulce, contaminación del aire, pérdida de biodiversidad, contaminación de los océanos, degradación de los suelos, etc. La gravedad de estos problemas subraya la importancia de impulsar esfuerzos y estrategias de gestión que contribuyan a la protección del medio ambiente, al cuidado de los servicios ecosistémicos que la naturaleza entrega, y al uso sostenible de los recursos naturales^[1].

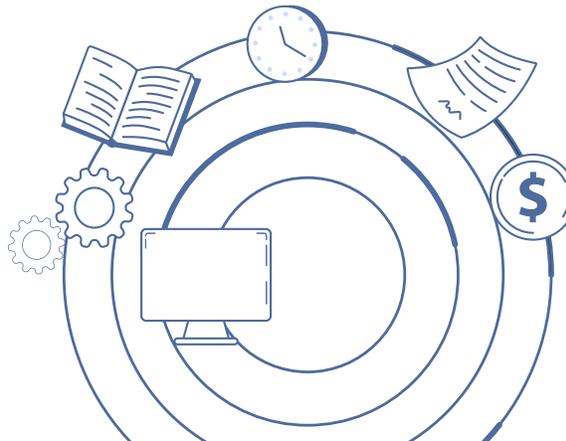
Entre las diversas tecnologías que están actualmente disponibles, la Inteligencia Artificial nos proporciona herramientas técnicas, que podemos utilizar para automatizar y hacer más eficiente la generación de información y conocimiento ambiental, a fin de estudiar, proteger y conservar los ecosistemas terrestres y marinos.



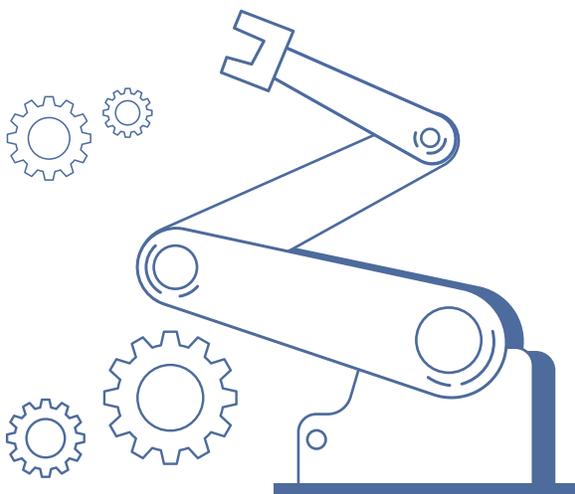
2. INTELIGENCIA ARTIFICIAL



La Inteligencia Artificial es una ciencia interdisciplinaria que incluye diversos campos de las ciencias, tecnología y de las humanidades, tales como: ciencias de la computación, neurociencia, psicología, matemática, lingüística y filosofía, entre otras^[2]. Existen varias definiciones de Inteligencia Artificial y no hay total consenso sobre los alcances y elementos que debe incluir. No obstante, para los fines de este estudio se utilizará la definición propuesta por uno de los padres de esta disciplina el Dr. Marvin Minsky, quien define a la Inteligencia Artificial como:



“UNA DISCIPLINA QUE SE ENCARGA DE CREAR MÁQUINAS PROGRAMADAS QUE SEAN CAPACES DE HACER COSAS QUE REQUIEREN LA MISMA INTELIGENCIA QUE SI FUESEN HECHAS POR HUMANOS”



En otras palabras, la Inteligencia Artificial (AI por sus siglas en Inglés), es una tecnología desarrollada por humanos, que permite a las máquinas realizar tareas que requieren decisiones inteligentes¹. En este marco la AI agrupa áreas tan diversas como el Procesamiento de Lenguaje Natural, Visión Artificial, Aprendizaje Automático o “Machine Learning”, Sistemas Expertos, Representación del Conocimiento, Agentes Inteligentes, Robótica, Optimización Metaheurística, entre otras.

¹ Para conocer más sobre inteligencia e inteligencia artificial, se recomienda leer el artículo “On the Measure of Intelligence” de François Chollet, <https://arxiv.org/abs/1911.01547>

2.1. NIVELES DE INTELIGENCIA ARTIFICIAL

La Inteligencia Artificial comenzó a desarrollarse en la década del cincuenta, en donde uno de los primeros trabajos que generó las bases de esta ciencia corresponde a la publicación de Alan Turing del paper "Computing Machinery and Intelligence" (1950), y posteriormente del "Test de Turing". Luego, Nick Bostrom, un filósofo de la Universidad de Oxford, describe tres niveles principales en el desarrollo de la Inteligencia Artificial^[2].



INTELIGENCIA ARTIFICIAL ESTRECHA (IAE)

La IAE es capaz de sobrepasar las capacidades cognitivas de los humanos en tareas muy específicas como reconocimiento de patrones en grandes bases de datos, lo que la hace especial para resolver con precisión problemas de agrupación y clasificación de texto, voz e imágenes^[2]. En las siguientes tareas se utiliza IAE **i)** conducción de autos autónomos, **ii)** reconocimiento facial, **iii)** sistemas de recomendación de productos basados en historial de navegación, **iv)** clasificación de spam, **v)** clasificación automática de fauna silvestre presente en imágenes.

INTELIGENCIA ARTIFICIAL GENERAL (IAG)

Consiste en que las máquinas podrían razonar y tener las mismas capacidades cognitivas de los humanos, lo que les permitiría aplicar el conocimiento para resolver problemas en todo tipo de tareas y en diferentes contextos. Actualmente no existe la IAG.

SÚPER INTELIGENCIA ARTIFICIAL (SIA)

La SIA teóricamente es una etapa superior a la IAG, en donde sobrepasa las capacidades cognitivas de los humanos. La humanidad no sería capaz de comprender su razonamiento y captar su conocimiento.

En virtud de las definiciones y alcances mencionados anteriormente, es necesario precisar que todas las aplicaciones actuales de Inteligencia Artificial en tareas relacionadas a medio ambiente corresponden al nivel de IAE. Luego, es importante considerar que Machine Learning (ML) y Deep Learning (DL) no son equivalentes a Inteligencia Artificial, ya que el ML es una de las ramas de la Inteligencia Artificial y el DL es a su vez un área del ML. Para poner en perspectiva las capacidades actuales de la Inteligencia Artificial y si usted desea comprender los mitos que se han generado en torno a esta ciencia. Se recomienda leer el artículo publicado en 2021 "Why AI is Harder Than We Think" de Melanie Mitchell.

2.2. ¿CÓMO SE VINCULA NUESTRA VIDA CON LA INTELIGENCIA ARTIFICIAL?

La AI está presente en muchas actividades que realizamos diariamente en el trabajo, estudio, tiempo de ocio. Por ejemplo, la predicción del texto en un motor de búsqueda en internet, las recomendaciones de productos cuando se realiza una compra en algunas plataformas de e-commerce, el sistema de reconocimiento facial de los teléfonos móviles, las recomendaciones de música en algunas aplicaciones, todos estos corresponden a aplicaciones de AI. También, existen plataformas de ciencia ciudadana como iNaturalist que utilizan AI para ayudar a identificar en forma automática las especies de animales o plantas registradas mediante fotografías por los usuarios.



2.3. ¿CÓMO APRENDE LA INTELIGENCIA ARTIFICIAL?

Las máquinas pueden aprender de tres formas, mediante aprendizaje supervisado y no supervisado y mediante aprendizaje por refuerzo. El “aprendizaje supervisado” es el más utilizado y en este caso se sabe con anterioridad qué debe aprender la máquina, por lo que es necesario proporcionarle datos (imágenes, textos, series de tiempo, etc.) con una etiqueta definida o variable a predecir. Por ejemplo, si se desea que la máquina aprenda a reconocer rinocerontes en una imagen, se deberá entregarle un conjunto de imágenes en donde aparezcan rinocerontes, de esta forma el algoritmo de Inteligencia Artificial podrá determinar las características y patrones más representativos de este tipo de animal.

En el “aprendizaje no supervisado”, se proporcionan los datos sin etiqueta a la máquina, para que descubra automáticamente y por sí misma los patrones presentes en los datos^[2]. En este caso si se le pasa a la máquina un conjunto de imágenes, esta podría agruparlas en función de las características similares que posean. En el “aprendizaje por refuerzo” la máquina completa por sí misma la tarea a realizar, conociendo con anterioridad solamente algunas reglas elementales. Luego, el supervisor interviene en forma iterativa para premiar la estrategia utilizada por la máquina en donde se obtiene un desempeño exitoso, de esta forma con cada iteración el desempeño de la máquina mejora.

Figura 1 | Ilustración del aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo.



Fuente: Adaptado a partir del original de Mesko B, et al (2020)^[2].

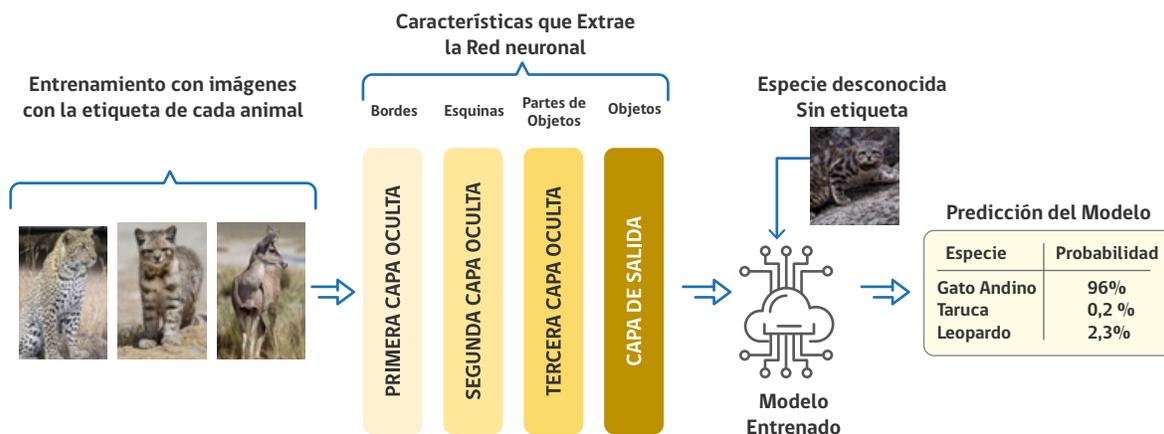
Representación visual de las formas en que aprende la Inteligencia Artificial (AI). **a)** En el aprendizaje supervisado, el supervisor sabe lo que quiere enseñarle a la AI, él define la respuesta esperada y la AI aprende como realizar la tarea. **b)** En el aprendizaje no supervisado, el supervisor no influye en el aprendizaje de la AI, pero analiza los resultados que la AI obtiene al resolver la tarea. **c)** En el aprendizaje por refuerzo, el supervisor sabe lo que quiere enseñar a la AI, pero no define la forma en que la AI debería aprenderlo. En cambio el supervisor solo entrega retroalimentación después que se completa la tarea, recompensa los resultados que a él le interesan, y le pide a la AI que desarrolle su propia estrategia para conseguir los resultados que fueron recompensados.

