

ARTÍCULO DE REVISIÓN

Aprendizaje Automático como herramienta para el manejo integrado de recursos naturales en un contexto de cambio climático

*Machine Learning as Tool for the Integrated Management
of Natural Resources in a Climate Change Context*

Erick Armando Sedeño Bueno

erick@cimac.cu • <https://orcid.org/0000-0001-8333-5188>

CENTRO DE INVESTIGACIONES DE MEDIO AMBIENTE DE CAMAGÜEY, CUBA

Julio Madera Quintana

julio.madera@reduc.edu.cu • <https://orcid.org/0000-0001-5551-690X>

UNIVERSIDAD DE CAMAGÜEY, CUBA

Recibido: 2022-04-29 • *Aceptado: 2022-06-30*

RESUMEN

El manejo de recursos naturales en un contexto del cambio climático necesario para lograr un desarrollo sostenible en las comunidades y del medio ambiente, necesita de herramientas tecnológicas que impulsen los análisis en pro de la toma de decisiones. El Aprendizaje Automático como herramienta para programar máquinas para un aprendizaje supervisado o no supervisado por distintos algoritmos, permite entrenar sistemas para la cambiante situación espacio-temporal y panorama desigual. Entendiendo sus fundamentos y modelos de entrenamiento y aprendizaje, puede utilizarse para clasificar o predecir según datos de entrada, generando decisiones de soporte. Por esto la actual vinculación del Aprendizaje Automático con el manejo de los recursos naturales y el medio ambiente es de vital importancia y relevancia, y una revisión en cuanto a sus aplicaciones y fundamentos se presenta en el actual escrito.

PALABRAS CLAVE: Aprendizaje automático; cambio climático; gestión integrada de recursos naturales.

ABSTRACT

The management of natural resources in the context of climate change, necessary to achieve sustainable development in communities and the environment, needs technological tools that promote analysis in favor of decision-making. Machine learning as a tool to program machines for supervised or unsupervised learning by different algorithms, allows training systems for the changing space-time situation and uneven panorama. By understanding its fundamentals and training and learning models, it can be used to classify or predict based on input data, generating support decisions. For this reason, the current link of Machine Learning with the management of natural resources and the environment is of vital importance and relevance, and a review regarding its applications and foundations is presented in the current writing.

KEYWORDS: *Machine learning, climate change, integrated management of natural resources.*

INTRODUCCIÓN

Los constantes avances en el área de las tecnologías de la información y la comunicación (TIC) extendieron su alcance a diferentes áreas. Esto hace que se establezca un ritmo elevado de obtención de información (*Big Data*), la cual, administrada y procesada debidamente, permiten adquirir un gran volumen de datos, útil para la toma de decisiones. Para este propósito se requiere de la introducción de técnicas específicas que permitan operar con los mismos y obtener de ellos información.

En la actualidad, las limitaciones que impone el cambio climático junto con la creciente sobre explotación de los recursos naturales a nivel mundial, hacen que muchas investigaciones busquen dar soluciones a este tipo de problemáticas y que estas sirvan de soporte para la toma de decisiones por parte de todos los actores responsables en el tema, y en un sentido más amplio que contribuyan a un uso responsable del medio ambiente.

El Aprendizaje Automático podría convertirse en la tecnología que puede dar este gran salto en el manejo de los recursos naturales y el medio ambiente, en un contexto de cambio climático, al lograr comprender, aprender y responder, diferentes situaciones basadas en el aprendizaje para contrarrestar la pérdida y degradación de recursos naturales, formar parte de los sistemas de alerta temprana, y contribuir de manera elevada a un desarrollo sostenible de los territorios.

Para ello, se necesita de un estudio previo de las diferentes aplicaciones de esta herramienta relacionada con la gestión de elementos relacionados con el medio ambiente y otros, que

permitan visualizar las oportunidades y bondades de la herramienta. Por tanto, el objetivo del trabajo está encaminado a realizar una profunda revisión bibliográfica sobre la temática, para exponer el uso de esta herramienta y su factibilidad en la gestión de los recursos naturales y la biodiversidad, en un contexto de cambio climático.

METODOLOGÍA

Se realizó una revisión bibliográfica de un total de 43 artículos científicos y libros sobre la temática, de ellos 7 nacionales y 36 internacionales, 29 de ellos en los últimos cinco años.

Se utilizaron los métodos histórico lógico para develar los antecedentes de la temática y su evolución hasta la actualidad y el Método de análisis y síntesis para el análisis y selección de la información relevante, lo cual permitió obtener un estado del arte del Aprendizaje Automático y su aplicación a la gestión integrada de recursos naturales en un contexto de cambio climático, para luego proponer su uso en Cuba.

