

1
A



DESDE LOS CIMIENTOS

DESAFÍOS Y OPORTUNIDADES EN EL CONTEXTO
DE AMÉRICA LATINA Y EL CARIBE

IA DESDE LOS CIMIENTOS

DESAFÍOS Y OPORTUNIDADES EN EL CONTEXTO
DE AMÉRICA LATINA Y EL CARIBE

Autores

Guillermo Cruz
Alexander Riobó
María Angélica Pfeifer
Diana Duarte

Diseño y diagramación

.Puntoaparte

Diciembre 2024

Catalogación en la fuente proporcionada por la

Biblioteca Felipe Herrera del

Banco Interamericano de Desarrollo

IA desde los cimientos: desafíos y oportunidades en el contexto de América Latina y el Caribe / Guillermo Cruz, Alexander Riobó, María Angélica Pfeifer, Diana Duarte.

p. cm. — (Monografía del BID ; 1247)

Incluye referencias bibliográficas.

1. Artificial intelligence-Latin America. 2. Artificial intelligence-Caribbean Area. 3. Infrastructure (Economics)-Effect of technological innovations on-Latin America. 4. Infrastructure (Economics)-Effect of technological innovations on-Caribbean Area. I. Cruz, Guillermo. II. Riobó Patino, Alexander. III. Pfeifer, María Angélica. IV. Duarte, Diana. V. Banco Interamericano de Desarrollo. División de Transporte. VI. Banco Interamericano de Desarrollo. División de Energía. VII. Banco Interamericano de Desarrollo. División de Agua y Saneamiento. VIII. Banco Interamericano de Desarrollo. Sector de Infraestructura y Energía. IX. Serie.

IDB-MG-1247

Palabras Claves: Inteligencia Artificial, infraestructura inteligente, transformación digital, Deep learning / Códigos JEL: 031, 032, 033

Diseño y diagramación: .Puntoaparte

Diciembre 2024

Copyright © **2024** Banco Interamericano de Desarrollo (BID). Esta obra se encuentra sujeta a una licencia Creative Commons CC BY 3.0 IGO (<https://creativecommons.org/licenses/by/3.0/igo/legalcode>). Se deberá cumplir los términos y condiciones señalados en el enlace URL y otorgar el respectivo reconocimiento al BID.

En alcance a la sección 8 de la licencia indicada, cualquier mediación relacionada con disputas que surjan bajo esta licencia será llevada a cabo de conformidad con el Reglamento de Mediación de la OMPI. Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la Comisión de las Naciones Unidas para el Derecho Mercantil (CNUDMI). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID, no están autorizados por esta licencia y requieren de un acuerdo de licencia adicional.

Note que el enlace URL incluye términos y condiciones que forman parte integral de esta licencia.

Las opiniones expresadas en esta obra son exclusivamente de los autores y no necesariamente reflejan el punto de vista del BID, de su Directorio Ejecutivo ni de los países que representa.



CONTENIDO



Índice de figuras y tablas

Figura 1. Sistema de Inteligencia Artificial

9

Figura 2. Aprendizaje Automático en Sistemas de IA.

12

Figura 3. Representación de una red neuronal de una sola capa (Perceptrón)

13

Figura 4. Modelo de redes neuronales multi-capa

14

Figura 5. Esquema de los tres principales tipos de aprendizaje en ML

18

Figura 6. Descripción del caso Pavimenta2

29

Figura 7. Descripción del caso VíaSegura

31

Figura 8. Descripción del caso Energizados

34

Figura 9. Descripción del caso Aquadata

39

Figura 10. Esquema del Enfoque de Desarrollo e Innovación Ágil

46

Figura 11. Pipeline de datos

56

Tabla 1. Marcos regulatorios de protección de datos en Latinoamérica

77

Tabla 2. Marcos regulatorios de IA en Latinoamérica

81

Glosario de acrónimos

ALC	América Latina y el Caribe	GPS	Global Positioning System
ANN	Redes Neuronales Artificiales	GPU	Unidad de Procesamiento Gráfico
API	Application Programming Interface	IA	Inteligencia Artificial
ATMS	Sistemas Avanzados de Gestión de Tráfico	iRAP	International Road Assessment Program
BID	Banco Interamericano de Desarrollo	IoT	Internet de las Cosas
CAF	Banco de Desarrollo de América Latina y el Caribe	LLM	Large Language Models
CNN	Redes Neuronales Convolucionales	ML	Machine Learning
DL	Deep Learning	MVP	Producto Mínimo Viable
DNP	Departamento de Planeación Nacional de Colombia	NLP	Procesamiento de Lenguaje Natural
DT	Digital Twins	OECD	Organización para la Cooperación y el Desarrollo Económico
EPMAPS	Empresa Pública Metropolitana de Agua Potable y Saneamiento de Quito	SVM	Máquina de Soporte Vectorial
ETL	Extract Transform Load	UAVs	Unmanned Aerial Vehicles
FEM	Foro Económico Mundial	UPS	Uninterruptible Power Supply
FMI	Fondo Monetario Internacional	YOLO	You Only Look Once



INTRODUCCIÓN

La Inteligencia Artificial (IA) ha adquirido una relevancia crucial por su capacidad de transformar de manera significativa diversos sectores económicos y múltiples dimensiones de la sociedad. El impacto potencial de esta tecnología es tal que en el contexto internacional se ha señalado¹ que se encuentra en camino de convertirse en una tecnología de propósito general, como en el pasado han sido catalogados la máquina de vapor, la electricidad, la informática e Internet.



¹ Ver, por ejemplo, la Recomendación del Concejo de la OECD sobre Inteligencia Artificial OECD/LEGAL/0449

El crecimiento exponencial en la capacidad de cómputo y la consecuente reducción en los costos asociados, en adición a la digitalización de la información y al despliegue de Internet, ha sido un factor fundamental que ha posibilitado que esta tecnología ahora esté al alcance de los gobiernos y organizaciones en los diferentes sectores económicos. En este contexto, recientemente, diferentes empresas y entidades en los sectores de energía, transporte y agua, saneamiento y residuos sólidos, han venido adoptando soluciones basadas en IA para propósitos estratégicos y misionales, entre los que se encuentran la mejora en la planeación de los sistemas, la optimización de la operación y el mantenimiento de los activos, la reducción de costos y la prestación de mejores servicios. Estas nuevas posibilidades de creación de valor habilitadas por la IA resultan de alta importancia para los países, los gobiernos y para las organizaciones públicas y privadas, dado que los servicios prestados por estos sectores son críticos para el crecimiento económico, y para el normal funcionamiento de las sociedades.

Este documento ofrece un conjunto de recomendaciones y consideraciones técnicas para el desarrollo y adopción de soluciones basadas en IA en los sectores de infraestructura. Estas recomendaciones se fundamentan en evidencia global, la experiencia del BID y las lecciones aprendidas del

despliegue de herramientas en América Latina y el Caribe (ALC). Para la elaboración de esta publicación se realizaron 17 entrevistas con equipos técnicos del BID, así como con clientes y actores externos, con experiencia en desarrollo e implementación de soluciones de tecnologías emergentes e IA. Adicionalmente, se incluye como anexo la revisión de los marcos regulatorios aplicables a la IA en ALC.