2.4. MACHINE LEARNING Y DEEP LEARNING

El Machine Learning o aprendizaje automático (en adelante ML) es una rama de la Inteligencia Artificial y se refiere a una categoría de algoritmos computacionales que pueden ser entrenados en forma iterativa para aprender patrones en los datos. El aprendizaje puede realizarse mediante el entrenamiento supervisado y no supervisado. Por ejemplo, desde los años noventa se han realizado investigaciones para detectar residuos marinos en forma automática mediante el empleo de algoritmos de ML como Support Vector Machine (SVM), Random Forest (RF) o Gradient Boosting Machine (GBM)². Para realizar el entrenamiento de estos algoritmos es necesario efectuar el pre-procesamiento de las imágenes, para extraer las características más representativas del objeto que se necesita detectar. Este proceso es costoso en términos de tiempo y requiere alta expertís de la persona que realizará el pre-procesamiento de las imágenes_[3, 4, 5].

El Deep Learning es a su vez un área del ML en donde los algoritmos son capaces de detectar y extraer automáticamente las características y patrones de los datos, sin la necesidad de que un experto realice esa tarea. Los algoritmos de Deep Learning (en adelante, DL) utilizan una estructura en capas de redes neuronales artificiales que se inspira en el funcionamiento de la red neuronal del cerebro humano_[6]. Las unidades de procesamiento de información se llaman neuronas, las que trabajan en forma interconectada para resolver problemas y son las que realizan la tarea de determinar los patrones más característicos presentes en los datos. Las redes neuronales tienen tres partes principales: (a) una capa de entrada que recibe los datos, (b) el núcleo de procesamiento que contiene una o más capas ocultas, y (c) una capa de salida que da el resultado de la predicción del modelo_[7].

Figura 2 | Representación idealizada de una red neuronal.

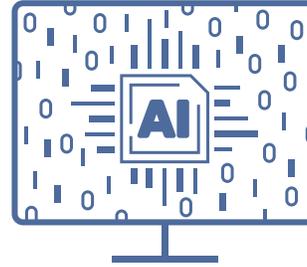


La principal desventaja del DL es que se necesitan miles de datos para realizar el entrenamiento de la red y se requiere el empleo de hardware especializado como GPUs (Graphics Processing Unit)_[8].

² RF, SVM y GBM se usan también para otro tipo de tareas como sistemas de recomendación, categorización de textos, etc.

2.5. ¿POR QUÉ SE HA EXTENDIDO EL USO DE LA INTELIGENCIA ARTIFICIAL?

La Inteligencia Artificial es una disciplina que comenzó a desarrollarse desde la década del cincuenta, por tanto, no es una ciencia nueva. No obstante, en los últimos años su uso se ha extendido considerablemente, debido a que han convergido algunos factores que facilitan el uso de la Inteligencia Artificial para resolver tareas en diferentes áreas^[9]. Entre estos factores destacamos:



a) ACCESO A BIG DATA

Actualmente existen diversas fuentes de información de acceso público y bases de “datos estructurados” (datos en Excel o similar) y “datos no estructurados” (texto, video, audio, imágenes), que están disponibles online. Algunas de estas bases de datos pueden tener miles o millones de datos como: imágenes de animales o plantas, registros del canto de aves, conjuntos de noticias, etc. Además, el amplio uso de sensores en actividades de monitoreo ambiental de la biodiversidad, calidad del aire y agua, entrega la posibilidad de acceder a miles de datos.

b) FACILIDAD DE ACCESO A HARDWARE ESPECIALIZADO

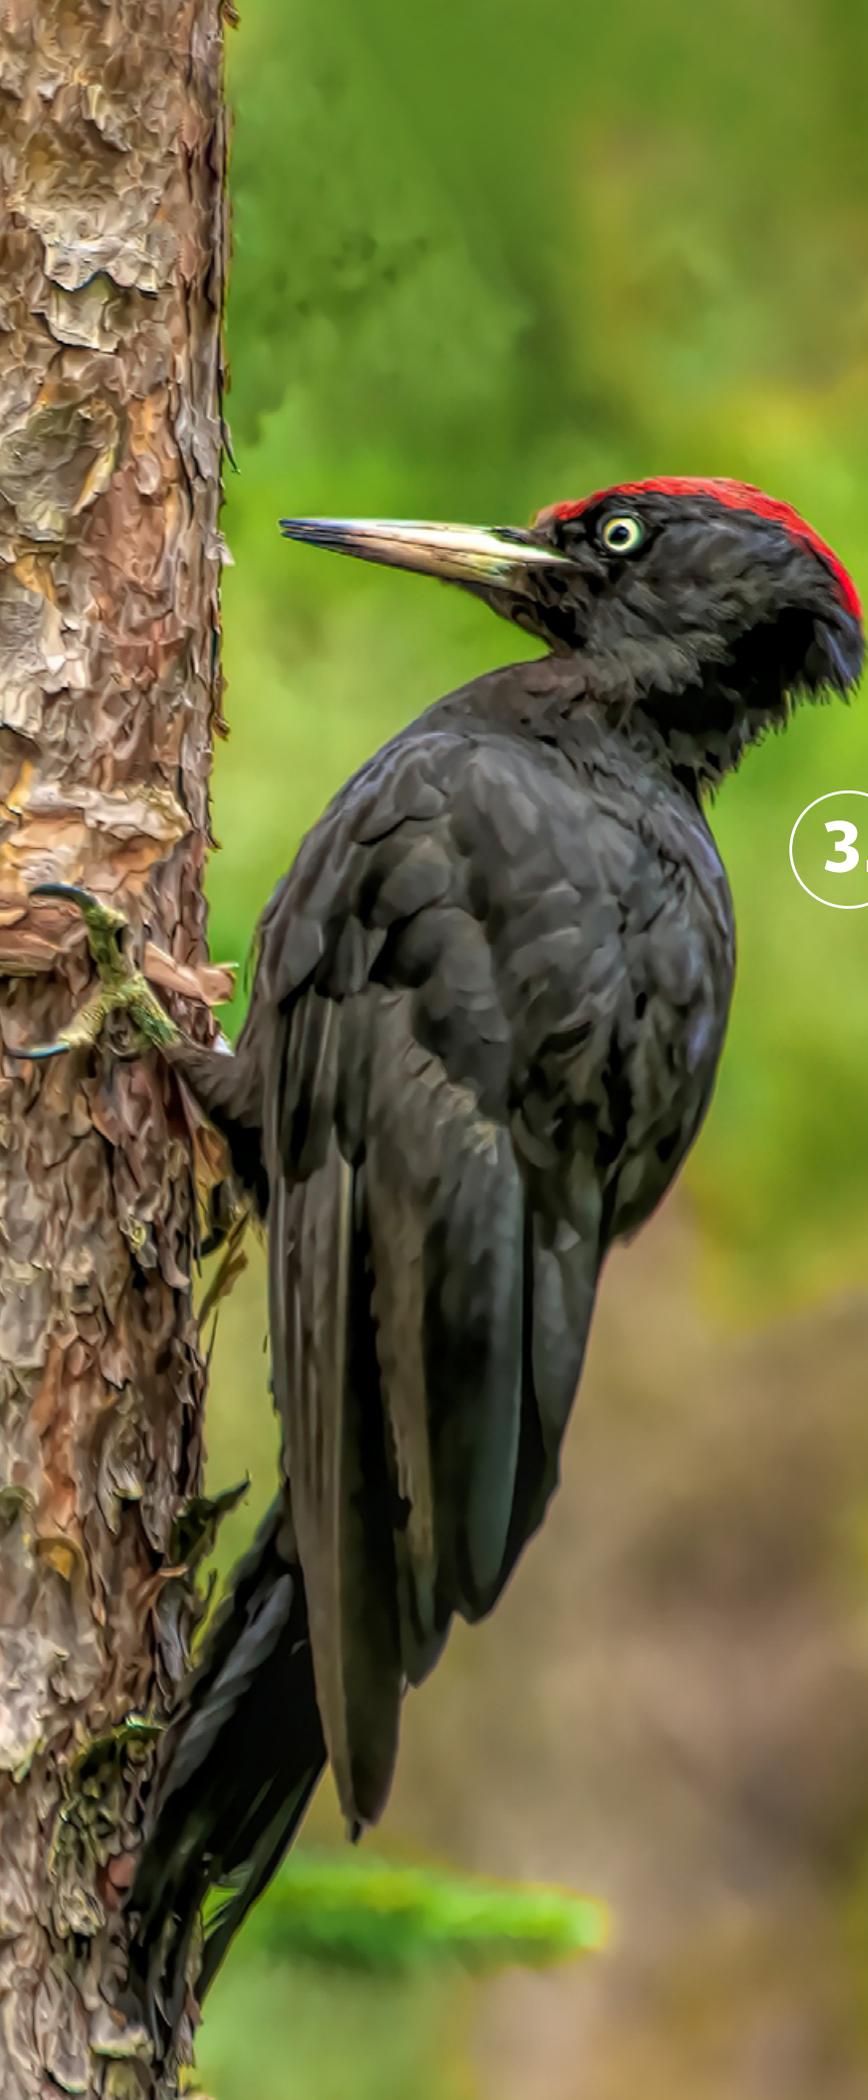
La computación en la nube concede la posibilidad de acceder en forma gratuita o a relativamente bajo precio a hardware especializado como GPUs y TPUs, las que entregan un poder de computo que permite reducir sustantivamente el tiempo necesario para procesar grandes volúmenes de datos y entrenar los modelos de Inteligencia Artificial.

c) DISPONIBILIDAD DE SOFTWARE LIBRE

El software libre ha permitido acelerar y democratizar el uso de la Inteligencia Artificial^[9]. Frameworks como TensorFlow, Pytorch, SpaCy, NLTK o Scikit-Learn permiten reducir el tiempo que se necesita para programar los algoritmos de ML, DL o NLP, y de esta forma centrar los esfuerzos en el desarrollo y pruebas de los modelos.

d) ALGORITMOS MEJORADOS

El DL ha ido sustituyendo paulatinamente a los algoritmos tradicionales de ML, en tareas asociadas a visión artificial como es la detección y clasificación de objetos presentes en imágenes. Las redes neuronales Convolucionales (CNN) están siendo ampliamente utilizadas en estudios ambientales como la detección y clasificación de plantas y animales silvestres.