DESARROLLO

El deterioro de los recursos naturales y el calentamiento global ponen en riesgo la vida como se la conoce hoy en el planeta. Las leyes que dominan la naturaleza conforman un sistema, y como tal podemos en alguna medida tratar de entenderlas. La comprensión de los fenómenos naturales y antropogénicos que provocan tales cambios deben ser abordados desde un nuevo paradigma de análisis e interpretación. Cada día se desarrollan nuevos sistemas de recolección y monitoreo de datos, que van desde las mediciones más comunes meteorológicas hasta la información enviada por sensores instalados en lugares de mucho interés ambiental, como el aire, satélites o en el mar. En esta explosión en los datos es donde entra a jugar su papel fundamental la inteligencia artificial, y dentro de ella, el Aprendizaje Automático. El mismo permitirá hacer mejor uso de la información científica que facilitará adaptarnos mejor y mitigar estos efectos adversos del cambio climático.

Lo ideal es conformar un sistema que pueda comportarse de manera inteligente, a través de los datos y que sea capaz de resolver problemas del mismo modo que lo hacen los humanos, en base a la experiencia y al conocimiento. Aquí es donde el aprendizaje automático, como parte de la Inteligencia Artificial (IA) juega un importante rol a través de las tecnologías computacionales, la matemática, la lógica y la filosofía, estudia la creación y diseño de sistemas capaces de resolver problemas cotidianos por sí mismos, utilizando como paradigma la inteligencia humana.

Es de prever que con el uso de recursos tecnológicos puede ser posible lograr más medios eficientes de combatir la degradación ambiental no solo a nivel local, sino a nivel mundial. En este sentido, el desarrollo de la tecnología ha permitido hoy en día poder contar con las buenas prácticas de Aprendizaje Automático.

El término *Machine Learning* traducido del inglés al español tiene las siguientes connotaciones: aprendizaje automático (AA), aprendizaje automatizado o aprendizaje de máquinas, el aprendizaje automático, como término, no fue propuesto por un solo autor, sino que es sugerido años después de la investigación con la IA.

Flach (2012) concibe el aprendizaje automático como el estudio sistemático de algoritmos y sistemas con el fin de mejorar su conocimiento o desempeño a través de la experiencia.

De igual forma, ha sido definido como el campo científico que le confiere a máquinas la habilidad de aprender a través de la programación, el proceso de aprendizaje tiene por lo general cuatro tipos diferentes de algoritmos, no supervisado, supervisado, semi-supervisado y aprendizaje de refuerzo. Este explora el estudio y construcción de algoritmos que puedan no sólo aprender, sino igualmente hacer predicciones sobre los datos (Ge *et al.*, 2017).

El Aprendizaje Automático describe una clase de algoritmos que no necesitan ser explícitamente programados *a priori* y son muy eficaces para aprender y hacer predicciones a partir de patrones en los datos (Goodfellow, Bengio, and Courville, 2016). Por ser estos enfoques buenos en predecir respuestas complejas de diversos tipos de datos, el Aprendizaje Automático es cada vez más relevante en la era moderna, especialmente cuando los avances en la detección y la computación permiten obtener datos a tasas y escalas extraordinarias (Farley *et al.*, 2018; Lausch, Schmidt, and Tischendorf 2015; Rode *et al.*, 2016). A pesar de la superposición entre los modelos del aprendizaje automático y los modelos estadísticos clásicos, hay motivaciones para aplicar estos enfoques. Los modelos de aprendizaje automático suelen centrarse en la predicción, mientras que los modelos estadísticos clásicos enfatizan la prueba de hipótesis y la cuantificación de la incertidumbre (Breiman, 2001; Donoho, 2017).

Como resultado de estas diferencias en la motivación, los modelos de aprendizaje automático son adecuados para predecir relaciones matizadas y no lineales a partir de grandes conjuntos de datos de alta resolución (Olden, Joy, and Death, 2004), mientras que los modelos estadísticos clásicos (por ejemplo, regresión lineal) son adecuados para maximizar la información de conjuntos de datos pequeños y cuidadosamente seleccionados (Hampton *et al.*, 2013).

En el aprendizaje supervisado, se presentan datos con entradas de ejemplo y las salidas correspondientes, el objetivo es construir una regla general que asigne entradas a salidas. En ciertos casos, las entradas solo pueden estar disponibles parcialmente con algunos de los objetivos, faltan salidas o se dan solo como retroalimentación a las acciones en un entorno dinámico (refuerzo aprendizaje). En el entorno supervisado, la experiencia adquirida (modelo entrenado) se utiliza para predecir las salidas faltantes para los datos de prueba.

En el aprendizaje no supervisado, no hay distinción entre el entrenamiento y los conjuntos de pruebas con datos sin etiquetar.

Entre los modelos de aprendizaje más comunes tenemos (Liakos *et al.*, 2018):

- **Regresión:** es un modelo de aprendizaje supervisado, con el objetivo de predecir una variable de salida de acuerdo a las variables de entrada conocidas.
- **Agrupación (*clustering*):** es típica del modelo de aprendizaje no supervisado, utilizado para encontrar agrupaciones naturales de datos.

