

Una revisión sobre la inteligencia artificial como herramienta para la sustentabilidad en México

A review of artificial intelligence as a tool for sustainability in Mexico

Victor Hugo Leal-Cisneros¹, María Concepción Martínez-Rodríguez²

Leal-Cisneros, V.H; Martínez-Rodríguez, M.C. Una revisión sobre la inteligencia artificial como herramienta para la sustentabilidad en México . *Tecnología en Marcha*. Vol. 39 N° especial sobre Inteligencia Artificial. Febrero, 2026. Pág. 285-298.

 <https://doi.org/10.18845/tm.v39i5.8522>



- 1 Instituto Politécnico Nacional. México.
 vlealc1500@alumno.ipn.mx
 <https://orcid.org/0009-0005-1151-2727>
- 2 Instituto Politécnico Nacional. México.
 mcmartinezr@ipn.mx
 <https://orcid.org/0000-0003-3094-5411>

Palabras clave

Inteligencia artificial; sustentabilidad; México; aprendizaje automático; monitoreo ambiental.

Resumen

La Inteligencia Artificial (IA) emerge como una herramienta estratégica para abordar los desafíos de la sustentabilidad en México. El presente trabajo tiene como objetivo evaluar el estado actual de la investigación sobre IA aplicada a la sostenibilidad en el país, identificar patrones de impacto y señalar áreas de oportunidad críticas. Mediante una revisión metodológica de literatura científica reciente en repositorios clave, seleccionando 11 estudios posteriores a 2020, el análisis revela una marcada dicotomía de “dos IA’s”. Por un lado, una IA verde, enfocada en el monitoreo ambiental y la conservación de ecosistemas, demostrando una madurez creciente y resultados exitosos, que se atribuyen al fuerte respaldo institucional y a la disponibilidad de datos satelitales públicos. Por otro lado, una IA marrón, destinada a problemas urbanos e industriales como la gestión de residuos, la cual se determina como incipiente, teórica y la cual enfrenta fracasos prácticos. Se concluye que esta divergencia se debe fundamentalmente a los tipos y la disponibilidad de datos, donde, por un lado la IA verde prospera con datos públicos abundantes, la “IA marrón” se ve frenada por la escasez de datos granulares y de alta calidad. Además, el estudio identifica brechas significativas en áreas como energías renovables, planificación urbana y economía circular, proponiendo estrategias de adaptación pragmáticas para superar la barrera de los datos como paso inicial hacia futuras innovaciones específicas del contexto en México.

Keywords

Artificial intelligence; sustainability; Mexico; machine learning; environmental monitoring.

Abstract

Artificial Intelligence (AI) is emerging as a strategic tool to address sustainability challenges in Mexico. This study aims to evaluate the current state of research on AI applied to sustainability in the country, identify impact patterns, and highlight critical areas of opportunity. Employing a methodological review of recent scientific literature from key repositories and selecting 11 studies published after 2020, the analysis reveals a marked dichotomy of “two AIs.” On the one hand, “green AI,” focused on environmental monitoring and ecosystem conservation, demonstrates growing maturity and successful outcomes, which are attributed to strong institutional support and the availability of public satellite data. On the other hand, “brown AI,” applied to urban and industrial problems such as waste management, is determined to be incipient, theoretical, and facing practical failures. It is concluded that this divergence is fundamentally due to data types and availability: while “green AI” thrives on abundant public data, “brown AI” is hindered by the scarcity of granular, high-quality data. Furthermore, the study identifies significant gaps in areas such as renewable energy, urban planning, and the circular economy. It proposes pragmatic adaptation strategies to overcome the data barrier as an initial step toward future context-specific innovations in Mexico.

Introducción

La Inteligencia Artificial (IA) representa una de las transformaciones tecnológicas más profundas del siglo XXI. El término carece de una definición única y consensuada, se puede entender en un sentido amplio como “la capacidad de los programas informáticos para realizar tareas

comúnmente asociadas con los seres inteligentes” [1]. Históricamente, podríamos considerar que su origen conceptual se remonta a la Conferencia de Dartmouth de 1956, donde John McCarthy y un grupo de investigadores plantearon la hipótesis de que la mente humana podría ser replicada en máquinas, sentando así, las bases de la disciplina [2]. Desde entonces, la IA ha evolucionado de un campo teórico a una fuerza omnipresente que redefine industrias, economías y sociedades.

Para comprender el alcance de la IA es fundamental distinguirla como un campo general de sus subcampos más influyentes, campos como el Aprendizaje Automático (Machine Learning - ML), el cual es el más predominante y se define como la ciencia de desarrollar algoritmos y modelos estadísticos que permiten a las computadoras aprender de los datos y mejorar su rendimiento en una tarea sin ser programadas explícitamente para ello [3]. En otras palabras, el objetivo central del ML es que un modelo, entrenado en un conjunto de datos representativo, puede generalizar ese aprendizaje para hacer inferencias y predicciones precisas sobre datos nuevos y no vistos, aplicando los patrones que ha aprendido [4].

Otro campo igual de predominante es el de Aprendizaje Profundo (Deep Learning - DL), un subconjunto del ML que utiliza arquitecturas de redes neuronales artificiales con múltiples capas, de ahí el término “profundo” [3]. Estas redes son inspiradas en la estructura del cerebro humano pues son capaces de aprender representaciones de datos con múltiples niveles de abstracción, lo que les permite descubrir estructuras intrincadas en grandes conjuntos de datos. El DL es la tecnología que impulsa la mayoría de las aplicaciones de IA de vanguardia en la actualidad, desde el reconocimiento de imágenes y el procesamiento del lenguaje natural hasta los vehículos autónomos [5].

Globalmente el impacto de la IA ha sido dual. Por un lado, su potencial para el bien es inmenso dado que acelera el descubrimiento en el ámbito científico al analizar volúmenes de datos que superan la capacidad humana, identificando patrones, formulando hipótesis y agilizando la revisión de literatura [2]. En la sanidad, mejora la precisión de los diagnósticos médicos, personaliza los planes de tratamiento y optimiza la eficiencia operativa de los sistemas de salud [6] o en la educación, donde facilita experiencias de aprendizaje personalizadas y adaptativas, mejorando la accesibilidad para estudiantes con diversas necesidades [7].