**3. CASOS DE
USO DE
INTELIGENCIA
ARTIFICIAL
EN MEDIO
AMBIENTE**

A continuación se describen algunos ejemplos de casos documentados en donde se ha utilizado Inteligencia Artificial para realizar estudios ambientales o para implementar tareas como clasificación de animales silvestres, categorización de textos científicos o modelar sistemas complejos como las relaciones cazador-presa en un ecosistema.

3.1. DETECCIÓN Y CLASIFICACIÓN DE ANIMALES SILVESTRES

Se han utilizado ampliamente algoritmos de DL para estudios de biodiversidad y conservación ambiental, en donde se requiere detectar, clasificar, contar y etiquetar en forma automática diferentes especies de animales silvestres como leones, cebras, tigres, elefantes, entre otros. Los que están presentes en imágenes y videos capturados mediante cámaras trampa o vehículos aéreos no tripulados^[10]. Utilizar DL en este tipo de estudios ambientales permite reducir el tiempo requerido para analizar y procesar grandes cantidades de datos. Además, permite mejorar la precisión de las labores de clasificación de animales, ya que estos modelos en determinadas condiciones pueden alcanzar una precisión mayor al 95% en este tipo de tareas^[11, 12].



3.2. CLASIFICACIÓN DE NOTICIAS Y PUBLICACIONES CIENTÍFICAS SOBRE ASUNTOS AMBIENTALES

El Procesamiento del Lenguaje Natural (Natural-Language Processing o NLP) es un área de la Inteligencia Artificial que permite que los computadores puedan comprender el lenguaje humano para realizar tareas complejas sobre diferentes objetos lingüísticos como palabras, frases, discursos^[13]. El NLP puede ser utilizado para realizar en forma automática tareas de comprensión y categorización de grandes volúmenes de información no estructurada como textos, noticias, papers científicos, etc. En este marco, el NLP se puede utilizar para categorizar noticias que traten sobre un determinado tema ambiental de interés como Cambio Climático, Biodiversidad, Residuos Marinos, Capa de Ozono, entre otros. También se podría utilizar NLP para categorizar publicaciones científicas que traten sobre el éxito de programas de reintroducción de especies^[14]. En estos casos el NLP tiene la ventaja que permite categorizar grandes volúmenes de información en forma más rápida y precisa que las personas.

3.3. DETECCIÓN DE RESIDUOS MARINOS EN ECOSISTEMAS ACUÁTICOS

Los residuos marinos como botellas y bolsas plásticas, equipos y artes de pesca, envases de comida, plásticos de un solo uso, entre otros. Producen impactos negativos en el medio ambiente, economía y bienestar de las personas. Por lo que, se considera que constituyen uno de los problemas más graves que afectan al medio marino, junto con el cambio climático, la acidificación de los océanos, y la pérdida de biodiversidad^[15]. Los residuos marinos pueden producir impactos en la biodiversidad, causando daños físicos en peces, mamíferos (ballenas, delfines, focas), reptiles (tortugas marinas) y aves, por enredo o ingestión. Lo que provoca laceraciones, asfixia e inanición, produciendo la muerte de individuos de estas especies^[16,17,18,19]. Algoritmos de DL pueden ser utilizados para detectar en forma automática residuos marinos presentes en ecosistemas acuáticos como playas, ríos, humedales, lagos, arrecifes, etc. Para desarrollar e implementar programas más eficientes de limpieza y recolección de este tipo de residuos.

.....

3.4. PREDICCIÓN DE LA CALIDAD DEL AIRE

La calidad del aire es un asunto ambiental de preocupación en la mayoría de las grandes ciudades urbanas del mundo, ya que una mala calidad del aire puede generar efectos en el bienestar de las personas y en el medio ambiente. Predecir la calidad del aire es un asunto complejo en donde intervienen variables como la meteorología, geografía, fuentes de emisión fijas y móviles, entre otros. Algoritmos de DL como las redes neuronales recurrentes (RNN) y en particular la Unidad de Memoria a Corto Plazo (LSTM), pueden ser utilizadas para predecir la concentración de contaminantes como material particulado MP2,5 y MP10 y gases como el Dióxido de Azufre (SO₂) o Compuestos Orgánicos Volátiles (COVs). Estos algoritmos pueden ser entrenados con los datos recolectados por estaciones de monitoreo local, para generar modelos que realicen predicciones en diferentes periodos de tiempo^[20].

.....

3.5. SIMULACIÓN EN ECOLOGÍA

La simulación basada en agentes (Agent-Based Modelling, ABM) es un método computacional que representa entidades autónomas e individuales (agentes), cada una con comportamientos dinámicos, adaptativos y características heterogéneas que interactúan entre sí y con su entorno. Estas interacciones generan resultados emergentes que se pueden utilizar para estudiar y analizar cuantitativamente sistemas complejos como un ecosistema^[21]. ABM es una herramienta que se usa para estudios en ecología desde una escala individual hasta el nivel de poblaciones y comunidades^[22]. Por ejemplo, se puede utilizar ABM para investigar como responderá la vida silvestre a posibles cambios en las condiciones ambientales de sus hábitats.

3.6. MONITOREO DE BALLENAS

El monitoreo de cetáceos es una tarea de alta complejidad y difícil de implementar, debido a que este tipo de animales se desplaza largas distancias en el océano. El uso de sensores remotos y empleo de imágenes satelitales de alta resolución puede ser una solución para el monitoreo en el océano de ballenas. No obstante, estos métodos producen conjuntos masivos de datos que son difíciles de clasificar en forma manual. Modelos de DL pueden ser utilizados para realizar esta tarea en forma semi-automática, en donde el modelo de DL selecciona las imágenes que tienen alta probabilidad de contener ballenas, las que después pueden ser verificadas por biólogos marinos u otros profesionales^[23].

.....

3.7. PREVENCIÓN DE LA CAZA FURTIVA

En el mundo existen varias especies que se encuentran en peligro de extinción como el Rinoceronte, Gorila de montaña, Chinchilla, Tigre de Sumatra, entre otros³. Entre los factores que influyen en esta situación se encuentra la caza ilegal a la que se ven expuestas estas especies. La Inteligencia Artificial se puede utilizar para el procesamiento de datos obtenidos de observaciones en terreno, imágenes satelitales y registro de incidentes, para predecir las posibles rutas que utilizarán los cazadores furtivos y para determinar los lugares donde se producirán nuevos ataques^[24, 25]. Esta información puede ser utilizada por las policías u organismos encargados de la protección de la fauna silvestre, para optimizar los recursos destinados a la vigilancia, prevención de ataques y protección de estas especies.

.....

3.8. CONTROL DE LA PESCA ILEGAL, NO DECLARADA Y NO REGLAMENTADA

Este tipo de pesca es una de las mayores amenazas para los ecosistemas marinos, causa impactos negativos en la economía de algunos países y en la seguridad alimentaria. El empleo de sensores remotos en combinación con algoritmos específicos de ML y DL, pueden utilizarse para analizar en tiempo real las embarcaciones, predecir trayectorias y determinar movimientos sospechosos⁴. Con el propósito de informar a las autoridades correspondientes la ubicación de estas embarcaciones, para que realicen en forma más eficiente su control y fiscalización.

³ <https://www.iucnredlist.org/search?query=GORILLA&searchType=species>

⁴ <https://www.oceanmind.global>

3.9. OPTIMIZACIÓN DE LAS RUTAS DE RETIRO DE RESIDUOS SÓLIDOS

En muchas ciudades u operaciones mineras, la planificación de las rutas de retiro de residuos sólidos e industriales, se realiza en forma manual. Esta situación genera ineficiencias en el uso de activos, ya que muchas veces los camiones pasan a retirar residuos en puntos donde no se ha completado la capacidad de almacenamiento de los contenedores de residuos, y no se atiende adecuadamente los lugares donde si se están generando mayores cantidades de residuos. La Inteligencia Artificial puede utilizarse para predecir los puntos más probables de alta generación de residuos y algoritmos de optimización metaheurística se pueden emplear par diseñar mejores rutas de retiro.

En la **Tabla 1** se muestra un resumen de algunas tareas ambientales, en donde se han utilizado técnicas de Inteligencia Artificial. También se muestra un ejemplo de la exactitud alcanzada y la cantidad de datos que se utilizaron para el entrenamiento de los diferentes algoritmos empleados.