El objetivo de la publicación es proporcionar enfoques conceptuales y metodológicos a líderes, formuladores de políticas, equipos misionales, unidades tecnológicas del sector público y privado, desarrolladores y demás actores del ecosistema emprendedor, que contribuyan a fortalecer el diseño y desarrollo de soluciones en los sectores de infraestructura y a maximizar las oportunidades que la IA ofrece en este ámbito.

El documento concluye con un conjunto de recomendaciones para el desarrollo e implementación exitosas de estas soluciones en ALC. Dentro de las principales recomendaciones se encuentran: (i) implementar metodologías ágiles de desarrollo e innovación de IA y considerar la realización de pruebas de concepto, prototipos y productos mínimos viables, los cuales representan espacios de experimentación, aprendizaje y retroalimentación para la mejora de las

soluciones, (ii) definir esquemas organizacionales que habiliten el desarrollo y adopción de estas soluciones, así como evaluar y garantizar la existencia de las habilidades necesarias en los equipos, (iii) entender la importancia de los datos y su gobernanza, y en este sentido determinar los datos necesarios, fuentes disponibles, la arquitectura y el flujo de los mismos, (iv) identificar y evaluar desde el diseño los requerimientos de herramientas tecnológicas e infraestructura de datos para el desarrollo de soluciones, en especial las capacidades de almacenamiento y procesamiento de datos, (v) definir criterios objetivos para la selección de los modelos, asociados a la naturaleza del problema, el tipo y calidad de la información, la capacidad computacional, los objetivos de rendimiento y la explicabilidad, entre otros, y (vi) prestar especial atención a los aspectos éticos, de privacidad y seguridad desde las etapas iniciales del diseño.



¿QUÉ ES INTELIGENCIA ARTIFICIAL?

2.1

Definición de Inteligencia Artificial

El concepto de IA ha sido de común utilización en la disciplina de la informática desde los años cuarenta (40), a partir de los trabajos de profesores como Alan Turing² y John Von Newman³, entre otros. Específicamente, dicho concepto nació en un taller realizado en el Dartmouth College en el año 1956 que contó con la participación de expertos como John McCarthy, Alan Newell, Arthur Samuel, Herbert Simon y Marvin Minsky, a quienes se les atribuye el término (OECD, 2019; Wang, 2019).



2 Alan Turing en su trabajo "Computing Machinery and Intelligence" (1950), planteó la pregunta "¿pueden las máquinas pensar?", para lo que desarrolló un juego -"The Imitation Game"-, conocido después como el "Test de Turing", en donde a partir de una serie de preguntas el investigador podía determinar si su interlocutor era un humano o una máquina.

3 John Von Neumann desarrolló una serie de principios matemáticos con el fin de construir un computador que pudiera realizar cálculos complejos en poco tiempo y que incluso pudiera contribuir a solucionar problemas más estructurales.

Diferentes organizaciones en el ámbito internacional han propuesto definiciones de IA que comparten ciertos componentes pero que también incluyen elementos específicos. El Instituto de Ingenieros Eléctricos y Electrónicos (IEEE) define la IA como “la teoría y el desarrollo de sistemas informáticos capaces de realizar tareas que normalmente requieren inteligencia humana, como la percepción visual, el reconocimiento del habla, el aprendizaje, la toma de decisiones y el procesamiento del lenguaje natural” (IEEE-USA, 2017).

El BID⁴ en diferentes documentos se ha referido a la IA como un concepto amplio que incluye tecnologías en los computadores que pueden emular destrezas típicas de los humanos⁵. Esta definición hace referencia a los sistemas informáticos que pueden identificar el entorno que los rodea, pensar, aprender y decidir en función de los insumos obtenidos y de los propósitos del modelo⁶. El Banco Mundial

define la IA como la capacidad de los sistemas informáticos para realizar tareas asociadas a la inteligencia humana como la vista, el habla y el lenguaje, y el conocimiento y la búsqueda (Banco Mundial, 2020), mientras que la CAF (Corporación Andina de Fomento) señala que la IA “es un campo de estudio que se refiere a la creación, a partir del uso de tecnologías digitales, de sistemas capaces de desarrollar tareas para las que se considera que se requiere inteligencia humana” (Vélez *et al.*, 2022).

La Unión Europea considera que un sistema de IA requiere un nivel mínimo de autonomía y que, mediante datos proporcionados por máquinas y/o personas, infiere el proceso para cumplir con los propósitos definidos por el ser humano. Esto lo hace mediante aproximaciones del conocimiento, de aprendizaje automático y/o la lógica. Los resultados generados incluyen contenidos, recomendaciones, decisiones o predicciones, que a su vez modifican lo que rodea al sistema de IA⁷.

Así mismo, la Organización para la Cooperación y el Desarrollo Económicos (OECD) define la IA como un sistema automatizado que infiere a partir de insumos cómo crear productos con base en objetivos explícitos o implícitos. Los productos generados incluyen contenidos, decisiones, pronósticos, y recomendaciones. Un sistema de IA puede ser representado a partir de sus componentes y la forma en que interactúa con el ambiente, en términos de insumos y resultados (**Figura 1**).

La definición de la OECD se refiere a objetivos explícitos del modelo cuando los programa directamente un desarrollador humano, mientras que son implícitos cuando se desarrollan a través de un conjunto de reglas definidas por un humano, o cuando el sistema puede aprender nuevos objetivos⁸.

4 En otros documentos, como, por ejemplo, *Uso responsable de la IA para las políticas públicas: Manual de ciencia de datos*, esta entidad hace referencia a la definición planteada por la Organización para la Cooperación y el Desarrollo Económicos (OECD) que se expone en el presente documento.