- **Modelos Bayesianos:** son modelos gráficos probabilísticos dentro del aprendizaje supervisado, cuyo análisis está dentro del contexto de inferencia bayesiana, y puede resolver problemas de clasificación o regresión.
- **Árboles de decisión:** para este modelo el conjunto de datos se organiza en subpoblaciones homogéneas y al mismo tiempo se genera un gráfico de árbol asociado. Cada nodo interno es una comparación por pares, y cada rama el resultado de la comparación, los nodos de hoja son la decisión final o predicción tomada.
- **Redes Neuronales Artificiales (ANN, por sus siglas en inglés):** están inspiradas en la funcionalidad del cerebro humano, emulando funciones como la cognición, generación de patrones, aprendizaje y toma de decisiones, a partir de sus miles de millones de neuronas. Estas redes neuronales artificiales son una simplificación de la red neuronal biológica y son un modelo supervisado usado principalmente en problemas de regresión y clasificación, disponiéndose de nodos por capas, una capa de entrada donde los datos son introducidos al sistema, una o más capas ocultas en las cuales se lleva a cabo el aprendizaje y una capa de salida que da la decisión o predicción. Los algoritmos de aprendizaje más utilizados son las redes de función de base radial, algoritmos de perceptrón, *backpropagation*, la back-propagation resiliente, algoritmos de contrapropagación, sistemas de inferencia difusa neuro-adaptativa, *autoencoder*, XY- fusión, redes Hopfield, perceptrón multicapa, mapas autoorganizados, máquinas de aprendizaje extremo, red neuronal de regresión generalizada, redes neuronales de conjunto, entre otras.
- **Support Vector Machine:** son un clasificador binario que construye un hiperplano de separación lineal para clasificar las instancias de los datos, utilizadas para realizar clasificación, regresión y agrupamiento, ocupándose principalmente de problemas de sobreajuste. Entre los más utilizados está la regresión de vectores de soporte, la máquina de vectores de soporte de mínimos cuadrados y la máquina de vectores de soporte de algoritmo de proyección sucesiva.
- **Modelos de aprendizaje conjunto:** su objetivo es mejorar el rendimiento predictivo de un aprendizaje estadístico, basándose en que cada conjunto entrenado representa una hipótesis única, los sistemas de clasificación múltiple permiten hibridar hipótesis no inducidas. Están los *Random Forest*, técnica de refuerzo, *adaboost*, algoritmo de agregación o embolsado de *bootstrap*.

Aprendizaje Automático surge a la par de las tecnologías *Big Data*, dando nuevas oportunidades para desentrañar, cuantificar y comprender procesos intensivos con datos en entornos naturales (Liakos *et al.*, 2018), lo que llega en un momento muy oportuno, debido a los constantes impactos negativos generados sobre la biodiversidad y los recursos naturales en un escenario de cambio climático. La complejidad de los problemas ambientales está dada en cuestiones que son difíciles de entender, particularmente en lo que respecta a los riesgos ambientales (Molinero and Leal, 2018).

La aplicación de Aprendizaje Automático en el manejo de los recursos naturales va de la mano de sensores para captar la mayor cantidad de datos que aporten robustez para entrenar el

sistema, y actuadores que permitan responder en base a predicciones e inferencias, o bien sistemas de alerta que faciliten actuar y se vuelvan más rentables y faciliten, frente a una gran cantidad de datos, una mejora de varios sectores de la sociedad, revolucionando la vida humana.

Muchas han sido las acciones del manejo de recursos naturales que se han visto beneficiadas con las aplicaciones del aprendizaje automático

El agua es uno de los principales recursos y es de vital importancia en la vida humana y un elemento fundamental en el desarrollo, el cual influye en el entorno, tanto en el ambiente natural, como en las esferas productivas y sociales. Aplicaciones de aprendizaje automático han logrado con éxito plantear modelos hidrometeorológicos y en algunos casos modelos relacionados con la optimización de recursos, maquinarias y procesos, los que empíricamente requieren de más tiempo y mayor inversión y representan un ahorro sustancial en tiempo y medios económicos, siendo esta la pauta para una nueva revolución orientada a la inteligencia artificial y sus aplicaciones (Vargas-Crispin *et al.*, 2021).