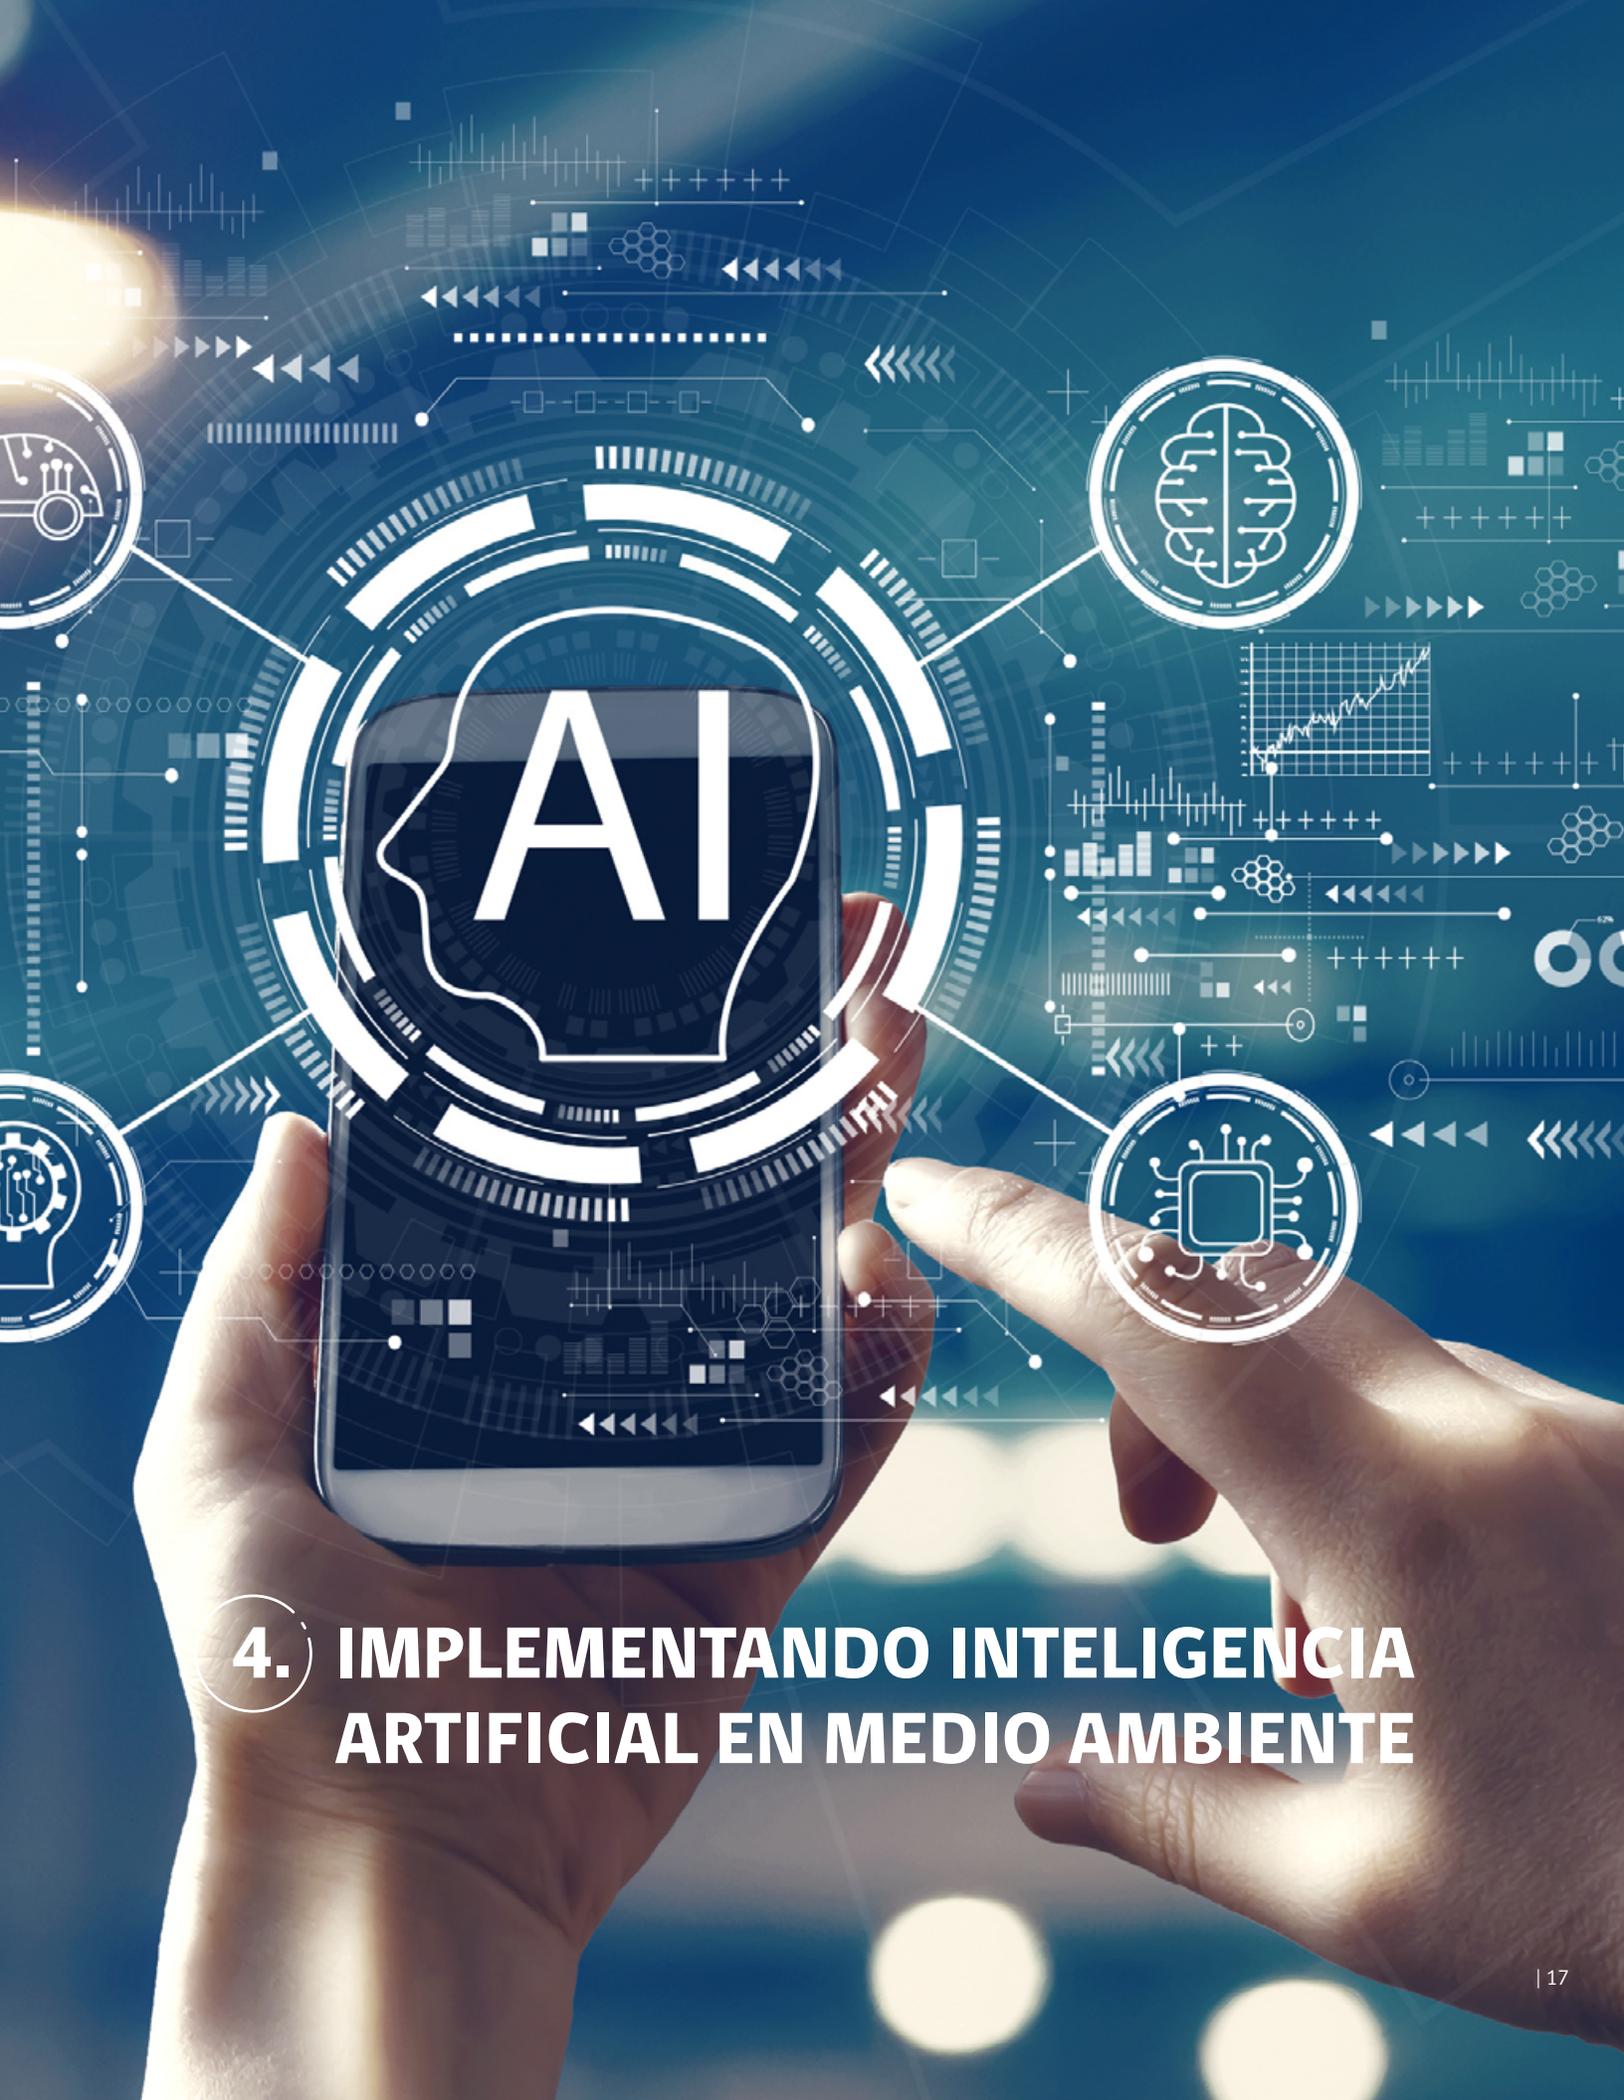
Tabla 1 | Tareas ambientales en las que se han aplicado técnicas de Inteligencia Artificial.

Aplicación	Técnica- Algoritmo	Exactitud ⁵ alcanzada	Nº datos utilizado en Entrenamiento	Referencia
Clasificación de Ciervo Canadiense	DL-CNN	0,99	185 K	Tabak et al, (2018)
Clasificación de Alces	DL-CNN	0,98	25 K	
Clasificación de Aves	DL-CNN	0,95	61 K	
Clasificación de Tejón	DL-CNN	0,95	10,8 K	Chen at al, (2019)
Detección de Mosquito Tigre	DL-CNN	0,92	6,68 K	Armin et al, (2021)
Detección de Residuos Marinos	ML-SVM	0,75	NR	Goncalves et al, (2020)
Detección de Residuos Marinos	ML-RF	0,72	NR	
Predicción del Estado de Conservación de Plantas	ML-RF	0,73 - 0,82	150 K	Espíndola et al, (2018)
Predicción del comportamiento de focas	ML-GBM	0,74 - 0,8	64,6 K ⁶	Ladds et al, (2016)
Cuantificación de la belleza de paisajes	DL-CNN	0,66	200 K	Illushka et al
Predicción de la calidad del agua	DL-LSTM-CNN	No aplica	35 K	Barzegar et al, (2020)
Predicción de la calidad del aire	DL-LSTM	No aplica	43,8 ⁷	Chang et al, (2020)
Determinación del éxito de planes de reintroducción de especies	NLP-RNN	No aplica	4,3 K	Van Houtan et al, (2020)
Simulación de la exposición a sustancias químicas peligrosas	ABM-Netlogo	No aplica	No aplica	Brandon et al, (2020)

⁵ Cuando los datos están desbalanceados la métrica "exactitud" puede no ser la mejor para evaluar el rendimiento de un modelo de ML o DL

⁶ Datos obtenidos a partir de grabaciones en video y datos de acelerómetros

⁷ Serie de tiempo de 5 años x 365 días x 24 horas)



4. IMPLEMENTANDO INTELIGENCIA ARTIFICIAL EN MEDIO AMBIENTE

A continuación se describen los pasos generales que se recomienda seguir para implementar técnicas de Inteligencia Artificial al estudio o solución de problemas ambientales.