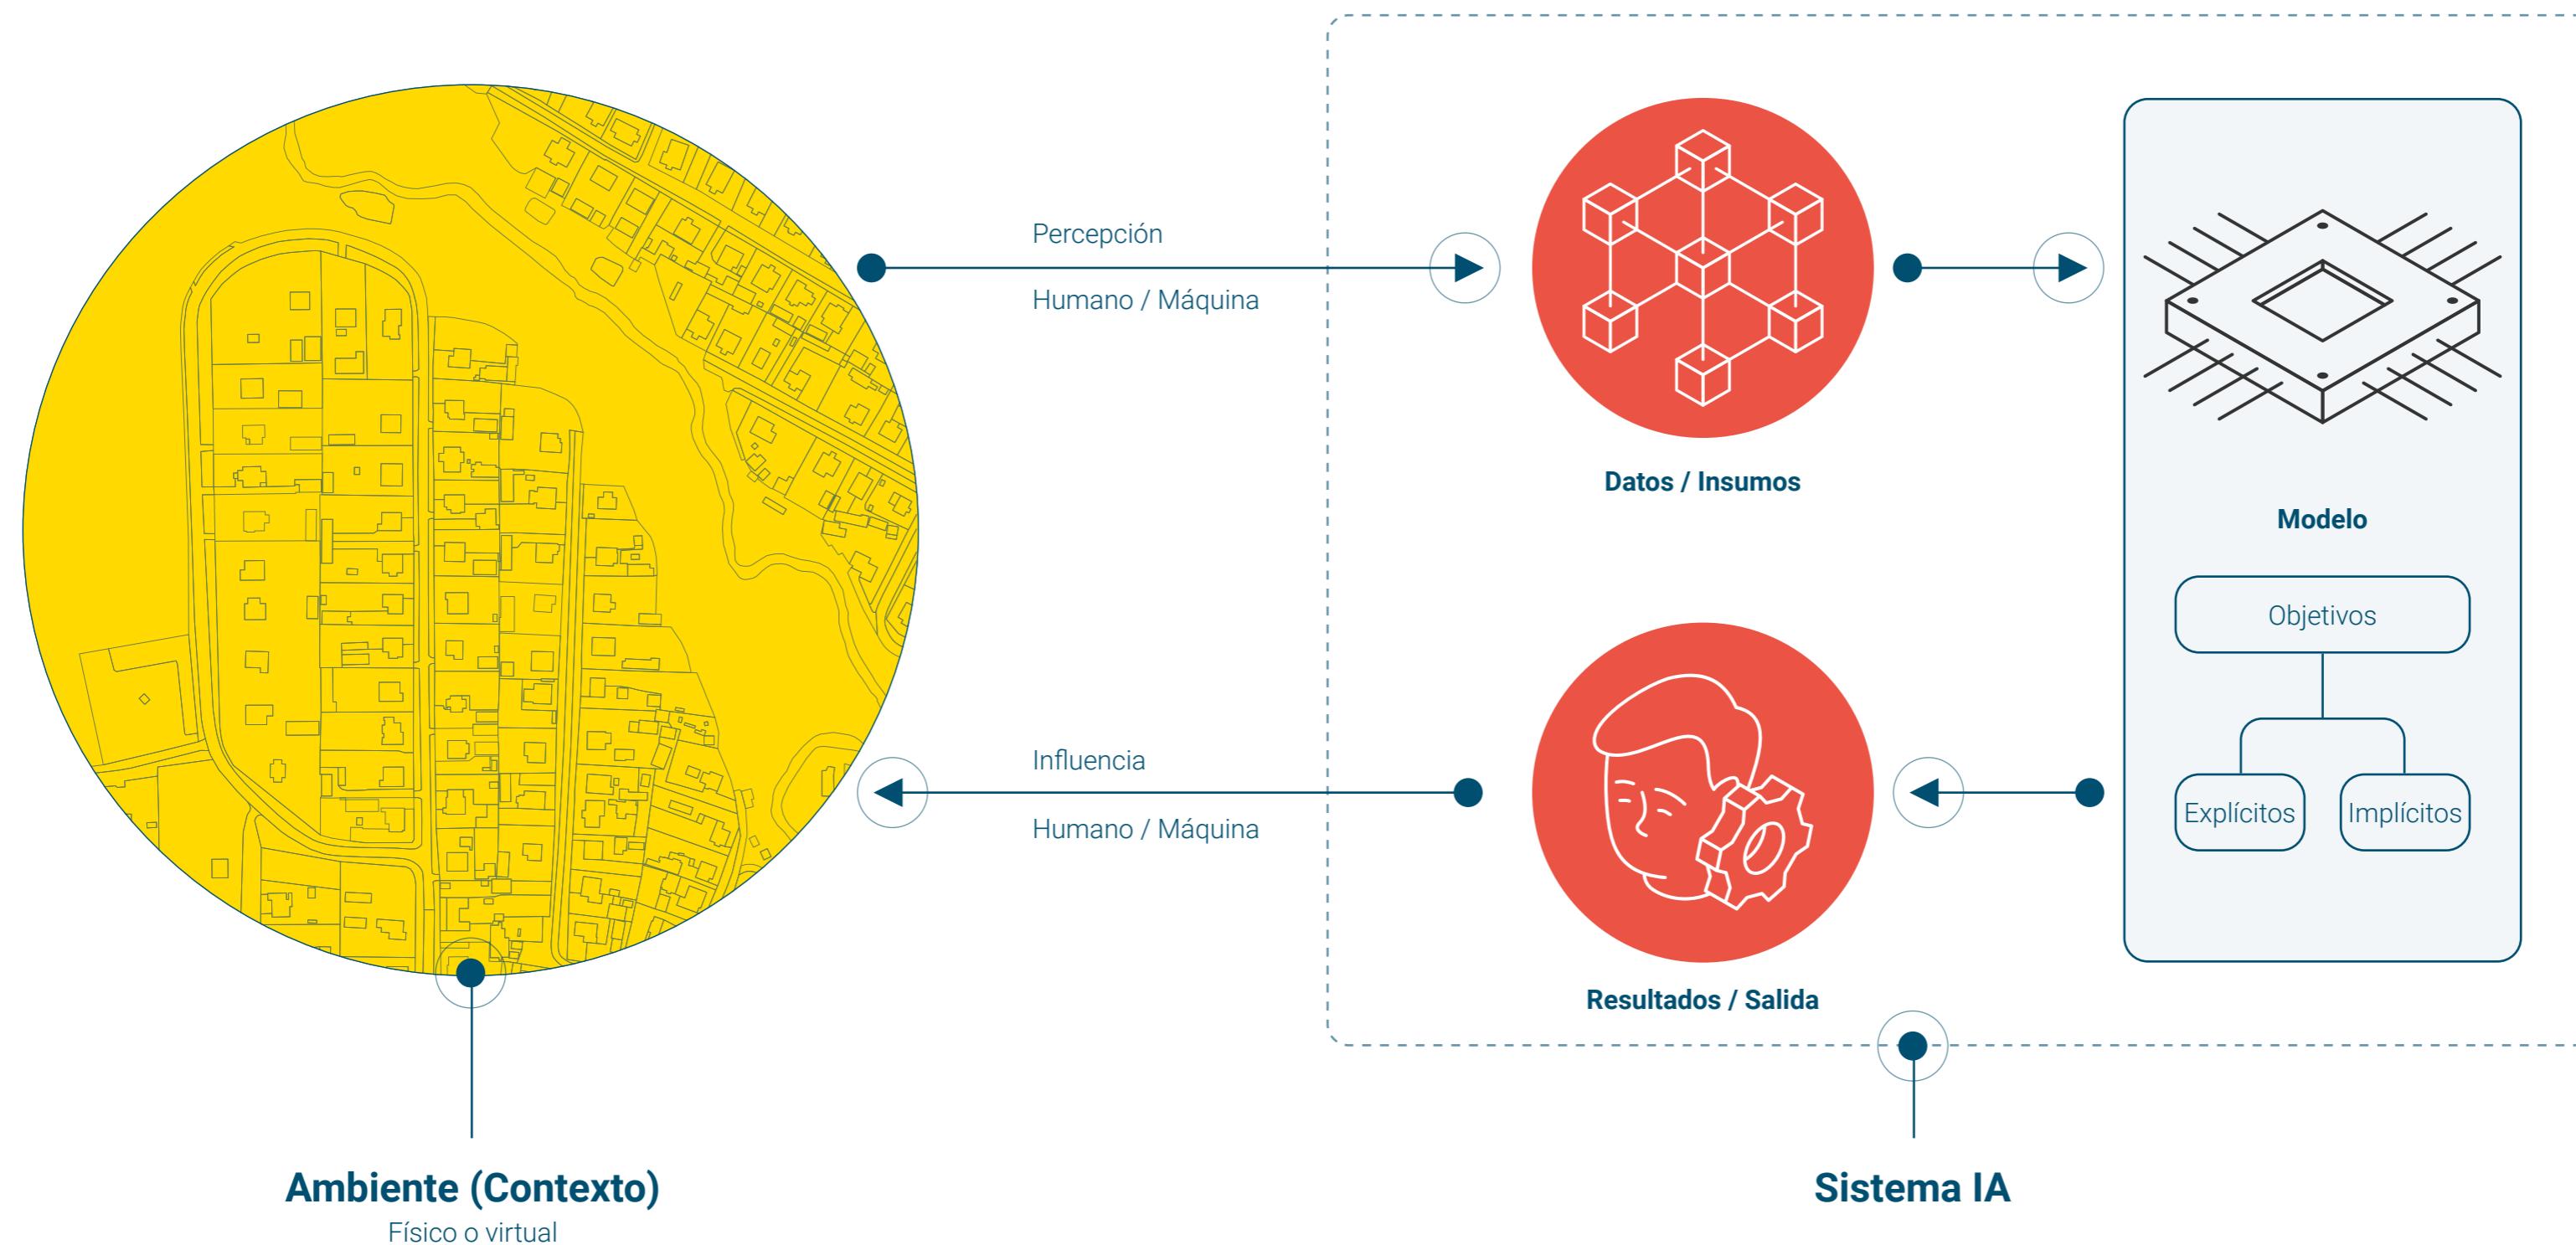
5 Inteligencia artificial: conceptos básicos y aplicaciones en el desarrollo. (2019, febrero). Recuperado de <<https://blogs.iadb.org/conocimiento-abierto/es/inteligencia-artificial/>>