Por otra parte, la rápida proliferación de la IA plantea profundos desafíos sociales, éticos y económicos. La automatización de tareas cognitivas y físicas amenaza con el desplazamiento de una parte significativa de la fuerza laboral, lo que podría exacerbar la desigualdad de la riqueza si los beneficios se concentran en un pequeño grupo de inversores y tecnólogos [8]. Los algoritmos de IA, entrenados con datos históricos, pueden perpetuar e incluso amplificar los sesgos sociales existentes, conduciendo a decisiones discriminatorias en áreas críticas como la contratación, el crédito o la justicia penal [9]. Además, la capacidad de la IA para recopilar y analizar datos personales a una escala sin precedentes genera graves preocupaciones sobre la privacidad, la vigilancia y la manipulación del comportamiento humano [8]. Todos estos dilemas dejan en claro la necesidad imperativa de un desarrollo y despliegue de la IA que sea ético, transparente y centrado en el ser humano, lo que hace que un análisis contextualizado para cada nación, como México, se convierta en una tarea esencial.

En los últimos años, México se ha posicionado como un mercado de gran atractivo a nivel global en el ámbito de la IA y ha comenzado a explorar e implementar sus aplicaciones como un motor potencial para el desarrollo económico y social [10]. Este creciente interés se refleja en un aumento significativo de la producción científica. Una revisión sistemática de la literatura entre los años 2000 y 2023 identificó 120 artículos de investigación originales sobre la aplicación de modelos de ML y DL en el país, demostrando una actividad académica en [3].

Las oportunidades que la IA presenta para México son vastas y diversas, donde el análisis de la producción científica revela que las principales áreas de aplicación han sido las Ciencias Sociales y la Medicina, lo que sugiere un enfoque en la resolución de desafíos directamente relacionados con el bienestar de la población [3]. El gobierno mexicano ha reconocido este potencial a través de iniciativas como la Estrategia Nacional de Inteligencia Artificial, presentada en 2018 por la Secretaría de Economía y el CONACYT, que busca promover el desarrollo y la adopción de estas tecnologías [10]. Existen ejemplos concretos de su aplicación en sectores clave: en salud, el Instituto Mexicano del Seguro Social (IMSS) utiliza la IA en programas como DiabetIMSS para la detección temprana de enfermedades crónicas; en agricultura, se explora su uso para optimizar el uso de recursos; e incluso en el ámbito cultural, se emplean herramientas de IA para preservar y difundir las lenguas y tradiciones de los pueblos originarios [10].

Sin embargo, a pesar de este panorama prometedor en México, el ecosistema de IA enfrenta barreras sistémicas que limitan su pleno desarrollo y su aplicación equitativa, donde la principal debilidad, identificada por la comunidad científica, es la falta de una estrategia nacional de IA consolidada y financiada adecuadamente, lo que resulta en esfuerzos fragmentados y una falta de dirección unificada [3]. Esta debilidad estratégica se manifiesta en una serie de desafíos prácticos que obstaculizan la implementación a gran escala.

Por un lado la IA depende de grandes volúmenes de datos de alta calidad para su entrenamiento, misma calidad que en México se ve comprometida por la recopilación, organización y accesibilidad, ocasionando limitaciones críticas. Otro problema presente es el desarrollo y mantenimiento de soluciones con IA pues requieren una infraestructura digital robusta y una inversión sostenida. Así mismo, al igual que a nivel global, México enfrenta profundos dilemas sociales, éticos y jurídicos, donde cuestiones como la privacidad de los datos, el potencial de sesgo algorítmico, el desplazamiento laboral y la asignación de responsabilidad legal por los errores de los sistemas de IA siguen sin ser abordadas de manera integral en el marco regulatorio nacional, lo que crea un vacío que podría dar lugar a implementaciones perjudiciales o inequitativas [9].

Todo el escenario mostrado, lleno de desafíos estructurales y oportunidades emergentes cobra especial relevancia al enfocarlo en uno de los retos más apremiantes para el país: la sustentabilidad. La capacidad de la IA para modelar sistemas complejos, optimizar el uso de recursos hídricos y energéticos, monitorear la deforestación y predecir fenómenos climáticos la posiciona como una herramienta estratégica para avanzar hacia un desarrollo sostenible. Sin embargo, para capitalizar este potencial es imperativo diagnosticar con precisión cómo se están empleando estas tecnologías en el país y qué barreras específicas enfrentan en el sector ambiental. En este contexto, el objetivo del presente artículo es evaluar el estado actual de la investigación sobre IA para la sustentabilidad en México, identificar los patrones de impacto emergentes, señalar las áreas de oportunidad críticas y proponer direcciones futuras que se adapten a las particularidades del contexto nacional.

Taxonomía de la Inteligencia Artificial Aplicada a la Sustentabilidad

Antes de comenzar a analizar de manera efectiva las aplicaciones de la IA en el ámbito de la sustentabilidad, es crucial establecer una taxonomía clara de los principales tipos y modelos de IA que se encuentran en la literatura científica pertinente. El Aprendizaje Automático es el enfoque central en la mayoría de las aplicaciones prácticas de IA. Como se mencionó, su esencia radica en la capacidad de los algoritmos para aprender patrones directamente de los datos [4]. Los métodos de ML se clasifican generalmente en dos categorías principales según la naturaleza de los datos de entrenamiento.

Aprendizaje Supervisado: En este paradigma, el algoritmo se entrena con un conjunto de datos que ha sido previamente “etiquetado” con la respuesta correcta. El objetivo es que el modelo aprenda una función de mapeo que pueda predecir la etiqueta de salida para nuevos datos no vistos [3]. Las tareas comunes incluyen la clasificación (predecir una categoría, como “manglar” o “no manglar”) y la regresión (predecir un valor continuo, como la cantidad de carbono almacenado).

Aprendizaje No Supervisado: A diferencia del aprendizaje supervisado, este enfoque utiliza datos no etiquetados. El objetivo del algoritmo es descubrir patrones, estructuras o agrupaciones ocultas dentro de los datos por sí mismo [3]. La técnica más común es el clustering, que agrupa los puntos de datos en función de su similitud.