4.1. DEFINIR EL PROBLEMA AMBIENTAL QUE SE NECESITA RESOLVER O ESTUDIAR

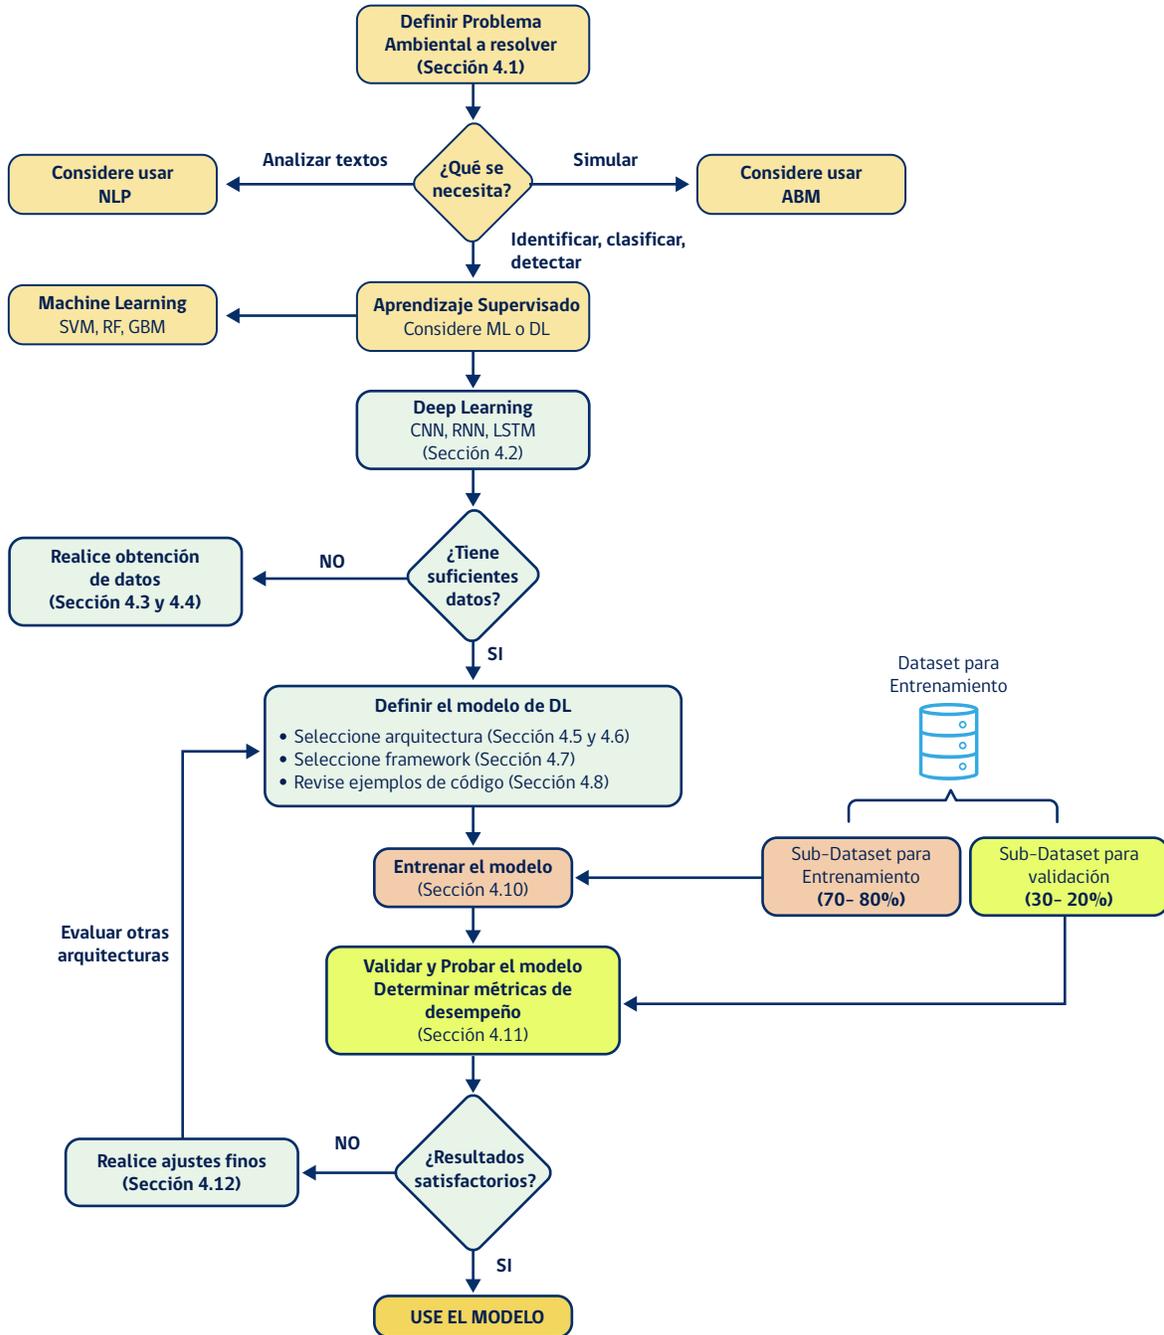
Antes de implementar un modelo de Inteligencia Artificial en medio ambiente, es importante que el profesional ambiental haya realizado el ejercicio de determinar si el problema que necesita estudiar o resolver, puede ser abordado mediante técnicas de Inteligencia Artificial, y si el uso de estas tecnologías es lo más apropiado. En el capítulo 3 “Casos de Uso de Inteligencia Artificial en Medio Ambiente” se han descrito casos de uso reales, por lo que si usted necesita resolver un problema parecido. Escoger la Inteligencia Artificial podría ser una buena alternativa. Luego para poner en perspectiva la aplicación de esta tecnología en Medio Ambiente, se utilizará como ejemplo la aplicación de Deep Learning a la tarea de clasificar animales en imágenes.

4.2. ¿CÓMO DESARROLLAR UN MODELO DE DEEP LEARNING?

A continuación se describen en términos generales los principales pasos que se recomienda seguir para implementar DL (aprendizaje supervisado), a la clasificación de animales silvestres. En donde se requiere lo siguiente:

- Obtener y preparar los datos que serán utilizados (sección 4.3 y 4.4).
- Seleccionar una arquitectura y componentes de la red neuronal (sección 4.5 y 4.6).
- Elegir un framework y las librerías que se utilizarán. Las que se usan para implementar la arquitectura seleccionada anteriormente (sección 4.7).
- Desarrollar el modelo, haciéndolo desde cero o utilizando un modelo pre-entrenado (sección 4.8).
- Entrenar el modelo con un subconjunto (generalmente 70%) del total de datos disponibles (sección 4.10).
- Validar y testear el modelo realizando pruebas con un subconjunto (generalmente 15%) del total de datos disponibles para validación y el otro 15% de los datos para test. El rendimiento del modelo se puede evaluar calculando métricas como la precisión (la proporción de resultados correctos en todos los resultados positivos), el recall (la proporción de resultados correctos), y el F1, que es la media armónica de precisión y recall (sección 4.11).
- Realizar ajustes finos al modelo, en donde se deberán hacer pruebas para determinar el efecto que tiene en los resultados, la variación de los hiperparámetros del modelo (tasa de aprendizaje, número de batch, etc.), utilizar más datos, cambiar la arquitectura de la red o de las diferentes capas (sección 4.12).

Figura 3 | Diagrama de flujo de las etapas requeridas para crear un modelo de DL.



Fuente: Diagrama adaptado a partir del original propuesto por Christin S, et al (2019)^[31]

4.3. OBTENCIÓN DE DATOS

Actualmente existen bases de datos públicas en donde se puede compartir, encontrar y obtener millones de imágenes y datos sobre diversas especies de animales y plantas, para entrenar modelos de Inteligencia Artificial. En las plataformas de ciencia ciudadana iNaturalist (<https://inaturalist.org>), GBIF (<https://gbif.org>), eBird (<https://ebird.org>) es posible encontrar imágenes sobre aves, mamíferos, insectos y otras especies. También en el sitio LilaScience (<http://lila.science>) se pueden encontrar diversas bases de datos con imágenes de animales etiquetados. En la plataforma online Movebank (<https://movebank.org>) se puede obtener, archivar y compartir datos sobre el movimiento de animales a través de diferentes áreas geográficas del mundo.

En la Encyclopedia of life (<https://eol.org>) se pueden encontrar más de doce millones de atributos (imágenes, mapas, etc.) para cerca de dos millones de especies de animales, plantas, hongos, protistas y bacterias. Además, en el sitio DataWorld (<https://data.world/datasets/environment>) se pueden obtener datos de diferentes áreas ambientales como suelos, calidad del aire, agua, etc.

Si se dispone de datos, pero no se cuenta con el conocimiento o con los recursos adecuados para etiquetarlos, es posible solicitar apoyo online en plataformas de ciencia ciudadana como Zooniverse (<https://zooniverse.org>), en donde es posible crear proyectos pidiendo a las personas que contribuyan a identificar y etiquetar los conjuntos de datos.^[26] Finalmente es preciso mencionar que las plataformas GitHub y Kaggle también incluyen varias bases de datos sobre medio ambiente que pueden ser consultadas.