6 Inteligencia artificial: qué aporta y qué cambia en el mundo del trabajo. (2022,

septiembre). Recuperado de <<https://blogs.iadb.org/trabajo/es/inteligencia-artificial-que-aporta-y-que-cambia-en-el-mundo-del-trabajo/>>

7 The EU Artificial Intelligence Act. Recuperado de <[https://www.artificial-intelligence-act.com/#:~:text='Artificial%20intelligence%20system'%20\(AI,logic%2D%20and%20knowledge%20based%20approaches%2C](https://www.artificial-intelligence-act.com/#:~:text='Artificial%20intelligence%20system'%20(AI,logic%2D%20and%20knowledge%20based%20approaches%2C)>

8 *Ibidem*.

Figura 1. Sistema de Inteligencia Artificial

De otra parte, en términos generales los sistemas de IA pueden ser categorizados en tres tipos dependiendo de sus funcionalidades y capacidades:



Inteligencia Artificial estrecha o débil (Narrow AI):

Todos los desarrollos hasta hoy conocidos de IA se encuentran dentro de esta clasificación. Los sistemas de IA estrecha tienen la capacidad de cumplir con una tarea o función concreta (OECD, 2019; Pombo *et al.*, 2020; Vélez *et al.*, 2022) sin tener conciencia, sensibilidad, ni estar influenciados por las emociones (Vélez *et al.*, 2022). No obstante, en el caso de la IA Generativa, los modelos fundacionales de herramientas como ChatGPT, Gemini o MetaAI, pueden adaptar sus respuestas para simular ser empáticos con sus usuarios⁹.



Inteligencia Artificial General (General or Strong AI):

Hace referencia a los sistemas que tienen la capacidad de entender y realizar tareas en diferentes áreas del conocimiento como lo hacen los humanos, incluso teniendo capacidades cognitivas similares (OECD, 2019; Pombo *et al.*, 2020; Vélez *et al.*, 2022). Hasta el momento estos sistemas siguen siendo netamente teóricos.



Inteligencia Artificial Superinteligente (Superintelligent AI):

Es el tercer tipo de IA que podría superar en todas las facetas la capacidad cognitiva de los seres humanos (Pombo *et al.*, 2020). Este sistema sigue siendo especulativo y aún no cuenta con modelos teóricos sólidos que avizoren desarrollos en el corto plazo.

⁹ Fuente: Conversaciones con ChatGPT, Gemini y MetaAI acerca de sentimientos y emociones

2.2

Tipos de sistemas de IA

Por lo general, la literatura hace referencia a un conjunto amplio de sistemas de IA que incluye como subcomponentes el *Aprendizaje Automático* (*Machine Learning - ML*) y el *Aprendizaje Profundo* (*Deep Learning*). Existen sistemas de IA que no son considerados como Machine Learning, debido a que no están basados en el entrenamiento de modelos a partir de datos; algunos ejemplos de IA que no es considerada ML son los sistemas expertos¹⁰, los algoritmos genéticos¹¹ y los algoritmos de búsqueda¹², entre otros¹³.

A continuación, se presenta una descripción general de los conceptos de Aprendizaje Automático (*Machine Learning - ML*), Aprendizaje Profundo (*Deep Learning - DL*), y, en relación con este último, la IA Generativa (*Generative AI*):

● **Aprendizaje Automático (*Machine Learning - ML*):** Hace referencia a los métodos computacionales que por medio de la experiencia pueden aumentar su rendimiento o lograr una mayor precisión en las predicciones (Mohri *et al.*, 2018). En particular, la experiencia se entiende como la información que se utiliza para que el modelo aprenda (Mohri *et al.*, 2018). Así, los modelos de ML tienen la capacidad de resolver problemas mediante el descubrimiento de patrones a partir de ejemplos, en vez de ser programados explícitamente para ello (Li, 2023)¹⁴.

10 Estos pueden ser definidos como "Sistemas de información avanzados que modelan la experticia en un ámbito específico para imitar los procesos de toma de decisiones de los expertos" Fuente: ScienceDirect. Disponible en: <<https://www.sciencedirect.com/topics/social-sciences/expert-systems>>

11 Como se menciona en la sección 3.2.2, un algoritmo genético es una técnica de búsqueda computacional para encontrar soluciones aproximadas a modelos de optimización y problemas de búsqueda. Está inspirado en el proceso de evolución natural, en donde se seleccionan las mejores soluciones para un problema, se combinan y se mutan para crear nuevas soluciones, todo dentro un proceso iterativo que se detiene cuando encuentra la mejor solución posible. Fuente: <<https://www.sciencedirect.com/topics/engineering/genetic-algorithm>>

12 Los algoritmos de búsqueda son métodos computacionales que se utilizan para ubicar datos específicos en una colección de datos. Definición basada en: Rouse. (2017). *Search Algorithm*. Techopedia. Disponible en: <<https://www.techopedia.com/definition/21975/search-algorithm>>