El uso de imágenes satelitales y su interpretación por medio de aprendizaje automático se ha extendido, dada la disponibilidad de imágenes y los algoritmos cada vez más eficiente de esta tecnología. Por ejemplo, en cuanto a la vegetación, aplicaciones de Aprendizaje Automático han permitido identificar, clasificar y cuantificar niveles de estrés en las plantas a través del análisis de imágenes en cuanto a colores y formas. Igualmente, mediante imágenes disponibles en *Copernicus*, se han podido hacer clasificaciones de la vegetación de cualquier ciudad en el mundo, logrando detectar zonas verdes en las ciudades, posteriormente calcular el porcentaje de vegetación y la cantidad de zonas verdes de acuerdo a los patrones establecidos (Posada Valcárcel, 2020). Por su parte el análisis de la cubierta vegetal ha sido objeto de estudio utilizando estas técnicas de la inteligencia artificial, en particular el aprendizaje automático, y con una gran variedad de campos de aplicación como en la detección de la cobertura vegetal en yacimientos mineros (Parra Muñoz, 2020), análisis de cambio en la cobertura boscosa (Morales Martínez, 2020), análisis de imágenes satelitales de la tierra y datos geoespaciales para obtener modelos que clasifiquen la vegetación (Posada Valcárcel, 2020). Por otra parte, a través de imágenes satelitales *LandSat* y mediante el empleo de Aprendizaje Automático, se han obtenido resultados relevantes en el manejo del recurso bosque, lo que ha demostrado la eficacia en el uso de esta herramienta, que va más allá del análisis del propio recurso y aporta elementos que pueden ayudar en previsiones sobre incendios forestales (Campos Santelices, 2017), así como en la predicción del contaminante atmosférico PM 2.5 (Pedraza Camelo, n.d.).

Sus aplicaciones también se introducen al marco de la actividad productiva, especialmente en la agricultura.

Los algoritmos de clasificación y regresión del aprendizaje automático se ajustan para realizar predicciones, utilizando datos de los cultivos y del clima, todo encaminado a la toma de decisiones más apropiadas. Liakos *et al.*, (2018) realizaron una revisión de aplicaciones de aprendizaje automático donde encontraron que esta herramienta se ha utilizado principalmente en predicciones de rendimiento y detección de enfermedades para manejo de cultivos agua y suelo.

Por medio del algoritmo *Random Forests* (RF), adaptado a las técnicas del Mapeo Digital del Suelo, se ha analizado la variación del Stock de carbono mediante el uso de perfiles y su estandarización, a la vez que, por medio de un conjunto de variables bioclimáticas, topográficas y variables representativas de vegetación, se elaboraron modelos predictivos del *stock* de carbono lo que puede predecir si los mismos han perdido, en gran parte, el conjunto de propiedades que ofrece la materia orgánica. El uso de *Random Forests* como modelo predictivo presenta resultados óptimos, y permite incorporar los factores formadores de suelos en la distribución espacial del *stock* de carbono (Corvalán, 2019). *Random Forest* utiliza un conjunto de árboles de clasificación, donde cada árbol contribuye con un solo voto para la asignación de la clase más frecuente a los datos de entrada, utiliza un subconjunto aleatorio de características de entrada o variables predictivas en la división de cada nodo, en lugar de usar las mejores variables, lo que reduce el error de generalización. Además, para aumentar la diversidad de los árboles, una RF utiliza ensacado o agregación de arranque para hacer que los árboles crezcan a partir de diferentes datos de entrenamiento (Rodríguez-Galiano *et al.*, 2012).

También se ha empleado para detectar enfermedades en las plantas mediante imágenes de plantas sanas y plantas enfermas, imágenes de resolución espacial de diferentes satélites agrícolas, enfermedades de cultivos y los pesticidas utilizados (Badage, 2018). En monitoreo del tizón bacteriano en el arroz, y otras enfermedades en el cultivo de arroz, se han empleado técnicas de segmentación, extracción de características y dos clasificadores para el algoritmo de clasificación. Este tipo de abordaje, a través de imágenes satelitales, es tratada por Barragán Agudelo and Diaz Mujica (2020) y se plantea el uso de Interpretación de imágenes de satélite con técnicas de Aprendizaje Automático para el monitoreo de cultivos.

No solo los cultivos en el ámbito de la agricultura se han beneficiado de los aportes del aprendizaje automático, también en la ganadería se han hecho trabajos, que permiten entre muchas otras opciones, simular sistemas de producción de carne para poder tomar efectivas decisiones (Machado and Berger, 2012).

Dado el avance en el aprendizaje automático (y en las Redes Neuronales en particular), la mejora en el *hardware* de los teléfonos móviles y el incremento en los accesos de la población a estos dispositivos, se han propuesto plataformas en la nube que posibilitan la detección, en tiempo real, de enfermedades y plagas en cultivos a través de las cámaras de teléfono celular (Pereña Pineda, 2016).

Las predicciones para determinar en tiempo real la probabilidad de cancelación o retraso de un vuelo en función de las condiciones meteorológicas se han desarrollado utilizando aprendizaje automático en la modelación y a la vez se interlaza con *Power BI* como herramienta de procesamiento y visualización de datos (Pereña Pineda, 2016).