Tabla 2 | **Algunas bases de datos con información ambiental⁸**

Nombre de la Base de Datos	Tipo de Datos	Nº de datos disponibles	URL
Plant Trait Database	Registros de 279875 especies de plantas	11,85 M	https://www.try-db.org
Snapshot Serengeti	Imágenes de cámaras trampa de 61 especies de animales silvestres	7,1 M	http://lila.science/datasets/snapshot-serengeti
WCS Camera Trap	Imágenes de cámaras trampa de 675 especies de animales silvestres	1,4 M	http://lila.science/datasets/wcscameratraps
North American Camera Trap Images	Imágenes de cámaras trampa de 28 especies de animales silvestres	3,7 M	http://lila.science/datasets/nacti
HKH Glacier Mapping	Imágenes satelitales de Glaciares del Himalaya	14,1 K	https://github.com/krisrs1128/glacier_mapping
BirdVox	Registro de audios de aves	179 K	https://wp.nyu.edu/birdvox/codedata/#datasets
Pasadena Urban Trees	Imágenes de árboles etiquetadas	30 K	http://www.vision.caltech.edu/registree/publications-and-dataset.html
FishBase	Imágenes y referencias sobre peces	55 K	https://www.fishbase.in
NABirds	Imágenes de 400 especies de aves etiquetadas	48 K	https://dl.allaboutbirds.org/nabirds
Stanford Dogs	Imágenes de 120 razas de perros	20,5 K	http://vision.stanford.edu/aditya86/ImageNetDogs/
Caltech-UCSD Birds 200	Imágenes de 200 especies de aves	6 K	http://www.vision.caltech.edu/visipedia/CUB-200.html
Oxford Flowers	Imágenes de 119 especies de flores	>11 K	https://www.robots.ox.ac.uk/~vgg/data/flowers/
Animals with attributes	Imágenes de 50 especies de animales con atributos	37,3 K	https://cvml.ist.ac.at/AwA2/

⁸ M = millón K = miles

4.4. AUMENTACIÓN DE DATOS

Si no ha sido posible obtener suficientes imágenes para entrenar el modelo de DL, debido a que para el problema ambiental que se desea estudiar o resolver, no existen bases de datos públicas o no se ha generado la información que se requiere. Existe la posibilidad de incrementar en forma artificial el número de imágenes disponibles, mediante técnicas de visión artificial para aumentación de datos (data augmentation). Para una misma imagen, estas técnicas permiten realizar aumentos mediante transformaciones geométricas (rotaciones, recortes, etc.) y del espacio de color (inclusiones de ruido, cambio en el brillo y contraste, entre otras). El empleo de estas técnicas da origen a nuevas imágenes, pero con la misma etiqueta que la imagen original^[27,28].

4.5. ¿QUÉ ARQUITECTURA ESCOGER?

El tipo de arquitectura que se deberá seleccionar está íntimamente relacionada a la tarea que se desea realizar y a los datos que se tienen disponibles. En este caso, el propósito es clasificar animales silvestres en imágenes mediante DL y aprendizaje supervisado, por lo que lo más apropiado es utilizar redes neuronales Convolucionales (Convolutional Neural Networks, CNN). Por el contrario, si el objetivo fuera predecir la calidad del aire y se tuvieran datos en forma de series de tiempo, la arquitectura más recomendada a utilizar sería LSTM.

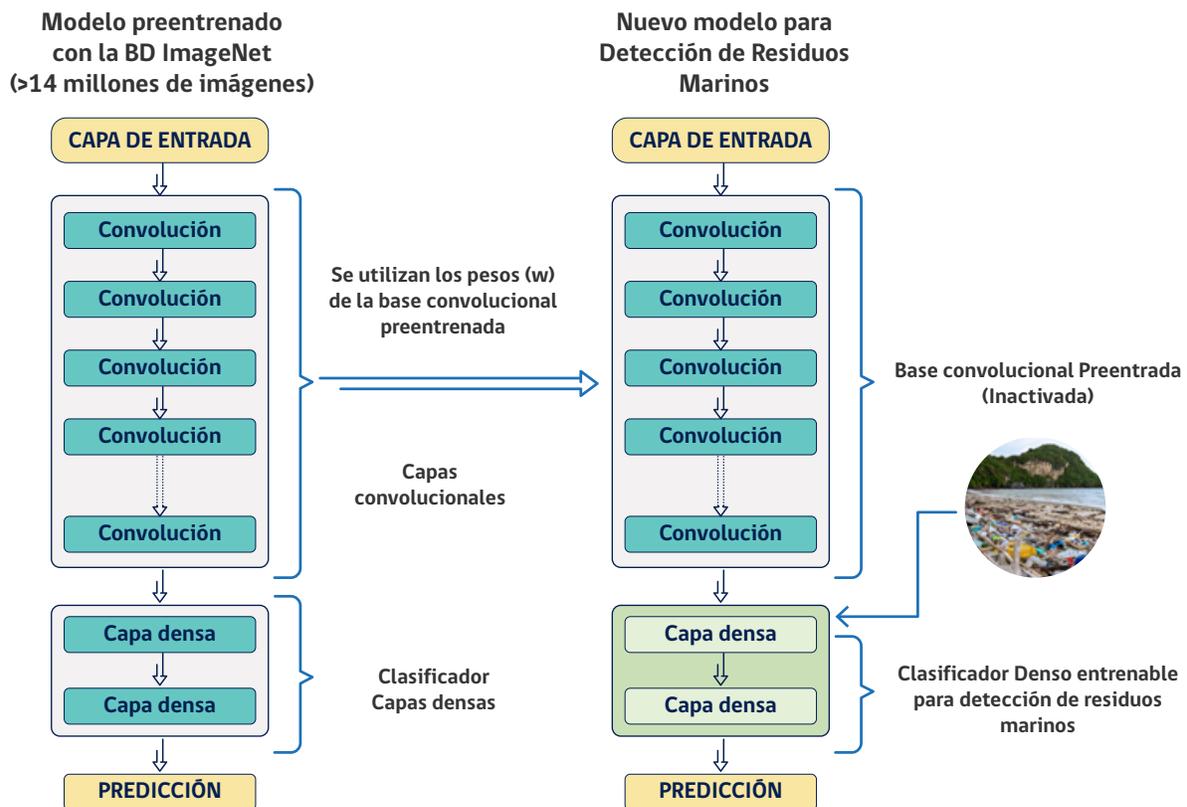
Las CNN contienen tres tipos de capas neuronales, i) capas Convolucionales que realizan la extracción de características de las imágenes mediante el empleo de diferentes filtros o kernels, ii) capas de pooling las que realizan la reducción de la dimensionalidad de las imágenes, iii) capas Fully Connected que es donde se realiza la clasificación de las imágenes^[29].



4.6. TRANSFER LEARNING

La dificultad de utilizar CNN para estudios en medio ambiente tiene que ver con que estas redes necesitan una gran cantidad de imágenes para ser entrenadas, lo que resulta ser un problema cuando se requiere usar CNN para detectar y clasificar objetos sobre los cuales existe muy poca información, como puede ser el caso de algunos problemas de clasificación de animales, para los que existen muy pocos datos disponibles. No obstante, esta dificultad puede ser resuelta utilizando técnicas de “transfer learning” la que consiste en emplear el conocimiento adquirido por un modelo previamente entrenado con millones de imágenes de diferentes clases, para resolver una tarea de carácter más general, pero adaptarlo a resolver el problema específico de interés para el que se dispone de pocos datos_[30]. El uso de CNN en combinación con técnicas de “transfer learning” para tareas de clasificación de objetos, puede alcanzar una precisión entre 85 y 95%_[11,12]. La mayor parte de los frameworks descritos en la **Tabla 3** permiten utilizar modelos que han sido previamente entrenados como Xception, InceptionV3, resNet50, VGG16, VGG19, etc.

Figura 4 | Representación del proceso de “transfer learning”



4.7. ¿QUÉ FRAMEWORK ES POSIBLE UTILIZAR?

Los algoritmos de inteligencia artificial se pueden programar en varios lenguajes de programación como Python, R, Julia, Matlab, Java, C++. Para facilitar la tarea de desarrollo e implementación de modelos de DL, ML y NLP, existen bibliotecas de software de código abierto como TensorFlow, Pytorch, Keras, NLTK, SpaCy, que ofrecen funciones ya desarrolladas para lenguajes como Python y R. Esto facilita el desarrollo y reduce el tiempo necesario para implementar estos modelos en la solución de problemas ambientales. Todos estos frameworks ofrecen diferentes características en términos de facilidad de uso, recursos disponibles, soporte de arquitectura, personalización o soporte de hardware. Por lo tanto, se debe prestar mucha atención a la selección de las herramientas que mejor se adapten a las necesidades de cada uno^[31].

Tabla 3 | Principales Framework y librerías utilizadas en Inteligencia Artificial

Framework / Librería	Lenguaje Compatible	Áreas de Uso	URL
NLTK	Python, R	NLP	https://www.nltk.org
SpaCy	Python, R	NLP	https://spacy.io
Tensorflow	Python, C/C++, R, Java, Go, Julia	ML, DL	https://www.tensorflow.org
Keras	Python, R	ML, DL, NLP	https://keras.io
Microsoft CNTK	C#, C++, Python	ML, DL	https://docs.microsoft.com/en-us/cognitive-toolkit/
Pytorch	Python	DL	https://pytorch.org
Scikit-learn	Python, R	ML, NLP	https://scikit-learn.org/stable/
Gensim	Python, R	NLP	https://pypi.org/project/gensim/
MATLAB + Deep Learning Toolbox	Matlab	DL	https://www.mathworks.com
Deeplearning4j	Java, Scala, Clojure, Kotlin	DL	https://deeplearning4j.org
Netlogo	Netlogo	ABM	http://ccl.northwestern.edu/netlogo/
Pandas	Python, R	ML, DL	https://pandas.pydata.org/about/
Numpy	Python, R	ML, DL	https://numpy.org

4.8. ¿DÓNDE OBTENER EJEMPLOS DE CÓDIGO?

Existen diversas plataformas online en donde se puede consultar y obtener ejemplos de código, que han sido elaborados por otras personas, para desarrollar diversos modelos de ML, DL, NLP, etc. En sitios como GitHub (<https://github.com>), Kaggle (<https://kaggle.com>), NetLogo (<https://ccl.northwestern.edu/netlogo/>), se puede encontrar una amplia variedad de códigos y documentación que puede servir como punto de partida o material de referencia, para desarrollar nuevos modelos y adaptarlos al problema ambiental que se desea estudiar o resolver mediante algoritmos de Inteligencia Artificial.

Al momento de escribir esta publicación existen disponibles algunas aplicaciones y plataformas web, en donde es posible generar código en forma automática para tareas de clasificación de imágenes, detección de objetos y tareas de procesamiento de lenguaje natural (<https://traingenerator.jrieke.com>). Además, en el sitio GitHub se ha publicado "Copilot" (<https://copilot.github.com>), herramienta desarrollada por OpenAI que facilita la generación y edición de código para tareas de Inteligencia Artificial.