Por otra parte, el Aprendizaje Profundo es una forma más avanzada de ML que utiliza Redes Neuronales Artificiales (ANN) con muchas capas. Estas arquitecturas profundas permiten al modelo aprender jerarquías de características, desde las más simples en las primeras capas hasta las más complejas y abstractas en las capas más profundas [11]. Esta capacidad hace que el DL sea excepcionalmente poderoso para tareas que involucran datos no estructurados y de alta dimensionalidad, como imágenes, texto y sonido.

Otro modelo ampliamente utilizado de IA son los modelos de ensamble, los cuales son una técnica de ML que busca mejorar el rendimiento predictivo combinando las predicciones de múltiples modelos individuales (llamados “aprendices base”) [12], es decir, que, en lugar de depender de un solo modelo, se crea un “comité” de modelos, y la decisión final se toma por votación (en clasificación) o promediando (en regresión). Esta estrategia a menudo conduce a una mayor robustez y precisión.

Los Random Forest (RF) son de los modelos de ensamble más populares y versátiles; este es, como su nombre indica, un ensamble de múltiples árboles de decisión [13]. Su poder proviene de dos fuentes de aleatoriedad: primero, cada árbol se entrena en una muestra aleatoria (con reemplazo) del conjunto de datos original (una técnica llamada bagging); segundo, en cada nodo del árbol, solo se considera un subconjunto aleatorio de características para decidir la división. Esta doble aleatoriedad crea árboles diversos e independientes, lo que reduce el sobreajuste y mejora la capacidad de generalización del modelo [12]. Sus ventajas, como la capacidad de manejar datos de alta dimensionalidad, su robustez frente al ruido y la capacidad de proporcionar métricas de importancia de las variables, lo pueden hacer ideal para aplicaciones de teledetección en ecología.

Metodología

Como se ha mencionado, la IA ha tomado en los últimos años una relevancia global sin precedentes y México no es la excepción. Sin embargo, es importante resaltar que aún es un campo de estudio amplio y nuevo, por ende aún no se encuentra completamente sistematizado, misma razón por la que en muchas ocasiones en la literatura no se hace uso del término “artificial intelligence” de manera explícita, si no que, menciona herramientas como las previamente mencionadas (ML, DL, ANN o RF), que entran dentro de la categoría de IA, por lo que, a diferencia de un análisis bibliométrico masivo, este trabajo adopta un enfoque cualitativo y exploratorio para identificar patrones de implementación técnica y barreras estructurales.

Por esta razón la metodología consistió en la búsqueda de artículos bajo las palabras clave “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Artificial neural networks”, “Sustainability” y “México” en los repositorios SCOPUS, ResearchGate y SciELO, donde la

inclusión de ResearchGate, si bien presenta limitaciones respecto a la garantía de revisión por pares en la totalidad de sus documentos, resultado estratégica para acceder a la producción científica más reciente.

La selección de los documentos se rigió bajo el criterio de artículos publicados estrictamente a partir del año 2020, periodo que marca la democratización de herramientas como Google Earth Engine, nuevas arquitecturas de DL y un periodo anterior cercano al boom de la IA, además, se priorizaron estudios de caso aplicados en territorio mexicano que reportaran resultados empíricos utilizando las técnicas explícitas de IA antes mencionadas (ML, DL, etc.).

En el proceso de exclusión se descartaron revisiones sistemáticas para evitar redundancia en el análisis, artículos puramente teóricos sin validación experimental y estudios anteriores a 2020 por medio de un filtrado manual que considero relevancia y calidad técnica. Se seleccionó al final una muestra de 11 artículos, que a pesar de lo reducida, resulta representativa de los distintos sectores de aplicación y permite un análisis profundo de las metodologías empleadas en el país.

Tras la selección se llevó a cabo un proceso de categorización, donde se extrajo el tipo de modelo de IA utilizado, la metodología del trabajo, el objetivo principal de los autores y cuáles fueron las conclusiones y resultados obtenidos. Con ello se procedió a un análisis de las áreas de estudio con mayor impacto y se procedió a un trabajo de discusión sobre las áreas de oportunidad en el país para el aprovechamiento de las herramientas de la IA.




Figura 1. Diagrama Experimental de la metodología implementada.

Resultados

El cuerpo de investigación sobre la aplicación de la IA para la sostenibilidad en México, aunque creciente, muestra una concentración temática significativa. El análisis de la literatura científica recabada revela un fuerte enfoque en la conservación de ecosistemas y el monitoreo ambiental, con avances notables en la gestión de recursos críticos. Este campo ha capitalizado la sinergia entre la disponibilidad de datos de teledetección (imágenes satelitales y de drones) y el poder de los algoritmos de ML y DL para extraer información valiosa a escalas espaciales y temporales que serían inmanejables con métodos tradicionales.

Sin embargo, las aplicaciones en áreas como la gestión de residuos y la sostenibilidad en sectores productivos, aunque presentes, son más incipientes y a menudo de naturaleza prospectiva. El cuadro 1 resume los estudios clave que forman la base de este análisis, proporcionando una visión general del panorama actual en México.

Cuadro 1 Resumen de los estudios recopilados sobre el uso de IA en México.