El uso del aprendizaje automático está siendo empleado en monitoreo de aguas costeras para detectar manchas de aceite, que, a través de imágenes generadas diariamente por radares satelitales, permite capacitar un sistema de detección de contaminación, con ejemplos de derrames para cada usuario para sus propios fines, es solo un ejemplo de cómo esta tecnología puede ayudar en la preservación del medio ambiente. Al encontrar posibles manchas de acei-

te, primero el sistema procesa y normaliza la imagen, identificando el lugar sospechoso, posteriormente se determinan los atributos de cada mancha de aceite, como la región, el tamaño y la intensidad y, al final, se utiliza el aprendizaje de patrones para los atributos resultantes (Witten and Frank, 2002).

Estudios acerca de la observación de la tierra han tenido sus grandes logros en esta materia, utilizando los algoritmos de clasificación y predicción en temperatura de la superficie de la tierra, estudios de sequías y calidad del agua, detección y clasificación de nubes, aplicaciones de uso del suelo, clasificación y segmentación de imágenes, proyectos de energía renovable.

Además, las técnicas de aprendizaje automático se han convertido en una herramienta fundamentalmente eficaz en la forma de modelar y extraer patrones de big data de manera (semi) automática. La ciencia de la tierra ha sido también afectada por dicha revolución de muchas formas diferentes. Por ejemplo, los modelos de aprendizaje automático ahora son utilizados habitualmente para predecir y comprender los componentes del sistema terrestre encaminados a la:

- Clasificación de la cobertura terrestre
- Modelización del intercambio tierra-atmósfera y océano-atmósfera de gases de efecto invernadero
- Detección de anomalías y eventos extremos

El aprendizaje automático también se ha utilizado para complementar modelos físicos desarrollados en los últimos 50 años, que ahora son capaces de asimilar los datos medidos y producir estimaciones / predicciones más precisas de la evolución del sistema (o partes del mismo), como la Atmósfera o el Océano, un modelado híbrido y consciente de la física y el estudio futuro del sistema terrestre (Salcedo-Sanz *et al.*, 2020).

Algunos países han estado utilizando el sistema de algoritmo de aprendizaje automático para preservar el medio ambiente, como en Brasil, por su extensión y la cobertura boscosa del Amazonas, pulmón del planeta, con el fin de hacer efectivo el derecho fundamental a un medio ambiente ecológicamente equilibrado, en la toma de decisiones políticas, en las políticas públicas de justicia ambiental, en el ejercicio jurisdiccional y en los más diversos campos de actuación estatal (Rabinovich *et al.*, 2021).

En la acuicultura de precisión, el algoritmo mejorado de aprendizaje automático de decisiones (IDMLA) ha sido integrado con métodos para monitorear la alimentación de los peces, por medio de los cuales se pueden controlar parámetros importantes como la calidad del agua, el rango, la velocidad y el flujo de las bombas de agua, lo que hace que aumente la vida útil de los peces. En estos casos se emplea tecnología basada en sensores para monitorear los parámetros necesarios que se conecta fácilmente a bajo costo (Manoharan *et al.*, 2020). Por otra parte se han establecido las técnicas de algoritmo de *Machine Learning* para detectar las enfermedades en los peces en la etapa inicial, por lo que la automatización lleva a reducir los esfuerzos y las pérdidas de los inversores a gran y pequeña escala (Manoj and Rajan, 2020).

Se han utilizado procesos de decisión de Markov en el estudio del crecimiento de los peces, debido a la compleja condición de la acuicultura y la incertidumbre ambiental en factores

como temperatura, oxígeno disuelto, amoníaco no ionizado y acoplamientos no lineales fuertes, incluyendo múltiples entradas del modelo de crecimiento de peces, teniendo en cuenta que el problema de seguimiento de la trayectoria de crecimiento no puede ser resuelto de manera eficiente por los enfoques de control basados en modelos en la acuicultura de precisión. Por medio de estas aplicaciones se logra aprender la política de control óptima a partir de los datos muestreados de las trayectorias de crecimiento de los peces en cada etapa del ciclo de vida, desde los juveniles hasta el peso de mercado deseado en el entorno de la acuicultura (Chahid *et al.*, 2021).

La aplicación de algoritmos de aprendizaje automático en cría inteligente de peces, en los últimos cinco años, ha tenido impacto en la detección de biomasa de peces (estimación de tamaño, peso y cantidad) por medio de redes neuronales convolucionales (CNN) (Monkman *et al.*, 2019), la identificación y clasificación de peces (sexo, edad y especie) (Cui *et al.*, 2020), el análisis de comportamiento (comportamiento anormal y por grupos) (Zhou *et al.*, 2018) y la predicción de parámetros de calidad del agua por medio del modelo LSTM (*long short-term memory model*) para predecir *pH* y temperatura del agua (Hu *et al.*, 2019), y la predicción de oxígeno disuelto en agua (Ren *et al.*, 2020). El aprendizaje automático también se aplica a la predicción de otros parámetros de calidad del agua. Kim y col. (2020) desarrollaron un modelo de red de estado de eco profundo (*DEEP ESN*) para predecir la demanda bioquímica de oxígeno (DBO) (Kim *et al.*, 2020).