4.9. ¿CUANTO PODER DE COMPUTO SE REQUIERE?

El proceso de entrenamiento de modelos de ML o DL puede requerir una alta capacidad de computo y tiempo de ejecución del modelo (desde horas a varios días), especialmente cuando en el entrenamiento se utilizan grandes cantidades de datos o cuando el modelo necesitará aprender millones de parámetros^[32]. En este proceso se pueden utilizar computadores dotados con una unidad de procesamiento central (CPU) o con unidades de procesamiento de gráficos (GPU). Una CPU generalmente tiene de 2 a 8 núcleos, que se refieren a módulos de procesamiento individuales en un dispositivo, las GPU tienen miles de núcleos que están optimizados para ejecutar operaciones aritméticas paralelas y son ideales para ejecutar modelos de DL^[33]. Por lo que, las GPU pueden reducir los tiempos de ejecución y entrenamiento del modelo. Si no se cuenta con un computador que tenga una GPU, es posible utilizar recursos online basados en computación en la nube, en donde existen plataformas que ofrecen alternativas gratuitas y planes de pago, para ejecutar algoritmos de ML y DL en línea. Una vez que se logra obtener la precisión deseada en las predicciones del modelo, este se puede guardar y reutilizar repetidamente.

4.10. REALIZAR ENTRENAMIENTO DEL MODELO

Para entrenar una red neuronal normalmente se utiliza entre el 70-80% de los datos disponibles y se requiere emplear algoritmos de optimización⁹. Durante este proceso, la red neuronal optimiza sus parámetros internos para adecuarse de mejor forma a los datos de entrada^[34]. Una vez que la red está entrenada, podrá hacer predicciones de imágenes que no están etiquetadas, en donde será capaz de determinar la probabilidad de que una imagen corresponda a una determinada especie animal (**ver figura 2**). Luego, el modelo entrenado, tendrá que ser validado y probado. En donde se deberán evaluar algunas métricas para determinar el desempeño del modelo.

⁹ Para conocer más de este proceso de optimización se recomienda investigar sobre los algoritmos "Backpropagation" y "Stochastic gradient descent".

4.11. VALIDAR Y PROBAR EL MODELO

Para validar y probar el desempeño del modelo desarrollado, se utiliza entre el 30–20% de los datos disponibles. Además, es importante utilizar métricas que permitan comparar los resultados obtenidos. Las métricas más utilizadas corresponden a precisión, exactitud, recall y F1^[35, 36, 37]. Si se toma como ejemplo la clasificación del “Gato Andino” presente en imágenes de una cámara trampa, se tendrán los siguientes escenarios, **i)** el modelo predice que una imagen corresponde a un Gato Andino, cuando en realidad no lo es, esto sería un Falso Positivo (FP), **ii)** el modelo predice que una imagen no corresponde a un Gato Andino cuando en realidad si lo es, esto sería un Falso Negativo (FN), **iii)** el modelo predice que una imagen es un Gato Andino y en realidad si lo es, esto sería un positivo verdadero (TP), **iv)** el modelo predice que una imagen no corresponde a un Gato Andino y en realidad no lo es, esto sería un verdadero negativo (TN).

Tabla 4 | Métricas para evaluar el desempeño de un modelo de DL o ML

Métrica	Características	Formula de Cálculo
Precisión	Del total de las predicciones positivas, se evalúa cuanto de eso era realmente cierto	$\text{precisión} = \frac{TP}{TP + FP}$
Recall	Determina la cantidad de predicciones positivas sobre todo lo que era realmente positivo	$\text{recall} = \frac{TP}{TP + FN}$
F1	Combina las medidas de precisión y recall en un sólo valor	$F1 = 2 \times \frac{\text{precisión} \times \text{recall}}{\text{precisión} + \text{recall}}$
Exactitud	Representa el porcentaje de predicciones en donde el modelo ha acertado sobre el total de datos	$\text{exactitud} = \frac{TP + TN}{TP + TN + FP + FN}$

Cuando los datos están desbalanceados la métrica “exactitud” puede no ser la mejor para evaluar el rendimiento de un modelo de ML o DL. Luego, las métricas precisión, recall y F1 son más representativas, independiente que los datos estén desbalanceados o no.

4.12. EFECTUAR AJUSTES FINOS AL MODELO

Esta actividad requiere un alto grado de conocimiento técnico, por lo que si ha llegado hasta esta etapa, necesita ajustar el modelo para mejorar su desempeño y no sabe cómo hacerlo. Es recomendable buscar apoyo y colaborar con un profesional especialista en Inteligencia Artificial para que lo oriente sobre los tipos de ajustes que se podrían realizar. Por ejemplo, se pueden hacer pruebas agregando capas convolucionales, aumentar la cantidad de kernels, incluir nuevas capas de pooling y drop out, realizar pruebas con diferentes tasas de aprendizaje y distintos algoritmos de optimización de los parámetros de la red neuronal (Adam, Stochastic Gradient Descent, Mini-Batch gradient descent, etc.), o simplemente aumentar el número de épocas (epochs).

4.13. COSTOS ASOCIADOS

Diversos aspectos se deben considerar para estimar los costos asociados al desarrollo y entrenamiento de un modelo DL. No obstante, en términos generales el entrenamiento de un modelo de DL cuesta en promedio US\$ 1 por cada 1.000 parámetros^[38]. Luego, se debe tener presente que estos costos son solo referenciales y no consideran los costos asociados a la obtención y procesamiento de los datos necesarios para el entrenamiento del modelo.





5. ESTIMACIÓN DEL IMPACTO AMBIENTAL

El desarrollo de modelos de Inteligencia Artificial para la solución de problemas ambientales puede consumir una cantidad importante de energía eléctrica en la etapa de entrenamiento de los algoritmos. Esto implica que el desarrollo de modelos basados en DL o ML tiene un costo ambiental y un potencial impacto climático^[39]. Para determinar las emisiones de dióxido de carbono equivalente ($\text{CO}_{2\text{eq}}$), asociadas a estos procesos, se puede utilizar la calculadora de emisiones ML CO_2 impact¹⁰.

Por ejemplo, si en el entrenamiento de un modelo para clasificar animales silvestres se utilizan algoritmos de DL y se emplean 26 horas de cómputo en la nube (Ej: Google Colab), utilizando una GPU Nvidia Tesla K80 y región de cómputo Southamerica-east1. Las emisiones estimadas asociadas al entrenamiento del modelo serían de 1,56 kg de $\text{CO}_{2\text{eq}}$. Sin embargo, si con las mismas condiciones anteriores se usa como región de cómputo Asia-south1 las emisiones serían de 7,18 kg de $\text{CO}_{2\text{eq}}$.

En virtud de lo anterior, se recomienda que al momento de elegir una plataforma en la nube para entrenar y desarrollar los modelos, se tenga en consideración las potenciales emisiones de dióxido de carbono, y de ser posible se utilicen los datacenter de regiones en donde la matriz eléctrica tiene una componente principal de energías renovables.

¹⁰ <https://mlco2.github.io/impact/#compute>

6. CONSIDERACIONES ÉTICAS



En términos generales los problemas ambientales actuales, nos deben hacer cuestionar los valores con que hemos construido la sociedad. En este marco desarrollar un modelo de Inteligencia Artificial para la solución de problemas ambientales, requiere tomar las precauciones necesarias, que permitan evitar que el modelo desarrollado pueda generar impactos negativos (directos e indirectos), en el medio ambiente, servicios ecosistémicos y en el bienestar de las personas. Por lo que se recomienda poner en perspectiva y analizar lo siguiente:

Sesgo (BIAS)

No existe una definición única para el concepto de sesgo o BIAS en Inteligencia Artificial. Luego, si se considera la definición de sesgo en estadística de la Real Academia de la Lengua Española¹¹, quién lo define como:

“ERROR SISTEMÁTICO EN EL QUE SE PUEDE INCURRIR CUANDO AL HACER MUESTREOS O ENSAYOS SE SELECCIONAN O FAVORECEN UNAS RESPUESTAS FRENTE A OTRAS”

Se puede inferir que el sesgo se podría generar cuando se han seleccionado y utilizado datos con poca variabilidad para entrenar los algoritmos de Inteligencia Artificial. En virtud de lo anterior y tomando como ejemplo la clasificación de animales mediante DL, para reducir el sesgo, es recomendable que al confeccionar la base de datos se utilicen imágenes del animal a clasificar con los siguientes atributos:

- i) Animales en sus diferentes etapas de desarrollo (individuos juveniles y adultos),
- ii) Machos y hembras en diferentes ubicaciones y posiciones, en distintos tipos de terreno, con diferentes condiciones meteorológicas e imágenes capturadas durante las cuatro estaciones del año,
- iii) Diferente iluminación y calidad de las imágenes,

Además, se recomienda que el profesional de medio ambiente que desee desarrollar e implementar un modelo de Inteligencia Artificial, dedique un tiempo adecuado a explorar y considerar en su proyecto, las cualidades de justicia, responsabilidad, transparencia y ética (Fairness, Accountability, Transparency and Ethics)^[40, 41, 42] descritas en la **Tabla 6**.

Tabla 5 | Algunas publicaciones que abordan consideraciones éticas para la aplicación de la Inteligencia Artificial en asuntos relacionados a Medio Ambiente.

Ámbito del Estudio	Nombre del Estudio	Referencia
Ética	Responsible AI for Conservation	Wearn et al. (2019)
Ética, BIAS	Towards Ethical Deployment of AI for Conservation Systems	Kaesler-Chen et al. (2019)
BIAS	Disability, Bias, and AI	Whittaker et al. (2019)
Ética, Responsabilidad	How to address data privacy concerns when using social media data in conservation science	Di Minin et al. (2021)

¹¹ <https://dle.rae.es/sesgo>

7. SUGERENCIAS



La Inteligencia Artificial proporciona herramientas tecnológicas que pueden resultar muy útiles para automatizar y hacer más eficientes diversos procesos en labores de investigación en biodiversidad, ecología o en la solución de diversos problemas ambientales. Luego, en virtud de lo expuesto y descrito en esta publicación se sugiere lo siguiente:

- Definir bien el problema que se desea resolver, los objetivos que se espera lograr, y analizar la opción de utilizar métodos tradicionales. Si se requiere mejorar la eficiencia y se necesita automatizar procesos manuales y que pueden ser repetitivos, la Inteligencia Artificial podría ser una buena elección.
- Recolectar y preparar los datos ambientales que serán empleados para entrenar los algoritmos de Inteligencia Artificial que se ha decidido utilizar. Si no dispone de suficientes datos, considere utilizar bases de datos públicas o plataformas ambientales de ciencia ciudadana como las descritas en la sección 4.3.
- Si dispone de pocos datos y ha decidido utilizar Deep Learning, considere emplear técnicas de “data augmentation” y “transfer learning”, ya que como se ha explicado en esta publicación, ambas técnicas permiten reducir la necesidad de contar con grandes volúmenes de datos.
- Considerar formar un equipo interdisciplinario con especialistas en Medio Ambiente y en Inteligencia Artificial, quienes pueden ayudar a desarrollar modelos robustos y más ad-hoc al problema ambiental que se desea resolver o estudiar.
- Considerar para el modelo a desarrollar las cualidades descritas en la **Tabla 6**.