Autor y Año	Problema de Sustentabilidad	Área de Aplicación	Tipo de implementación de IA	Resultados Clave
Troche-Souza C. et al. (2025), [14]	Mitigación del cambio climático, conservación de sumideros de carbono.	Conservación de Ecosistemas	Machine Learning (Random Forest), Análisis Espacial (LISA).	Mapa de alta resolución que identifica "hotspots" de carbono; el 33% del área contiene el 46% del carbono total.
Monterrubio-Martínez E. et al. (2025), [15]	Pérdida de biodiversidad, monitoreo de especies clave.	Conservación de Ecosistemas	Deep Learning (MangroveNet, AttCloudNet+).	Los modelos de DL superaron a otros métodos en precisión y capacidad de generalización para la identificación de especies de manglar.
Valderrama-Landeros L. et al. (2024), [16]	Deforestación, impacto de la acuicultura y huracanes.	Conservación de Ecosistemas	Machine Learning (en Google Earth Engine).	Mapeo de 182,467 ha de manglares y detección de una pérdida neta de 1,817 ha entre 2015 y 2020.
Aviña-Hernández J. et al. (2023), [17]	Necesidad de conocimiento ecológico para la conservación.	Conservación de Ecosistemas	Machine Learning (Random Forest).	El modelo RF demostró un alto rendimiento y precisión en la clasificación de especies de manglar.
Rodríguez-Zúñiga M. T. et al. (2022), [18]	Necesidad de un sistema de monitoreo estandarizado para la conservación.	Conservación de Ecosistemas	Machine Learning (implícito en herramientas como GEE).	Consolidación del Sistema de Monitoreo de Manglares de México (SMMM) como base científica para la conservación.
Valderrama-Landeros L. et al. (2021), [19]	Optimización de la calidad de datos para el monitoreo remoto.	Conservación de Ecosistemas	Machine Learning (en Google Earth Engine).	Identificación de las fechas óptimas para la adquisición de imágenes satelitales, mejorando la precisión del monitoreo.
Maturano J. G. et al.(2024), [20]	Contaminación por disposición inadecuada de residuos.	Gestión de Residuos	Machine Learning (Random Forest).	El modelo no pudo distinguir con precisión la basura del suelo urbano/desnudo, pero identificó NDVI y SAVI como índices clave.
Sánchez Yáñez J. M. & Márquez Benavides L. (2024), [21]	Gestión ineficiente de residuos sólidos urbanos.	Gestión de Residuos	IA (Smart Waste) (como objeto de estudio).	Identificación de oportunidades (optimización de rutas) y desafíos (datos, infraestructura, financiamiento) en México.
López-Flores et al. (2025), [22]	Escasez de agua y conflictos en el uso de recursos.	Optimización de Recursos	Machine Learning (SVM, RF, ANN).	El modelo predice un escenario severo de escasez de agua y ofrece estrategias para optimizar el nexo agua-energía-alimentos.
Castillo Ortiz S. Y. et al. (2025), [23]	Uso ineficiente de recursos en la agricultura.	Optimización de Recursos	Análisis de Datos / Big Data (incluyendo ML).	La IA es una necesidad para la seguridad alimentaria y la modernización sostenible del agro mexicano.
Mengual Torres S. G. et al. (2022), [24]	Alto consumo energético e impacto ambiental en el sector turístico.	Sostenibilidad Sectorial	Inteligencia Artificial (ANN).	El modelo identificó configuraciones para reducir el uso de energía en hoteles entre un 9% y un 12%.

Análisis

Un primer escaneo de la investigación realizada revela un patrón de “adopción pragmática”, es decir, los modelos de IA más utilizados en el país son las Redes Neuronales Artificiales (ANN), Random Forest (RF) y las Máquinas de Vectores de Soporte (SVM), [3]. Estos algoritmos, aunque potentes, son tecnologías bien establecidas y probadas, consideradas “caballos de batalla” en el campo del ML. El uso predominante de estas herramientas en estudios aplicados, como el uso de RF para el monitoreo ambiental por teledetección o de ANN para modelar el consumo energético en hoteles, sugiere que la comunidad científica mexicana está enfocada en aprovechar la IA como una herramienta práctica para resolver problemas específicos en sus respectivos dominios, enfoque propio de un ecosistema tecnológico que está madurando y adaptando tecnologías existentes, pero que aún no se encuentra en la vanguardia del desarrollo de investigación fundamental en IA.

Podemos además observar en la tabla 1 que, un ejemplo destacado de la sofisticación alcanzada es el trabajo de Troche-Souza et al. [14], en el mapeo de reservas de carbono en Marismas Nacionales, el complejo de manglares más grande del Pacífico mexicano. Utilizando un modelo de Random Forest, los investigadores integraron datos de campo con un conjunto diverso de datos de teledetección (Sentinel-1, Sentinel-2 y LiDAR). El modelo de ML no solo procesó esta información multivariada, sino que logró una precisión predictiva, permitiendo la creación de un mapa de carbono de alta resolución. El resultado más impactante, obtenido mediante análisis espacial (LISA), fue la identificación de “hotspots” de carbono: áreas que, aunque solo comprenden el 33% del territorio, almacenan el 46% del carbono total (21.5 Tg C). Este hallazgo es de una importancia estratégica incalculable, pues permite a los gestores de conservación priorizar de manera eficiente y basada en evidencia las áreas más críticas para la mitigación del cambio climático [14].

También podemos observar que la investigación ha avanzado hacia un nivel de detalle más granular, como la identificación de especies. Aquí se observa un interesante contraste de enfoques. Monterrubio-Martínez et al. [15], emplearon Aprendizaje Profundo, desarrollando modelos específicos como MangroveNet. Estos modelos, probablemente basados en arquitecturas de redes neuronales convolucionales (CNN), fueron diseñados para integrar datos espectrales y espaciales de alta resolución obtenidos con drones. Demostraron una capacidad de generalización y precisión superiores a otros métodos para la identificación de especies, abriendo la puerta al monitoreo en tiempo real [15]. A la par, el estudio de Aviña Hernández et al. [17], demostró que un enfoque más simple, utilizando RF, también puede alcanzar un alto rendimiento y precisión en la clasificación de especies de manglar. Esto sugiere que, si bien el DL ofrece el pináculo de la precisión, el RF sigue siendo una alternativa robusta y más accesible para muchas aplicaciones de conservación [17].

A una escala más amplia, la IA está potenciando el monitoreo nacional de la cobertura y los cambios en los ecosistemas. El trabajo de Valderrama-Landeros et al. [16] es emblemático de esta tendencia. Utilizando la plataforma Google Earth Engine (GEE), que encapsula potentes algoritmos de ML, analizaron imágenes Sentinel-2 para mapear la extensión de los manglares en todo el noroeste de México. El estudio no solo cuantificó la cobertura actual (182,467 ha en 2020), sino que también detectó una alarmante pérdida neta de 1,817 ha en solo cinco años (2015-2020), atribuyéndola principalmente a la expansión de la acuicultura y al impacto de los huracanes. Este tipo de análisis a gran escala, realizado con alta precisión es fundamental para informar políticas públicas y asignar recursos para la restauración [16].