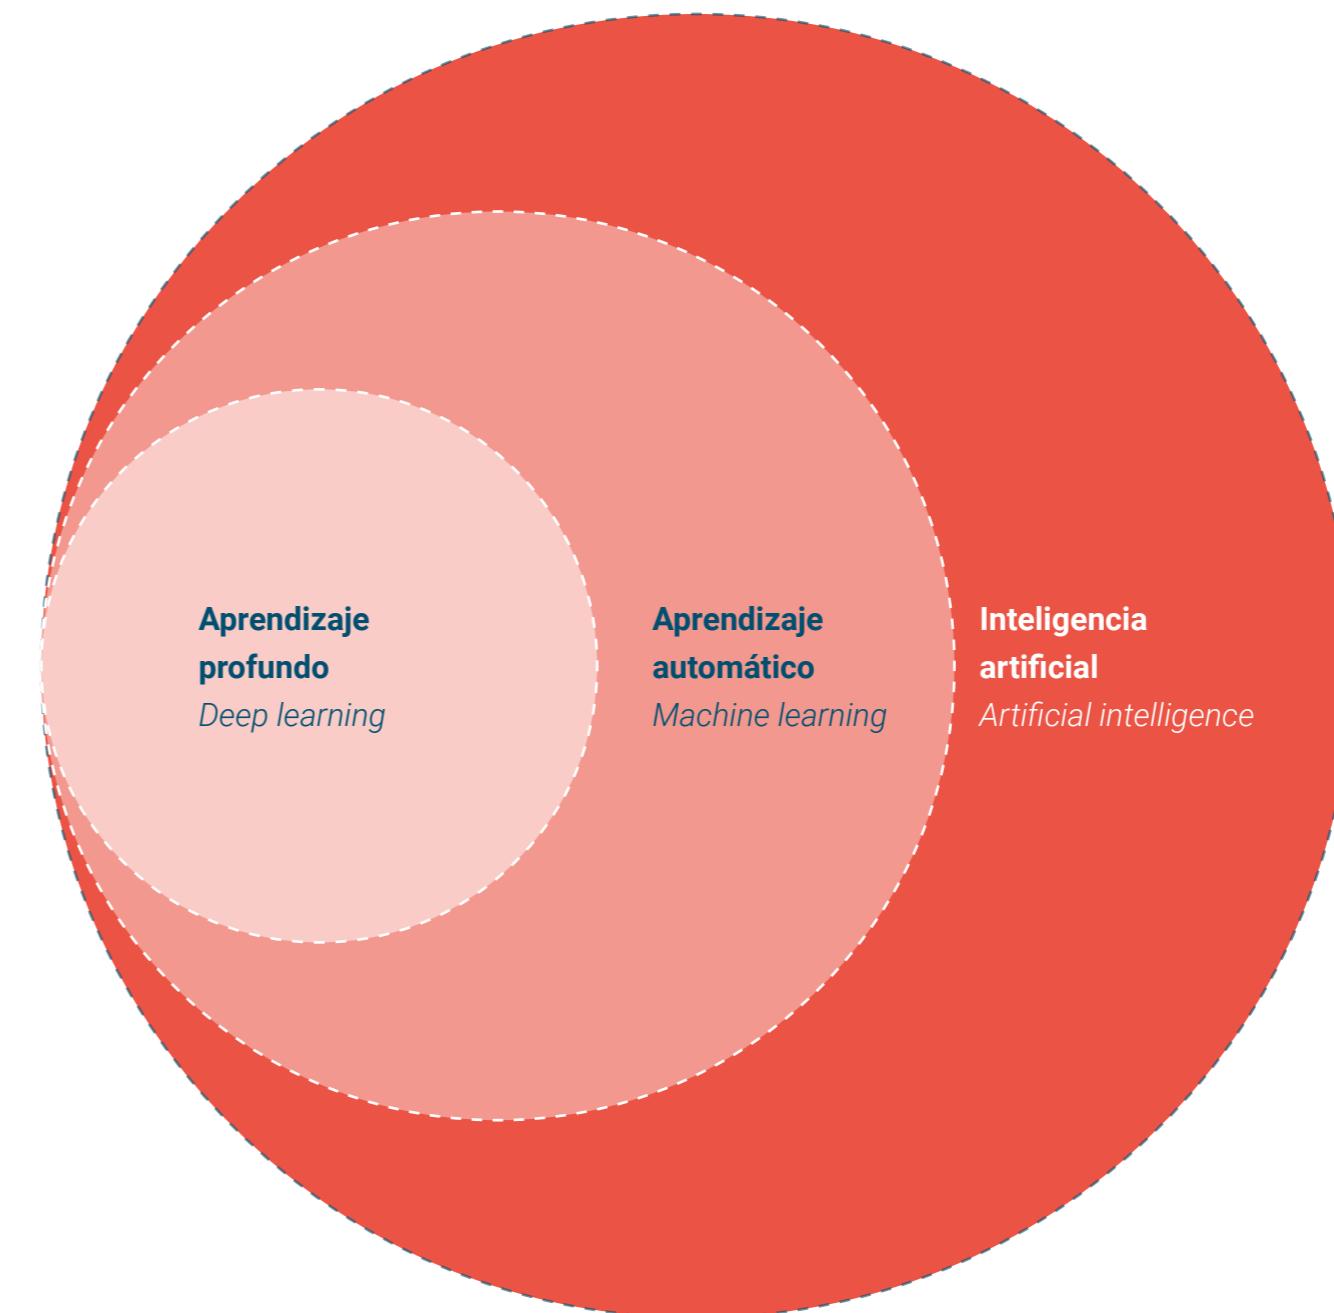
13 William E. (2023). *Non machine learning AI Examples*. Medium. Disponible en <<https://emmawilliam.medium.com/non-machine-learning-ai-examples-3e8c8fd85149>>

Por ejemplo, en una inspección de infraestructura de la red de energía eléctrica, una empresa de transmisión o distribución puede entrenar un modelo con imágenes de los elementos de la red averiados y con aquellos en perfecto estado, con el fin de crear un clasificador que detecte con cierto nivel de precisión la infraestructura que pueda llegar a estar desgastada o con algún componente anómalo, de tal manera que se realicen los mantenimientos preventivos y correctivos de manera oportuna. Como se puede inferir del ejemplo, los modelos de ML se fundamentan en la información que se utilice para entrenarlos, es decir, los datos con los que el modelo aprende por sí mismo.

14 Li, F. (2023) *The worlds I see: Curiosity, Explorations, and Discovery at the Dawn of AI*. Chapter 3.

Usualmente en infraestructura, los datos¹⁵ de insumo más utilizados suelen estar agrupados en series de tiempo¹⁶ y en catálogos de imágenes¹⁷. Aunque existe una variedad significativa de modelos dentro de la familia de ML, en términos generales estos tienen la capacidad de alimentarse de insumos relativamente sencillos, como series numéricas, y encontrar patrones entre ellas para predecir un valor que sea fácilmente interpretable por el usuario. La **Figura 2** presenta, en términos generales, la cascada de subconjuntos de sistemas que conforman los sistemas de Inteligencia Artificial, Aprendizaje Automático y Aprendizaje Profundo.

Figura 2. Aprendizaje Automático en Sistemas de IA.



Fuente: AWS¹⁸

15 Algunos ejemplos de tipos de datos utilizados en sistemas de infraestructura son: temperatura, presión, voltaje, caudal de agua, precipitación pluvial, unidades de consumo de agua o de energía, humedad, velocidad del viento, radiación solar, tráfico de vehículos, frecuencia de rutas, ubicación geoespacial, emisiones contaminantes, tarifas de servicios, entre otros.