Tabla 6 | Cualidades que debería tener un modelo de Inteligencia Artificial aplicado en Medio Ambiente

Cualidad	Descripción
Justicia (Fairness)	La tecnología desarrollada tiene que ser justa, no discriminar, y tiene que dar garantías que se tratará con equidad a las personas y a los diferentes elementos del medio ambiente.
Responsabilidad (Accountability)	Se debe tener claridad a quién se le atribuirá la responsabilidad por el uso de la tecnología desarrollada.
Transparencia (Transparency)	Es importante que los modelos desarrollados se puedan explicar en un lenguaje no técnico, a un público que no es especialista en la materia.
Ética (Ethics)	La tecnología desarrollada no debe ser empleada para causar por acción o inacción impactos negativos en el bienestar de las personas y daños ambientales a otras especies y/o ecosistemas.

BIBLIOGRAFÍA

1. IPBES (2019): Global assessment report on biodiversity and ecosystem services of the Intergovernmental Science–Policy Platform on Biodiversity and Ecosystem Services. E. S. Brondizio, J. Settele, S. Díaz, and H. T. Ngo (editors). IPBES secretariat, Bonn, Germany.
2. Mesko B, Görög M, (2020). A short guide for medical professionals in the era of artificial intelligence. *npj Digital Medicine* 3:126.
3. Olden, J. D., Lawler, J. J., & Poff, N. L. (2008). Machine learning methods without tears: A primer for ecologists. *The Quarterly Review of Biology*, 83(2), 171–193.
4. Ge, Z., Shi, H., Mei, X. et al. Semi-automatic recognition of marine debris on beaches. *Sci Rep* 6, 25759 (2016).
5. Biermann, L., Clewley, D., Martínez-Vicente, V. et al. Finding Plastic Patches in Coastal Waters using Optical Satellite Data. *Sci Rep* 10, 5364 (2020).
6. Richardson, K., Asmutis-Silvia, R., Drinkwin, J., Gilardi, K.V.K., Giskes, I., Jones, G. et al. (2019). Building evidence around ghost gear: Global trends and analysis for sustainable solutions at scale. *Marine Pollution Bulletin* 138: 222–229.
7. Munari, C., Corbau, C., Simeoni, U. and Mistri, M., (2015). Marine litter on Mediterranean shores: analysis of composition, spatial distribution and sources in north-western Adriatic beaches.
8. Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E (2018) Deep Learning for Computer Vision: A Brief Review. *Comput Intell Neurosci* 2018:1–13.
9. Harnessing Artificial Intelligence for the Earth, (2018). PwC.
10. Lamba, A., Cassey, P., Segaran, R. R., & Koh, L. P. (2019). Deep learning for environmental conservation. *Current Biology*, 29(19), R977–R982.
11. Miao, Z., Gaynor, K.M., Wang, J. et al. Insights and approaches using deep learning to classify wildlife. *Nature Sci Rep* 9, 8137 (2019).
12. Wang J, perez L, The Effectiveness of Data Augmentation in Image Classification using Deep Learning (2017), arXiv:1712.04621.
13. Atkinson J. (2020). *Analítica Textual: Una Introducción a la Ciencia y Aplicaciones del Análisis de Información no Estructurada*. Pag 46.
14. Van Houtan, K. S., Gagne, T., Jenkins, C. N., & Joppa, L. (2020). Sentiment Analysis of Conservation Studies Captures Successes of Species Reintroductions. *Patterns*, 100005.
15. UNEP 2019. *Global Environmental Outlook 6*.
16. Stelfox, M., Hudgins, J. and Sweet, M. (2016). A review of ghost gear entanglement amongst marine mammals, reptiles and elasmobranchs. *Marine Pollution Bulletin* 111, 6–17.
17. Ryan, P. (2018). Entanglement of birds in plastics and other synthetic materials. *Marine Pollution Bulletin* 135, 159–164.
18. Woods, J.S., Rødder, G. and Verones, F. (2019). An effect factor approach for quantifying the entanglement impact on marine species of macroplastic debris within the life cycle impact assessment. *Ecological Indicators* 99, 61–66.
19. Thiel M, Luna-Jorquera G, Álvarez-Varas R, Gallardo C, Hinojosa IA, Luna N, Miranda-Urbina D, Morales N, Ory N, Pacheco AS, Portflitt-Toro M and Zavalaga C (2018) Impacts of Marine Plastic Pollution From Continental Coasts to Subtropical Gyres—Fish, Seabirds, and Other Vertebrates in the SE Pacific. *Front. Mar. Sci.* 5:238.
20. Yue-Shan Chang, Hsin-Ta Chiao, Satheesh Abimannan, Yo-Ping Huang, Yi-Ting Tsai, Kuan-Ming Lin. (2020). An LSTM-based aggregated model for air pollution forecasting, *Atmospheric Pollution Research*, Volume 11, Issue 8, Pages 1451–1463.

21. McLane, A. J., Semeniuk, C., McDermid, G. J., & Marceau, D. J. (2011). The role of agent-based models in wildlife ecology and management. *Ecological Modelling*, 222(8), 1544–1556.
22. Bo Zhang, Donald L DeAngelis, An overview of agent-based models in plant biology and ecology, *Annals of Botany*, Volume 126, Issue 4, 14 September 2020, Pages 539–557.
23. Borowicz, A., Le, H., Humphries, G., Nehls, G., Höschle, C., Kosarev, V., & Lynch, H. J. (2019). Aerial-trained deep learning networks for surveying cetaceans from satellite imagery. *PLOS ONE*, 14(10), e0212532.
24. Brown, Dane & Schormann, Daniel. (2019). Poacher Detection and Wildlife Counting System.
25. Gholami, Shahrzad & Mc Carthy, Sara Marie & Dilkina, Bistra & Plumptre, Andrew & Tambe, Milind & Singh, Rohit & Nsubuga, Mustapha & Mabonga, Joshua & Driciru, Margaret & Wanyama, Fred & Rwetsiba, Aggrey & Okello, Tom & Enyel, Eric. (2019). Stay Ahead of Poachers: Illegal Wildlife Poaching Prediction and Patrol Planning Under Uncertainty with Field Test Evaluations.
26. Swanson, A., Kosmala, M., Lintott, C., Simpson, R., Smith, A., & Packer, C. (2015). Snapshot Serengeti, high-frequency annotated camera trap images of 40 mammalian species in an African savanna. *Scientific Data*, 2, 150026.
27. <https://towardsdatascience.com/data-augmentation-techniques-in-python-f216ef5eed69>. Revisado en octubre de 2020.
28. Shorten, C., Khoshgoftaar, T.M. A survey on Image Data Augmentation for Deep Learning. *J Big Data*, 60 (2019).
29. Tu, Xinyuan & Lai, Kenneth & Yanushkevich, Svetlana. (2018). Transfer Learning on Convolutional Neural Networks for Dog Identification. 357–360. 10.1109/ICSESS.2018.8663718.
30. Chen R, Little R, Mihaylova L, Delahay R, Cox R. Wildlife surveillance using deep learning methods. *Ecol Evol*. 2019;9:9453–9466
31. Christin S, Hervet É, Lecomte N. Applications for deep learning in ecology. *Methods Ecol Evol*. 2019;10:1632–1644
32. Chollet, F. (2016). Xception: Deep learning with depthwise separable convolutions. arXiv:1610.02357 [Cs]. Retrieved from <http://arxiv.org/abs/1610.02357>
33. Nickolls, J., and Dally, W. J. (2010). The GPU computing era. *IEEE Micro* 30, 56–59.
34. Lecun- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature* 521, 436–444.
35. Goutte, C., & Gaussier, E. (2005). A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation. *Advances in Information Retrieval*, 345–359.
36. D. M. Powers, "Evaluation: from precision, recall and Fmeasure to ROC, informedness, markedness and correlation," *Journal of machine learning research*, vol. 2, no. 1, 2011, pp. 37– 63.
37. Vakili, Meysam & Ghamsari, Mohammad & Rezaei, Masoumeh. (2020). Performance Analysis and Comparison of Machine and Deep Learning Algorithms for IoT Data Classification.
38. Future Today Institute (2021). 2021 Tech Trends Report; Artificial Intelligence, Pag 30.

39. Lacoste A, Schmidt V, Luccioni A, Dandres T, (2019). Quantifying the Carbon Emissions of Machine Learning, arXiv:1910.09700v2
40. Buolamwini, Joy, and Timnit Gebru. "Gender shades: Intersectional accuracy disparities in commercial gender classification." Conference on Fairness, Accountability and Transparency. 2018
41. Zhang, Brian Hu, Blake Lemoine, and Margaret Mitchell. "Mitigating unwanted biases with adversarial learning." Proceedings of the AAAI/ACM Conference on Artificial Intelligence, Ethics, and Society (AIES) (2018)
42. Bolukbasi, T.; Chang, K.-W.; Zou, J. Y.; Saligrama, V.; and Kalai, A. T. 2016. Man is to computer programmer as woman is to homemaker? debiasing word embeddings. In Advances in Neural Information Processing Systems,

ABREVIACIONES

ABM: Agent Based Modeling

AI: Inteligencia Artificial

BD: Base de datos

CPU: Central Processing Unit

CNN: Convolutional Neural Network

CO_{2eq}: Dióxido de carbono equivalente

DL: Deep Learning

GBM: Gradient Boosting Machine

GPU: Graphics processing unit

ML: Machine Learning

NLP: Natural Language Processing

RF: Random Forest

RM: Residuos Marinos

SVM: Support Vector Machine

TPU: Tensor Processing Unit



INTELIGENCIA ARTIFICIAL PARA LA PROTECCIÓN **DEL MEDIO AMBIENTE Y BIODIVERSIDAD**

Herramientas Tecnológicas para
Profesionales del Medio Ambiente