Finalmente, la IA se está utilizando de maneras más sutiles pero igualmente críticas para mejorar la calidad de la ciencia misma. Un estudio anterior de Valderrama-Landeros et al. [19] utilizó GEE no para mapear, sino para analizar la fenología de los manglares, es decir, sus cambios

estacionales. Al procesar series temporales de índices de vegetación, pudieron identificar las “ventanas” de tiempo óptimas para la adquisición de imágenes satelitales, evitando periodos de alta nubosidad o estrés estacional que podrían distorsionar los datos. Este uso de la IA para optimizar la recolección de datos es un paso fundamental que mejora la precisión y fiabilidad de todos los estudios de monitoreo posteriores [19].

En marcado contraste con el campo de la conservación, la aplicación de la IA a la gestión de residuos y la contaminación en México es un área incipiente, caracterizada más por el análisis de su potencial que por implementaciones exitosas y documentadas. La investigación en este sector se enfrenta a desafíos fundamentales relacionados con la calidad y disponibilidad de los datos a nivel local.

El artículo de revisión de Sánchez Yáñez y Márquez Benavides [21] establece el marco conceptual del “Smart Waste” o gestión inteligente de residuos en el contexto mexicano. El estudio identifica un enorme potencial para que la IA optimice la Gestión de Residuos Sólidos (GRS), que en México genera 120,128 toneladas diarias con una recolección promedio del 84% [21]. Las aplicaciones clave incluyen la optimización de las rutas de recolección de basura mediante el análisis de patrones de tráfico y datos en tiempo real de los niveles de llenado de los contenedores (a través de sensores IoT), la clasificación automática de residuos para mejorar las tasas de reciclaje y la predicción de patrones de generación de residuos para una mejor planificación. Sin embargo, el artículo concluye que la realización de este potencial está supeditada a la superación de barreras estructurales significativas: la falta de datos de calidad, la infraestructura tecnológica inadecuada y el financiamiento limitado, especialmente a nivel municipal [21].

El estudio de caso de G. Maturano et al. [20], en Oaxaca sirve como una validación empírica de estos desafíos. El objetivo era utilizar una metodología de IA estándar y probada en otros campos —un clasificador RF en la plataforma GEE para analizar imágenes Sentinel-2— con el fin de detectar vertederos ilegales. A pesar de que el modelo alcanzó una alta precisión general (0.9517), fracasó en su objetivo principal: no pudo distinguir con fiabilidad entre la basura, el suelo urbano y el suelo desnudo debido a la similitud de sus firmas espectrales en las imágenes de resolución media [20]. Este resultado es sumamente revelador. No indica un fallo en el algoritmo de IA per se, sino una limitación fundamental impuesta por la calidad de los datos de entrada. Demuestra que las técnicas que funcionan bien para distinguir la vegetación verde de otros tipos de cobertura terrestre no se traducen directamente a los complejos y heterogéneos paisajes urbanos y periurbanos donde se localizan los problemas de residuos. Aunque el estudio logró identificar los índices espectrales NDVI y SAVI como los más prometedores para la detección de basura, su principal contribución es ilustrar de manera concreta las barreras que Sánchez Yáñez y Márquez Benavides describieron teóricamente.

La IA también está comenzando a ser explorada en México para abordar problemas de sostenibilidad de naturaleza sistémica, es decir, aquellos que involucran interacciones complejas entre múltiples sectores, desafíos particularmente difíciles de modelar con métodos tradicionales, y es aquí donde la capacidad de la IA para identificar patrones en datos multivariados se vuelve invaluable. Un estudio de caso paradigmático es el de López-Flores et al. [22], que desarrolla un enfoque basado en ML para optimizar la gestión del nexo agua-energía-alimentos (WEF) en México. Utilizando un conjunto de modelos de ML (como SVM, RF y ANN), los investigadores crearon una simulación que captura las complejas interdependencias entre el uso del agua para la agricultura, la producción de energía y la garantía de la seguridad alimentaria. El modelo no solo logró predecir un futuro escenario severo de escasez de agua, sino que también permitió identificar estrategias de gestión óptimas que mejoran las sinergias y reducen los conflictos entre los tres sectores. Este trabajo demuestra el papel crucial de

la IA para modelar la complejidad inherente a los sistemas socio ecológicos y proporcionar a los responsables de la toma de decisiones herramientas que mejoren la resiliencia y la sostenibilidad [22].

Por su parte, en el sector agrícola, la IA se perfila como una tecnología no solo beneficiosa, sino necesaria. El artículo de perspectiva de Castillo Ortiz et al. [23] explora cómo el análisis de datos masivos y el ML pueden transformar la agricultura mexicana hacia un modelo más eficiente y sostenible. Las técnicas de agricultura de precisión, como la optimización del riego basada en sensores y predicciones meteorológicas, la aplicación variable de fertilizantes según las necesidades del suelo y la predicción de cosechas, tienen el potencial de aumentar significativamente la productividad mientras se reduce el consumo de recursos vitales como el agua y los insumos químicos. La conclusión del artículo es contundente: para un país como México, que enfrenta desafíos de seguridad alimentaria y estrés hídrico, la adopción de la IA en la agricultura no es una opción, sino un imperativo para la modernización sostenible del sector [23].

Más allá de los ecosistemas y los recursos naturales, la IA también ofrece herramientas prácticas para mejorar la sostenibilidad en sectores económicos clave para México, como el turismo. El estudio de Mengual Torres et al. [24], proporciona un ejemplo concreto de esta aplicación, centrándose en la operación sostenible de hoteles en climas tropicales, un sector de alto consumo energético. Los investigadores diseñaron y entrenaron un modelo de Red Neuronal Artificial (ANN) para analizar la relación entre diversos indicadores energéticos y ambientales. El modelo fue alimentado con datos de auditorías energéticas, incluyendo características del hotel (categoría, ubicación), tipos y cantidades de dispositivos consumidores de energía, y sus costos asociados. Una vez entrenado, el modelo de IA permitió simular diferentes escenarios de mejora.