En Cuba, aunque se han utilizado técnicas de inteligencia artificial y aprendizaje automático en muchos sectores como la salud y esferas mucho más específicas como neurociencias, biotecnología (Castillo *et al.*, 2016; Díaz-Barrios *et al.*, 2015), en el sector de los recursos naturales y la biodiversidad, no se ha incursionado lo suficiente, desaprovechando así las ventajas y aplicaciones del Aprendizaje Automático, aunque sus técnicas, basado en memoria, KNN, *K* vecinos más cercanos, algoritmos de clasificación, Interpolación, se han usado en estudios conjuntos, con equipos de Venezuela, para el desarrollo del cultivo del plátano (Grau-Merconchini *et al.*, 2010) y en otros casos sobre la caracterización de frijol (Verdesia-Hernández *et al.*, 2018).

En el sector azucarero cubano también se han empleado estas técnicas, sobre todo en la evaluación de las máquinas en el complejo cosecha-transporte-recepción de la caña de azúcar (Ramírez and López, 2014).

Otros recursos naturales, han sido tratados desde la arista del Aprendizaje Automático, como son: los análisis de la calidad del aire (Sanjuán de Caso, n.d.); pronóstico del tiempo (Gnoza Tansini and Barberena Allietti, 2018).

CONCLUSIONES

Las técnicas de Inteligencia Artificial y en particular el aprendizaje automático, han tenido un gran auge en el mundo de aplicaciones a problemas complejos, que involucran una gran cantidad de datos y procesamiento logístico, aunque en sectores que se beneficien del manejo integrado de los recursos naturales, todavía es amplio el horizonte. En Cuba, estas aplicacio-

nes, aunque se han potenciado en ramas de la medicina, neurociencias, biotecnología y deporte, con algunas aplicaciones, no se ha aprovechado lo suficiente en los sectores que tienen un amplio manejo de los recursos naturales y la biodiversidad.

En el contexto del cambio climático, la necesidad de utilizar estas herramientas para monitorear y gestionar los recursos naturales adquiere cada vez más relevancia, para dar respuesta a los retos impuestos al desarrollo sostenible y a la supervivencia de la especie humana, ya que las afectaciones negativas a los recursos naturales y la biodiversidad, por los impactos del cambio climático, inciden sobre los bienes y servicios ecosistémicos de los que se sirven los seres humanos para desarrollar sus actividades socioeconómicas y culturales. Es necesario, por lo tanto, buscar nuevas herramientas, más inteligentes y eficaces, que favorezcan el monitoreo y gestión de estos recursos, para facilitar la toma de decisiones de científicos, directivos y población en general, en relación con su uso sostenible, conservación y mejoramiento.

La revisión realizada ha posibilitado demostrar el amplio uso del aprendizaje automático en diferentes esferas de la sociedad y sus bondades en el estudio de recursos relacionados con el medio ambiente, lo cual demuestra la factibilidad de su uso para la gestión integrada de los recursos naturales y la biodiversidad.

REFERENCIAS

- Badage, Anuradha. 2018. Crop Disease Detection Using Machine Learning: Indian Agriculture. *Int. Res. J. Eng. Technol. (IRJET)* 5(9):866–69.
- Barragán Agudelo, Anderson, and Sebastián Danilo Diaz Mujica. 2020. Interpretación de Imágenes de Satélite Con Técnicas de Machine Learning Para El Monitoreo de Cultivos.
- Breiman, Leo. 2001. Statistical Modeling: The Two Cultures (with Comments and a Rejoinder by the Author). *Statistical Science* 16(3):199–231.
- Campos Santelices, Matías Felipe. 2017. Aplicación de Técnicas de Machine Learning Para Predecir El Tamaño de Incendios Forestales.
- Castillo, Duniel Delgado, Rainer Martín Pérez, Leonardo Hernández Pérez, Rubén Orozco Morález, and Juan Lorenzo Ginori. 2016. Algoritmos de Aprendizaje Automático Para La Clasificación de Neuronas Piramidales Afectadas Por El Envejecimiento. *Revista Cubana de Informática Médica* 8(3):559–71.
- Chahid, Abderrazak, Ibrahima N'Doye, John E. Majoris, Michael L. Berumen, and Taous-Meriem Laleg-Kirati. 2021. Fish Growth Trajectory Tracking via Reinforcement Learning in Precision Aquaculture. *ArXiv Preprint ArXiv:2103.07251*.
- Corvalán, Francisco Martin. 2019. Variación Del Contenido de Materia Orgánica En Suelos Agrícolas de Guaymallén Desde 1963 a 2018, Utilizando Machine Learning. Universidad Nacional de Cuyo. Facultad de Ciencias Agrarias.
- Cui, Yanhai, Tianhong Pan, Shan Chen, and Xiaobo Zou. 2020. A Gender Classification Method for Chinese Mitten Crab Using Deep Convolutional Neural Network. *Multimedia Tools and Applications* 79(11):7669–84.