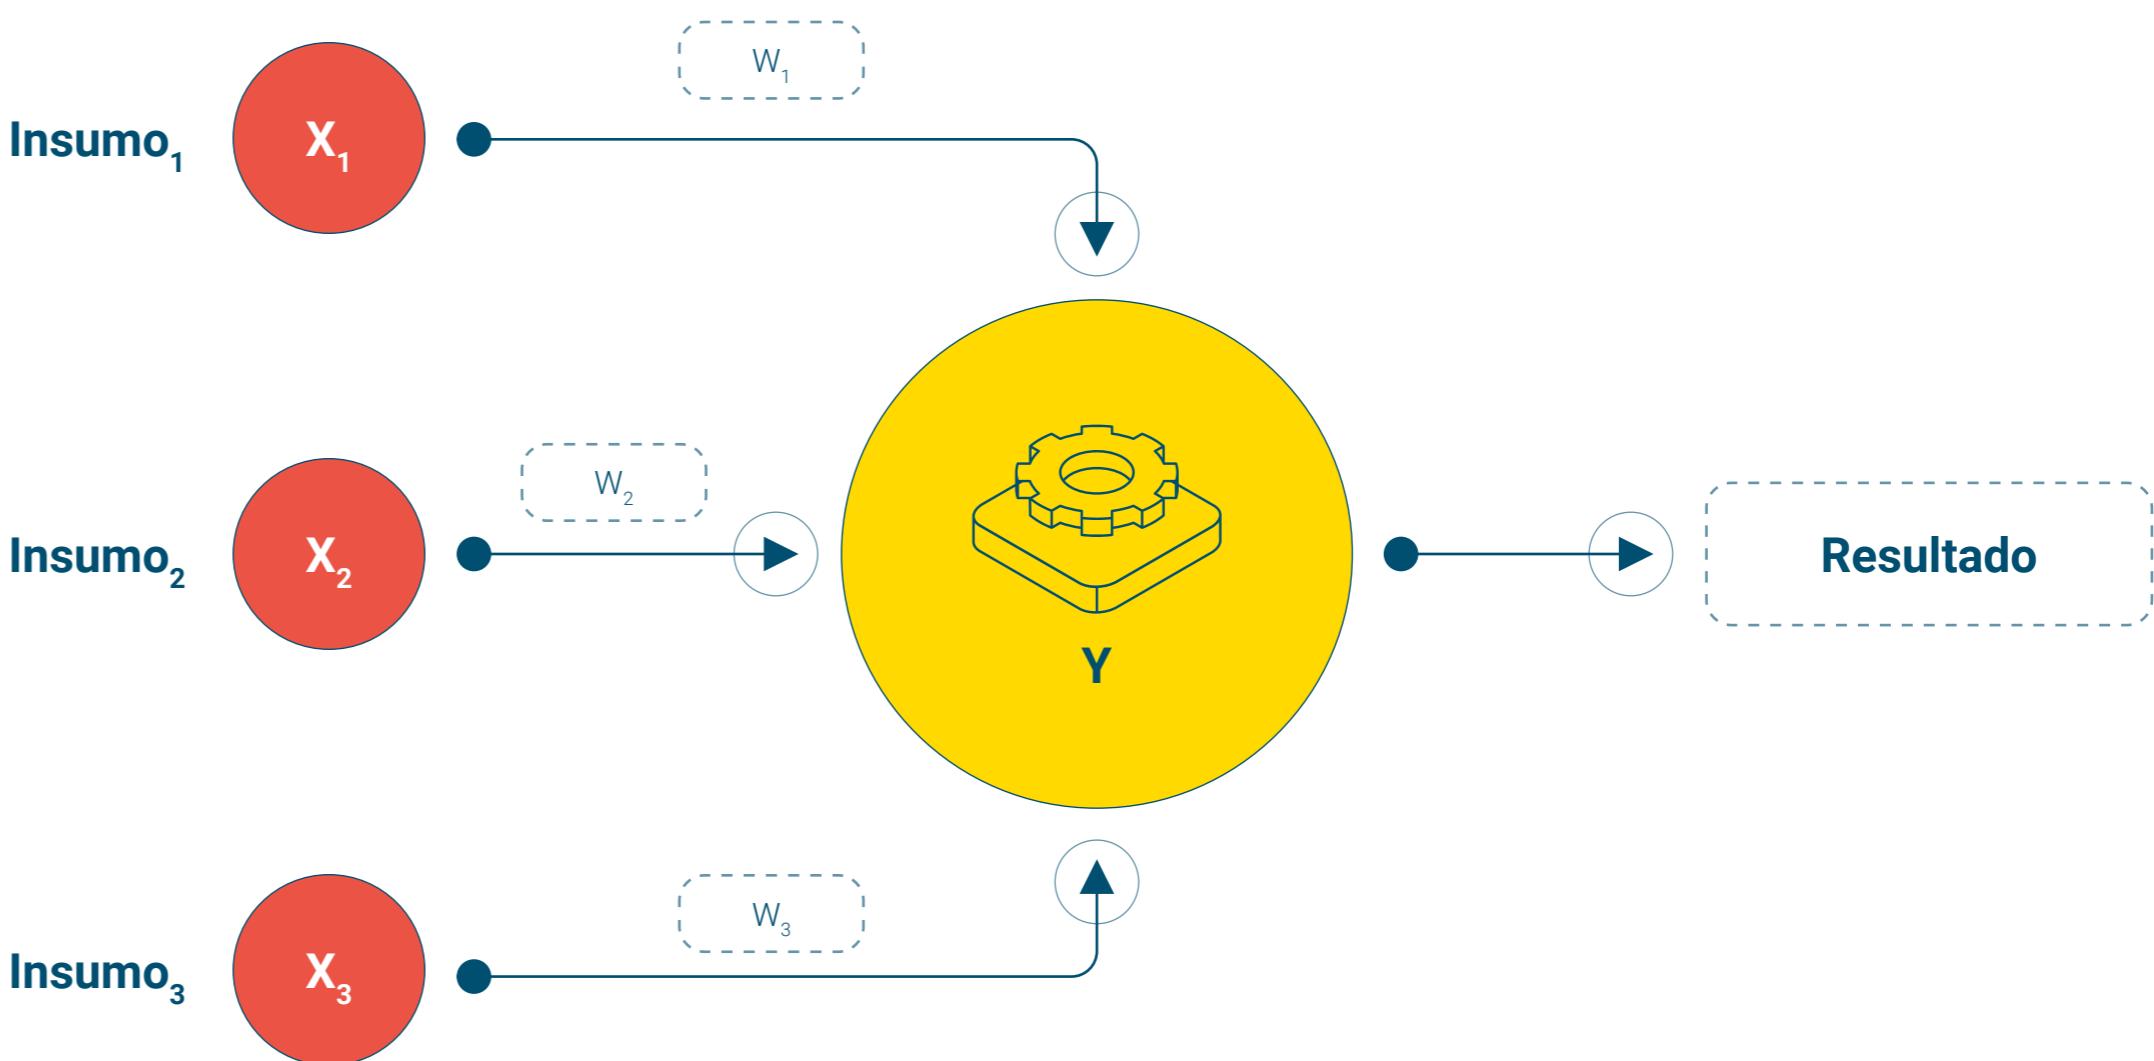
16 Las series de tiempo pueden ser definidas como una secuencia ordenada de valores de una variable distribuida en intervalos de tiempo igualmente espaciados. Fuente: National Institute of Standards and Technology. Disponible en: <<https://www.itl.nist.gov/div898/handbook/pmc/section4/pmc41.htm>>

17 Las imágenes pueden consistir en material fotográfico, mapas geoespaciales, planos técnicos, diagramas de red, termografías, radiografías, modelos 3D de infraestructuras o renderizaciones arquitectónicas, entre otros.