Los resultados demostraron que la implementación de configuraciones específicas, como la sustitución parcial de tecnologías de alto consumo, podría llevar a una reducción del uso de energía por habitación de entre un 9% y un 12% anual. Esta aplicación demuestra cómo la IA puede funcionar como una herramienta de apoyo a la toma de decisiones para los administradores de hoteles, traduciendo datos técnicos complejos en proyecciones claras de ahorro económico y reducción del impacto ambiental, facilitando así la adopción de prácticas más sostenibles [24].

El análisis de estas aplicaciones revela el surgimiento de una narrativa de “dos IA”, una que tiene éxito en la sostenibilidad “verde” y otra que lucha en la sostenibilidad “marrón” (ver cuadro 2). La literatura muestra un claro contraste, donde las aplicaciones en el monitoreo de ecosistemas naturales (sostenibilidad “verde”) demuestran una madurez creciente, progresando desde el mapeo básico hasta el análisis sofisticado de carbono y la identificación de especies con alta precisión. En contraste, las aplicaciones en la gestión de problemas urbanos e industriales (sostenibilidad “marrón”), como los residuos, son en gran medida teóricas o se topan con fracasos prácticos debido a problemas de acceso de datos e información.

Cuadro 2 Tabla comparativa IA Verde vs. IA Marrón.

Característica	IA Verde	IA Marrón
Dominio	Conservación, Monitoreo de Ecosistemas (Ej. Manglares)	Gestión Urbana/ Industrial (Ej. Residuos)
Estado	Madurez creciente, Resultados prácticos, Alta precisión	Incipiente, Teórica, Fracasos prácticos
Causa (Datos)	Abundantes, públicos, estandarizados (Datos satelitales, GEE)	Escasos, granulares, propietarios, inexistentes
Ejemplo Clave	Mapeo de carbono (Troche-Souza) o ID de especies (Monterrubio)	Falla en detección de basura (Maturano)

De este análisis podemos deducir que la causa subyacente de esta divergencia es la naturaleza de los datos, donde, la investigación “verde” se beneficia de la abundancia de datos públicos, estandarizados y globales (imágenes satelitales), la investigación “marrón” requiere datos granulares, localizados, a menudo propietarios o simplemente inexistentes (por ejemplo, generación de residuos en tiempo real, flujos de tráfico, uso de materiales en la industria). Esto nos muestra que el avance de la IA para la sostenibilidad en México está actualmente limitado por la disponibilidad de datos públicos y que si se busca desbloquear el potencial de la IA en la resolución de problemas urbanos e industriales, un esfuerzo nacional concertado para generar, estandarizar y abrir conjuntos de datos “marrones” es un prerrequisito fundamental.

Discusión: patrones de impacto y áreas de oportunidad

El análisis de la producción científica en México revela una adopción tecnológica que, si bien se alinea con ciertas tendencias globales, presenta divergencias críticas marcadas por la infraestructura de datos del país, donde a diferencia de los países del Norte Global, donde la IA se despliega ampliamente en entornos urbanos inteligentes impulsados por el Internet de las Cosas (IoT), México ha concentrado sus éxitos en áreas donde la dependencia de infraestructura terrestre es mínima.

La literatura internacional sugiere que el éxito de la IA en la sostenibilidad depende en gran medida de la capacidad de monitoreo del medio ambiente versus la interacción con sistemas sociales complejos [25]. En este sentido, el dominio de la “IA verde” en México (monitoreo de manglares y bosques) no es un hecho aislado, sino que refleja una capacidad nacional para capitalizar recursos globales, pues, mientras estudios internacionales destacan el uso de DL para modelos climáticos complejos [26], los investigadores mexicanos como Troche-Souza et al. [18] y Valderrama-Landeros et al. [16] han logrado resultados equiparables a los estándares internacionales al integrar datos satelitales abiertos (Sentinel, Landsat) con plataformas de procesamiento en la nube (Google Earth Engine). Esto confirma que, cuando los datos son accesibles y estandarizados globalmente, la ciencia mexicana compete en la frontera del conocimiento, superando las barreras de financiamiento local.

Por otro lado, el contraste con la literatura internacional en la denominada “IA marrón” o gestión urbana es bastante diferente. A nivel global, la gestión de residuos y la economía circular se apoyan en sistemas ciberfísicos, robótica y visión artificial aplicada en planta [27], [28], sin embargo, el estudio de caso de Maturano et al. [20] en Oaxaca ilustra una desconexión

tecnológica forzada por la escasez de datos donde al intentar utilizar herramientas de teledetección (diseñadas para grandes coberturas) para detectar micro-basureros urbanos, se enfrentaron a limitaciones físicas insuperables que no se reportan en estudios donde se utilizan sensores. Esta falla práctica corrobora lo expuesto por Sánchez Yáñez y Márquez Benavides [21]: México intenta resolver problemas de “Smart City” sin la infraestructura de datos de una ciudad inteligente, lo que obliga a la academia a buscar soluciones indirectas que a menudo resultan insuficientes.

Asimismo, existen brechas notables en comparación con las prioridades de investigación global, dado que, mientras investigaciones como las de Amnuaylojaroen [26] y Ezekiel et al. [29] documentan un uso intensivo de la IA para la predicción de energías renovables y resiliencia climática urbana, en México la aplicación reportada es marginal, ausencia que resulta alarmante dado el potencial solar y eólico del país, lo que sugiere una falta de digitalización en el sector energético nacional que inhibe la innovación académica que ya es común en otras latitudes. Del mismo modo, aunque la optimización del nexo agua-energía-alimentos es una prioridad en la agenda de investigación global, en México los esfuerzos como los de López-Flores et al. [22] siguen siendo ejercicios de modelado teórico más que implementaciones de campo, nuevamente limitados por la falta de redes de sensores agrícolas que sí están presentes en la agricultura de precisión de economías desarrolladas [30].