- Díaz-Barrios, Heidy, Yania Alemán-Rivas, Leidys Cabrera-Hernández, Alejandro Morales-Hernández, María del Carmen Chávez-Cárdenas, and Gladys María Casas-Cardoso. 2015. Algoritmos de Aprendizaje Automático Para Clasificación de Splice Sites En Secuencias Genómicas. *Revista Cubana de Ciencias Informáticas* 9(4):155–70.
- Donoho, David. 2017. 50 Years of Data Science. *Journal of Computational and Graphical Statistics* 26(4):745–66.
- Farley, Scott S., Andria Dawson, Simon J. Goring, and John W. Williams. 2018. Situating Ecology as a Big-Data Science: Current Advances, Challenges, and Solutions. *BioScience* 68(8):563–76.
- Flach, Peter. 2012. *Machine Learning: The Art and Science of Algorithms That Make Sense of Data*. Cambridge University Press.
- Ge, Zhiqiang, Zhihuan Song, Steven X. Ding, and Biao Huang. 2017. Data Mining and Analytics in the Process Industry: The Role of Machine Learning. *Ieee Access* 5:20590–616.
- Gnoza Tansini, Natalie, and Marcelo Enrique Barberena Allietti. 2018. Estudio de Factibilidad Del Uso de Machine Learning Con Múltiples Fuentes de Datos En El Pronóstico Del Tiempo.
- Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. 2016. *Deep Learning*. MIT press.
- Grau-Merconchini, David, Odalis Moreno-Oliva, Diana P. Chala-Ramírez, Jorge Andrés Quintero-Toro, and Luis Bertel-Paternina. 2010. Sistema Basado En El Conocimiento Para La Planificación y Gestión Del Cultivo de Plátano En Colombia y Cuba. *Ciencia En Su PC* (2):101–13.
- Hampton, Stephanie E., Carly A. Strasser, Joshua J. Tewksbury, Wendy K. Gram, Amber E. Budden, Archer L. Batcheller, Clifford S. Duke, and John H. Porter. 2013. Big Data and the Future of Ecology. *Frontiers in Ecology and the Environment* 11(3):156–62.
- Hu, Zhuhua, Yiran Zhang, Yaochi Zhao, Mingshan Xie, Jiezhuo Zhong, Zhigang Tu, and Juntao Liu. 2019. A Water Quality Prediction Method Based on the Deep LSTM Network Considering Correlation in Smart Mariculture. *Sensors* 19(6):1420.
- Kim, Sungwon, Meysam Alizamir, Mohammad Zounemat-Kermani, Ozgur Kisi, and Vijay P. Singh. 2020. Assessing the Biochemical Oxygen Demand Using Neural Networks and Ensemble Tree Approaches in South Korea. *Journal of Environmental Management* 270:110834.
- Lausch, Angela, Andreas Schmidt, and Lutz Tischendorf. 2015. Data Mining and Linked Open Data—New Perspectives for Data Analysis in Environmental Research. *Ecological Modelling* 295:5–17.
- Liakos, Konstantinos G., Patrizia Busato, Dimitrios Moshou, Simon Pearson, and Dionysis Bochtis. 2018. Machine Learning in Agriculture: A Review. *Sensors* 18(8):2674.
- Machado, C. F., and Horacio Berger. 2012. Uso de Modelos de Simulación Para Asistir Decisiones En Sistemas de Producción de Carne. *Revista Argentina de Producción Animal* 32(1):87–105.
- Manoharan, Hariprasath, Yuvaraja Teekaraman, Pravin R. Kshirsagar, Shanmugam Sundaramurthy, and Abirami Manoharan. 2020. Examining the Effect of Aquaculture Using