18 AWS. What is Artificial Intelligence (AI)? Recuperado de <<https://aws.amazon.com/what-is/artificial-intelligence/>>

- **Aprendizaje Profundo (Deep Learning - DL):** El concepto de Aprendizaje Profundo está directamente relacionado con el de redes neuronales. La investigación sobre Redes Neuronales Artificiales (ANN) ha estado motivada por la observación de que la inteligencia humana surge de redes de neuronas no-lineales y relativamente simples, que aprenden mediante ajustes a la fortaleza de sus conexiones (Bengio et al., 2021)¹⁹. En la **Figura 3** se representa una red neuronal de una sola capa (la abstracción más simple posible), en donde cada esfera representa una neurona o nodo. Los insumos son características o atributos de la información que se está analizando. Los pesos, que están identificados con una W_n , representan la importancia que el modelo le está dando a cada insumo para producir el resultado. Así como pasa con las neuronas, la señal eléctrica debe ser lo suficientemente fuerte para poder transmitir la información a la otra neurona. En el caso del modelo, el cómputo entre los insumos y los pesos deben pasar un

Figura 3. Representación de una red neuronal de una sola capa (Perceptrón)



19 Bengio, Y., LeCun, Y., & Hinton G. (2021). Deep Learning for AI. Communications of the ACM, 64(7), 58-65. <http://dx.doi.org/10.1145/3448250>

umbral determinado²⁰ para que se complete el objetivo. El modelo aprende, reacomodando los pesos hasta que obtiene el mejor resultado posible.

De esta manera, los modelos de DL funcionan con múltiples capas (ver **Figura 4**), siendo cada capa una forma diferente de extracción y transformación de la información que se está utilizando como insumo (Patterson & Gibson, 2017). Las capas (set de neuronas o nodos) permiten optimizar y refinar la precisión del resultado del modelo²¹.

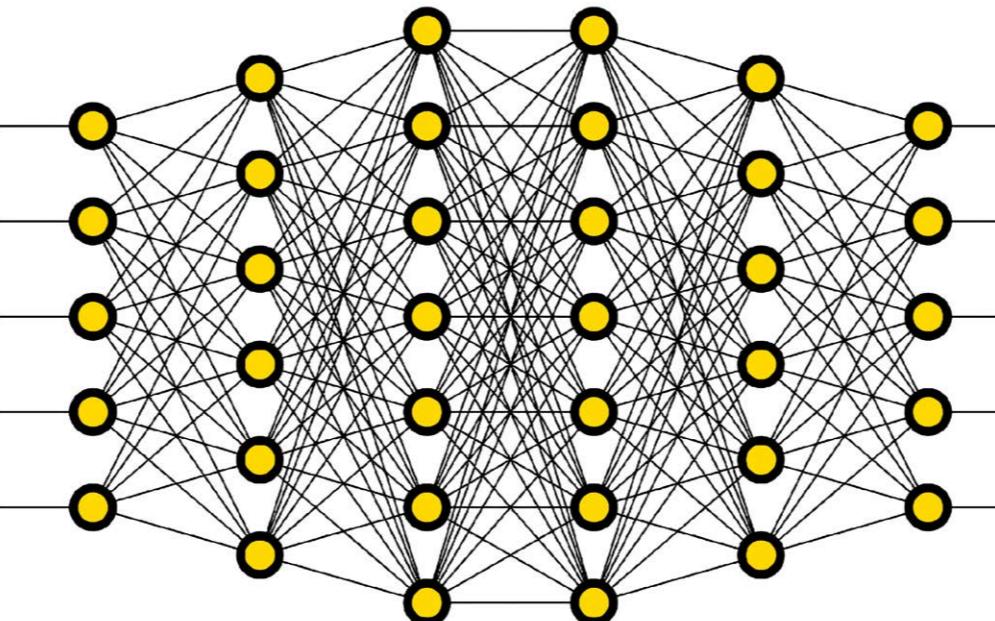
Estos tipos de modelos suelen recibir insumos relativamente complejos, como imágenes o textos, y a través de procesamientos complejos de cada parte del insumo, producen resultados simples como puede ser la clasificación de un objeto o el resumen de un documento.

20 Para más información sobre las funciones de activación (activation functions) consultar: Sharma et al., 2020 <<https://www.ijeast.com/papers/310-316,Tesma412,IJEAST.pdf>> & Manoharan, I 190. Demystifying the Gears: Activation Functions & Loss Functions for Neural Networks. (2024, marzo). Recuperado de <<https://medium.com/@ilakk2023/190-demystifying-the-gears-activation-functions-loss-functions-for-neural-networks-778f29d7780f>>

21 Ibidem.

Por ejemplo, en la inspección de la seguridad vial de una carretera, es posible entrenar un modelo de *deep learning* utilizando imágenes que representen las características clave que determinan el nivel de seguridad de la vía. Este modelo puede funcionar como un clasificador capaz de identificar con un alto grado de precisión los segmentos de la carretera que requieren intervenciones para reducir los riesgos para peatones, ciclistas y conductores.

Figura 4. Modelo de redes neuronales multi-capa



Fuente: Thajeb, S. Introducción to Deep Learning. (2020, julio). Recuperado de <<https://medium.com/swlh/introduction-to-deep-learning-50d971374dd2>>

● **Inteligencia Artificial Generativa (Generative AI):** Es un tipo de IA que utiliza el aprendizaje automático, no para predecir o clasificar con base en la información existente, sino para producir “nuevos” contenidos, ya sean estos datos numéricos, texto, videos, audios o imágenes, entre otros, a partir del análisis de patrones de los datos (Brynjolfsson et al., 2023; Cevallos et al., 2023). Los recientes avances de la IA Generativa se deben en parte a los progresos obtenidos en áreas como la escala computacional, las mejoras en la arquitectura de los modelos y la posibilidad de entrenar modelos mediante grandes volúmenes de datos no etiquetados²² (Brynjolfsson et al., 2023).

El ejemplo más común de IA generativa, después del auge de ChatGPT, corresponde a los grandes modelos de lenguaje (LLM, por sus siglas en inglés). Estos modelos hacen parte de la familia del Procesamiento de Lenguaje Natural (NLP, por sus siglas en inglés) que automatiza las funciones del lenguaje mediante el análisis, producción, modificación y respuesta a la voz y escritura humana

22 Un ejemplo de datos sin etiquetar puede ser una serie de imágenes de animales sin información relacionada con su tipo, es decir, si se trata de un león, un conejo, un perro o un gato.

(OECD, 2023). Los LLM están entrenados con grandes cantidades de datos (se estima que GPT-4 incluye 1,8 trillones de parámetros y está entrenado con cerca de 13 trillones de tokens²³) lo que les permite clasificar y simular entender la estructura de los textos, las complejidades gramaticales y los diferentes contextos de las oraciones, por lo que están en la capacidad de establecer conversaciones, dar respuestas precisas y crear “nuevos” textos²⁴ (Brynjolfsson *et al.*, 2023; Cevallos *et al.*, 2023). Aunque ChatGPT²⁵ es el generador de texto más conocido, existen otras plataformas como, por ejemplo, LLaMA²⁶ de Meta, Gemini²⁷ de Google y Claude²⁸ desarrollado por Anthropic, entre otros.