Ante este escenario, la adaptación pragmática emerge como la ruta más viable. En lugar de replicar modelos internacionales que requieren una “dataficación” masiva del territorio, la discusión actual apunta hacia estrategias híbridas. Esto implica, como sugieren Castillo Ortiz et al. [23], combinar la potencia de los datos satelitales globales con “pequeños datos” locales de alta calidad, generados mediante consorcios específicos o ciencia ciudadana, para entrenar modelos que, aunque más simples (como Random Forest), sean robustos ante la incertidumbre local.

Conclusión

En conclusión, tenemos que, a través del análisis de la literatura recabada, se buscó identificar tanto los patrones de impacto donde la IA ya genera resultados tangibles, como las áreas de oportunidad críticas que permanecen sub-exploradas. El hallazgo más significativo del estudio es la revelación de una marcada dicotomía, una narrativa de “dos IAs” que coexisten en el país. Por un lado, la existencia de una “IA verde” que demuestra una madurez creciente y un éxito considerable, enfocada principalmente en el monitoreo ambiental y la conservación de ecosistemas con ejemplos notables incluyendo el mapeo de alta resolución de reservas de carbono en manglares y la clasificación precisa de especies, éxitos que se atribuyen directamente a la confluencia de un fuerte respaldo institucional y la disponibilidad democratizada de datos satelitales públicos a través de plataformas como GEE.

En marcado contraste, la investigación también revela una “IA marrón” que se ocupa de los desafíos urbanos e industriales, como la gestión de residuos sólidos, misma área que en gran medida incipiente, teórica o, en sus aplicaciones prácticas, se enfrenta a fracasos significativos, como la incapacidad de los modelos para distinguir basura de suelo desnudo en imágenes satelitales, concluyendo que esta divergencia no es aleatoria, sino que se debe a una barrera estructural fundamental, donde la “IA verde” prospera gracias a la abundancia de datos públicos y estandarizados, mientras que la “IA marrón” se ve frenada por la escasez crítica de datos granulares, localizados y de alta calidad.

Así mismo, es importante reconocer las limitaciones inherentes a esta revisión. Al basarse en una selección metodológica deliberada de 11 artículos clave publicados a partir de 2020, el panorama trazado es una “fotografía” representativa de las tendencias emergentes, pero de

ningún modo constituye un censo exhaustivo de todo el campo de investigación de la IA en México, sin embargo, también es valioso resaltar que dicha instantánea fue suficiente para identificar brechas evidentes en áreas de inmensa relevancia nacional, como la optimización de energías renovables, la planificación urbana sostenible y el fomento de la economía circular, áreas de estudios sustentable donde aún hay un campo inmenso de exploración con las IA. Las direcciones futuras y estrategias de adaptación propuestas, como el inicio de proyectos piloto en sectores industriales específicos o el uso de modelos más simples con datos censales existentes, se formularon precisamente como respuestas pragmáticas para sortear la escasez de datos identificada.

Finalmente, es relevante subrayar que todas las propuestas realizadas deben entenderse solo como puntos de partida viables y no como un catálogo exhaustivo de soluciones, puesto que la complejidad y particularidad de los desafíos socioambientales de México garantizan que el verdadero potencial de la IA para la sostenibilidad no reside únicamente en la adaptación de modelos internacionales, sino en la innovación continua. El futuro requerirá el surgimiento de nuevas ideas, metodologías y enfoques creativos, específicos para el contexto nacional y las limitaciones locales, que vayan mucho más allá de las estrategias discutidas y que, con toda probabilidad, aún no hemos conceptualizado.

Referencias

- [1] D. Panteli et al., "Artificial intelligence in public health: promises, challenges, and an agenda for policy makers and public health institutions," *The Lancet Public Health*, vol. 10, no. 5, pp. e428–e432, 2025, doi: 10.1016/S2468-2667(25)00036-2.
- [2] M. L. S. da Silva, J. P. Lopes, T. Amadeu, and C. T. Mesquita, "Use of Artificial Intelligence in Scientific Publications," *Int. J. Cardiovasc. Sci.*, vol. 38, p. e20240198, 2025, doi: 10.36660/ijcs.20240198.
- [3] J. L. Uc Castillo et al., "A systematic review of Machine Learning and Deep Learning approaches in Mexico: challenges and opportunities," *Front. Artif. Intell.*, vol. 7, p. 1479855, 2025, doi: 10.3389/frai.2024.1479855.
- [4] D. Bergmann, "What is machine learning?," IBM Think, 2025. [En línea]. Disponible: <https://www.ibm.com/think/topics/machine-learning>.
- [5] D. Bergmann, "What is deep learning?," IBM Think, 2025. [En línea]. Disponible: <https://www.ibm.com/think/topics/deep-learning>.
- [6] M. Faiyazuddin et al., "The impact of artificial intelligence on healthcare: A comprehensive review of advancements in diagnostics, treatment, and operational efficiency," *Health Sci. Rep.*, vol. 8, p. e70312, 2025, doi: 10.1002/hsr2.70312.
- [7] V.-A. Melo-López, A. Basantes-Andrade, C.-B. Gudiño-Mejía, and E. Hernández-Martínez, "The Impact of Artificial Intelligence on Inclusive Education: A Systematic Review," *Educ. Sci.*, vol. 15, no. 5, p. 539, 2025, doi: 10.3390/educsci15050539.
- [8] M. C.-T. Tai, "The impact of artificial intelligence on human society and bioethics," *Tzu Chi Med. J.*, vol. 32, no. 4, pp. 339–343, 2020, doi: 10.4103/tcmj.tcmj_71_20.
- [9] A. M. Porcelli, "La inteligencia artificial y la robótica: sus dilemas sociales, éticos y jurídicos," *Derecho Global. Estudios sobre Derecho y Justicia*, vol. 6, no. 16, pp. 49–105, 2020, doi: 10.32870/dgedj.v6i16.286.
- [10] V. Baños González, "La inteligencia artificial, estudio de su evolución y aplicación en México," *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, vol. 12, no. Especial 4, pp. 250–260, 2024, doi: 10.29057/icbi.v12iEspecial4.13338.
- [11] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [12] E. Kavlakoglu, "What is random forest?," IBM Think, 2025. [En línea]. Disponible: <https://www.ibm.com/think/topics/random-forest>.
- [13] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [14] C. Troche-Souza et al., "Spatial distribution of mangrove forest carbon stocks in Marismas Nacionales, Mexico: Contributions to climate change adaptation and mitigation," *Forests*, vol. 16, no. 8, p. 1224, 2025, doi: 10.3390/f16081224.