- Sensor-based Technology with Machine Learning Algorithm. *Aquaculture Research* 51(11):4748–58.
- Manoj, M., and Reeja Rajan. 2020. Precision aquaculture using iot & machine learning techniques. *Agpe the royal gondwana research journal of history, science, economic, political and social science* 2(1):105–11.
- Molinario, Carlos Alberto, and Augusto Antônio Fontanive Leal. 2018. Big Data, Machine Learning and Environmental Preservation: Technological Instruments in Defense of the Environment. *VEREDAS DO DIREITO* 15(31):201–24.
- Monkman, Graham G., Kieran Hyder, Michel J. Kaiser, and Franck P. Vidal. 2019. Using Machine Vision to Estimate Fish Length from Images Using Regional Convolutional Neural Networks. *Methods in Ecology and Evolution* 10(12):2045–56.
- Morales Martínez, Paola Cristina. 2020. Análisis de Cambio En La Cobertura Boscosa En El Municipio de Cartagena Del Chairá a Través de Imágenes Satelitales de 2016 y 2019 Por Medio de Algoritmos de Machine Learning.
- Olden, Julian D., Michael K. Joy, and Russell G. Death. 2004. An Accurate Comparison of Methods for Quantifying Variable Importance in Artificial Neural Networks Using Simulated Data. *Ecological Modelling* 178(3–4):389–97.
- Parra Muñoz, Inés de la. 2020. Análisis de La Evolución de La Cubierta Vegetal En Las Minas Restauradas de Teruel a Partir de Teledetección y Un Modelo Machine Learning.
- Pedraza Camelo, Juan Camilo. n.d. Prototipo de Un Modelo de Machine Learning Para La Predicción de Partículas de Contaminación Atmosférica Finas, En La Localidad de Kennedy En La Ciudad de Bogotá.
- Pereña Pineda, Jaime. 2016. Modelo Predictivo. Machine Learning Aplicado Al Análisis de Datos Climáticos Capturados Por Una Placa Sparkfun.
- Posada Valcárcel, Stiven Fernando. 2020. Análisis de Imágenes Satelitales de Observación de La Tierra y Datos Geoespaciales a Través de Machine Learning.
- Rabinovich, Jorge E., Agustín Alvarez Costa, Ignacio J. Muñoz, Pablo E. Schilman, and Nicholas M. Fountain-Jones. 2021. Machine-Learning Model Led Design to Experimentally Test Species Thermal Limits: The Case of Kissing Bugs (Triatominae). *PLoS Neglected Tropical Diseases* 15(3):e0008822.
- Ramírez, Neeldes Matos, and Yoan Martínez López. 2014. La Inteligencia Artificial. Nuevo Enfoque En La Evaluación de Las Máquinas En El Complejo Cosecha–Transporte–Recepción de La Caña de Azúcar. *Revista Ingeniería Agrícola* 4(2):60–64.
- Ren, Qin, Xuanyu Wang, Wenshu Li, Yaoguang Wei, and Dong An. 2020. Research of Dissolved Oxygen Prediction in Recirculating Aquaculture Systems Based on Deep Belief Network. *Aquacultural Engineering* 90:102085.
- Rode, Michael, Andrew J. Wade, Matthew J. Cohen, Robert T. Hensley, Michael J. Bowes, James W. Kirchner, George B. Arhonditsis, Phil Jordan, Brian Kronvang, and Sarah J. Halliday. 2016. Sensors in the Stream: The High-Frequency Wave of the Present.
- Rodríguez-Galiano, V. F., M. Chica-Olmo, F. Abarca-Hernandez, Peter M. Atkinson, and C.

- Jeganathan. 2012. Random Forest Classification of Mediterranean Land Cover Using Multi-Seasonal Imagery and Multi-Seasonal Texture. *Remote Sensing of Environment* 121:93–107.
- Salcedo-Sanz, Sancho, Pedram Ghamisi, María Piles, M. Werner, Lucas Cuadra, A. Moreno-Martínez, Emma Izquierdo-Verdiguier, Jordi Muñoz-Marí, Amirhosein Mosavi, and Gustau Camps-Valls. 2020. Machine Learning Information Fusion in Earth Observation: A Comprehensive Review of Methods, Applications and Data Sources. *Information Fusion* 63:256–72.
- Sanjuán de Caso, Marta. n.d. Predicción de La Calidad Del Aire de La Ciudad de Madrid Mediante Técnicas de Machine-Learning.
- Vargas-Crispin, Wilber Samuel, Edwin Montes-Raymundo, Manuel Castrejón-Valdez, and René Antonio Hinojosa-Benavides. 2021. Machine Learning Como Herramienta Para Determinar La Variación de Los Recursos Hídricos. *Scientific Research Journal CIDI* 1(1):56–69.
- Verdesia-Hernández, Nelson, Ariel Hernández-Musa, Irina Blanco-Gil, and Alexis Lamz-Piedra. 2018. Sistema de Información Para El Control de La Biodiversidad de Variedades y Caracterización Del Cultivo de Frijol En Cuba. *Cultivos Tropicales* 39(2):28–33.
- Witten, Ian H., and Eibe Frank. 2002. Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations. *Acm Sigmod Record* 31(1):76–77.
- Zhou, Chao, Kai Lin, Daming Xu, Lan Chen, Qiang Guo, Chuanheng Sun, and Xinting Yang. 2018. Near Infrared Computer Vision and Neuro-Fuzzy Model-Based Feeding Decision System for Fish in Aquaculture. *Computers and Electronics in Agriculture* 146:114–24.