- [15] E. Monterrubio-Martínez, R. Trujillo-Acatitla, J. Tuxpan-Vargas, and P. Moreno-Casasola, "An approach for accurate identification and monitoring of species in mangrove forests based on multi-source spectral data and deep learning," *Ecol. Inform.*, vol. 102, p. 102961, 2025, doi: 10.1016/j.ecoinf.2024.102961.
- [16] L. Valderrama-Landeros et al., "An assessment of mangrove forest in northwestern Mexico using the Google Earth Engine cloud computing platform," *PLOS ONE*, vol. 19, no. 12, p. e0315181, 2024, doi: 10.1371/journal.pone.0315181.
- [17] J. Aviña Hernández, A. J. Sánchez, and R. Rodríguez, "Evaluación del rendimiento predictivo del algoritmo Random Forest en la identificación de especies de manglares en ambientes áridos," *Ecol. Inform.*, vol. 75, p. 102040, 2023, doi: 10.1016/j.ecoinf.2023.102040.
- [18] M. T. Rodríguez-Zúñiga et al., "Development and Structural Organization of Mexico's Mangrove Monitoring System (SMMM) as a Foundation for Conservation and Restoration Initiatives: A Hierarchical Approach," *Forests*, vol. 13, no. 4, p. 621, abr. 2022, doi: 10.3390/f13040621.
- [19] L. Valderrama-Landeros et al., "Extrapolating canopy phenology information using Sentinel-2 data and the Google Earth Engine platform to identify the optimal dates for remotely sensed image acquisition of semiarid mangroves," *J. Environ. Manage.*, vol. 279, p. 111617, 2021, doi: 10.1016/j.jenvman.2020.111617.
- [20] J. Gómez Maturano, J. D. Mendoza Santana, A. L. Aguilar García, and M. Serna Hernández, "Remote sensing of illegal dumps through supervised classification of satellite images: application in Oaxaca, Mexico," *Cuad. Investig. Geográfica*, vol. 50, no. 2, pp. 157–171, 2024, doi: 10.18172/cig.6273.
- [21] J. M. Sánchez Yáñez and L. Márquez Benavides, "Gestión de residuos sólidos y la inteligencia artificial en el contexto mexicano," *Cienc. Nicolaita*, no. 90, 2024, doi: 10.35830/cn.vi90.722.
- [22] F. J. López-Flores, X. G. Sánchez-Zarco, E. Rubio-Castro, and J. M. Ponce-Ortega, "A machine learning approach for optimizing the water-energy-food-ecosystem nexus: A resilience perspective for sustainability," *Environ. Dev. Sustain.*, vol. 27, no. 4, pp. 8863–8891, 2025, doi: 10.1007/s10668-023-04257-y.
- [23] S. Y. Castillo Ortiz et al., "Optimización del sector agrícola mediante el análisis de datos para una gestión eficiente de los recursos naturales: una perspectiva para México," *Ciencia Latina Rev. Cient. Multidiscip.*, vol. 9, no. 2, pp. 241–257, 2025, doi: 10.37811/cl_rcm.v9i2.16816.
- [24] S. G. Mengual Torres et al., "Analysis of Energy and Environmental Indicators for Sustainable Operation of Mexican Hotels in Tropical Climate Aided by Artificial Intelligence," *Buildings*, vol. 12, no. 8, p. 1155, 2022, doi: 10.3390/buildings12081155.
- [25] R. Vinuesa et al., "The role of artificial intelligence in achieving the Sustainable Development Goals," *Nat. Commun.*, vol. 11, p. 233, 2020, doi: 10.1038/s41467-019-14108-y.
- [26] T. Amnuaylojaroen, "Advancements and challenges of artificial intelligence in climate modeling for sustainable urban planning," *Front. Artif. Intell.*, vol. 8, p. 1517986, 2025, doi: 10.3389/frai.2025.1517986.
- [27] M. Despotović and M. Glatschke, "Challenges and Opportunities of Artificial Intelligence and Machine Learning in Circular Economy," *SocArXiv*, 2024, doi: 10.31219/osf.io/6qmhf.
- [28] M. Wilson, J. Paschen, and L. Pitt, "The circular economy meets artificial intelligence (AI): Understanding the opportunities of AI for reverse logistics," *Manage. Environ. Qual.*, vol. 33, no. 1, pp. 9–25, 2022, doi: 10.1108/MEQ-10-2020-0222.
- [29] P. I. Ezekiel, N. Dienagha, W. N. Digitemie, E. C. Onukwulu, and O. T. Oladipo, "Artificial Intelligence (AI) in renewable energy forecasting and optimization," *World J. Adv. Eng. Technol. Sci.*, vol. 15, no. 2, pp. 1100–1112, 2025, doi: 10.30574/wjaets.2025.15.2.0300.
- [30] F. Mortazavizadeh et al., "Advances in machine learning for agricultural water management: A review of techniques and applications," *J. Hydroinformatics*, vol. 27, no. 3, pp. 474–492, 2025, doi: 10.2166/hydro.2025.258. [30] M. Wilson, J. Paschen, and L. Pitt, "The circular economy meets artificial intelligence (AI): Understanding the opportunities of AI for reverse logistics," *Management of Environmental Quality: An International Journal*, vol. 33, no. 1, pp. 9–25, 2022. doi: [10.1108/MEQ-10-2020-0222](https://doi.org/10.1108/MEQ-10-2020-0222)
- [31] R. Vinuesa, H. Azizpour, I. Leite, M. Balaam, V. Dignum, S. Domisch, et al., "The role of artificial intelligence in achieving the Sustainable Development Goals," *Nature Communications*, vol. 11, p. 233, 2020. doi: 10.1038/s41467-019-14108-y

Declaración sobre uso de Inteligencia Artificial (IA)

Los autores aquí firmantes declaramos que no se utilizó ninguna herramienta de IA para la conceptualización, traducción o redacción de este artículo.