Los modelos fundacionales (FM) -*Foundation Models*-²⁹, entre los que se encuentran los LLM, tienen la capacidad de adaptarse a cualquier temática en la medida que están entrenados con millones de datos y, contrario a lo que pasa con los modelos de aprendizaje automático o profundo que están diseñados para cumplir con una tarea específica, estos modelos tienen la capacidad de analizar insumos complejos para producir formas de conocimiento más avanzadas como, por ejemplo, completar códigos de programación o analizar textos, entre otros³⁰, aunque también pueden generar resultados incorrectos en términos de sesgos o alucinaciones, cuando existen problemas con la calidad e integridad de los datos con que se alimentan³¹. Este tipo de modelos puede contribuir a mejorar la eficiencia de los procesos administrativos de las

entidades de los sectores de infraestructura, por ejemplo, en la mejora de la gestión documental o en los sistemas de respuesta a ciudadanos.

Tipos de aprendizaje en modelos de Machine Learning

Esta subsección presenta una revisión de los principales tipos de aprendizaje que se utilizan en los sistemas de ML. Como se mencionó, el ML tiene la capacidad de descubrir patrones y relaciones en grandes cantidades de datos, lo que ayuda a crear herramientas de predicción o clasificación con un buen nivel de precisión. En general, los problemas para los cuales se usan los modelos de ML pueden ser resumidos en tres vertientes:

23 En los modelos de NLP un token hace referencia a una unidad básica de texto, el cual puede ser una palabra, un número, un símbolo de puntuación o cualquier otra entidad lingüística significativa.

24 What are Large Language Models (LLM)? Recuperado de <<https://aws.amazon.com/what-is/large-language-model/>>

25 Para más información consultar: <<https://chat.openai.com/>>

26 Para más información consultar: <<https://llama.meta.com/>>

27 Para más información consultar: <<https://gemini.google.com/>>

28 Para más información consultar: <<https://claude.ai/chats>>

29 Los modelos fundacionales (FM) son redes neuronales que realizan aprendizaje profundo entrenados con grandes cantidades de datos y compuestos por un número significativo de parámetros, que pueden realizar distintas tareas generales como generar texto e imágenes, comprender lenguajes humanos y mantener conversaciones, entre otros (Fuente: ¿Qué son los modelos fundacionales? Recuperado de <https://aws.amazon.com/es/what-is/foundation-models/>).

30 AWS. What are Foundation Models? Recuperado de <<https://aws.amazon.com/what-is/foundation-models/#:~:text=Foundation%20models%20are%20a%20form,form%20of%20human%20language%20instructions.>>

31 Google Cloud. ¿Qué son las alucinaciones de la IA? Recuperado de <<https://cloud.google.com/discover/what-are-ai-hallucinations?hl=es-419>>



Clasificación:

En este caso el problema que se intenta resolver es la identificación de la o las categorías a la que pertenece cada elemento que se está analizando. El ejemplo más común, es la clasificación de imágenes. Por lo general, este tipo de modelos aprenden con información de entrenamiento que está etiquetada. Las técnicas que se pueden utilizar incluyen un simple umbral, regresiones, modelos de Markov, random forests o redes neuronales, entre otros. Por ejemplo, en una red eléctrica, es fundamental identificar rápidamente fallas o anomalías que puedan causar interrupciones en el suministro de energía. Para ello, se usan un modelo de aprendizaje automático que clasifique los eventos de la red en diferentes categorías, como "operación normal", "sobrecarga", "corte eléctrico" o "fallo del equipo".

Agrupamiento:

Estos modelos permiten encontrar relaciones entre series de datos, de manera que aquellos que tengan características en común sean parte de un mismo grupo o clúster. Un ejemplo en el sector de transporte es el agrupamiento de trayectorias de vehículos para optimizar rutas de transporte público. En este caso en una ciudad, se busca optimizar las rutas de autobuses o transporte público basándose en las trayectorias reales de los vehículos y los patrones de demanda de los pasajeros. Esto identifica rutas con alta demanda y aquellas que se podrían optimizar, agregando o eliminando paradas, o ajustando las frecuencias de servicio en rutas clave según los patrones de demanda.

Predicción:

Con base en información histórica, los modelos de predicción pronostican valores actuales o futuros, por ejemplo, la demanda de energía eléctrica, demanda de servicios de transporte, niveles de congestión o de accidentabilidad, y caudales de agua en sistemas de acueducto y alcantarillado. En este caso, se podría utilizar este modelo por las empresas de servicios de agua, ya que necesitan anticiparse a la demanda futura para evitar sobrecargas en el sistema de suministro o escasez de agua. Usar modelos predictivos les permite ajustar el suministro de agua de manera eficiente en función de las necesidades futuras, lo cual es crucial para una gestión sostenible.

Una de las características indispensables de los modelos de ML es que tienen la capacidad de aprender de la información disponible, por lo que su estructura se diferencia principalmente en los algoritmos que utilizan para aprender (Rebala *et al.*, 2019). Así entonces, generalmente se habla de tres tipos principales de modelos de aprendizaje dentro de ML: i) aprendizaje supervisado, ii) aprendizaje no supervisado, y iii) aprendizaje reforzado.

En cuanto al **aprendizaje supervisado**, su principal característica es que el entrenamiento de los modelos se realiza con base en información etiquetada; es decir, el modelo se entrena bajo el conocimiento de las respuestas correctas. Este tipo de aprendizaje trata dos problemas principales: clasificación y regresión. Como se señaló anteriormente, la clasificación hace referencia a la identificación de la categoría a la que pertenece cada elemento que se está analizando. Por su parte, la técnica de regresión descubre la relación en diferentes dimensiones de las distintas variables con el fin de predecir el comportamiento de una variable de interés (Rebala *et al.*, 2019). Algunas aplicaciones de este tipo de aprendizaje son el diagnóstico del estado de la infraestructura para fines de mantenimiento o identificación de fallas, la detección de fraude en el consumo de agua y energía, la clasificación de imágenes para detección de basurales o de congestión vehicular, la predicción de precios

o demanda de servicios de energía, agua o transporte público, entre otros. Para el problema de clasificación, los algoritmos más utilizados son máquina de soporte vectorial (SVM), K-vecinos más cercanos (KNN), Bayesiano ingenuo (Naive Bayes), árboles de decisión, random forests y redes neuronales convolucionales (CNN), entre otros. Para el caso de regresiones, generalmente se utilizan la regresión lineal, regresión logística, regresión polinomial, la regresión con máquinas de soporte vectorial (SVM) y Gradient Boosting (GBM), entre otros.

Por su parte, el **aprendizaje no supervisado** es aquel en el que los algoritmos no se centran en predecir o explicar una variable objetivo, sino en identificar patrones o relaciones existentes entre los datos. Los modelos de este tipo aprenden a identificar características similares entre las variables que las hacen pertenecer a un mismo grupo (Rebala *et al.*, 2019). Por lo general este tipo de aprendizaje utiliza algoritmos de clusterización o agrupamiento, lo que le permite obtener las particularidades principales de los datos, utilizando como insumo un conjunto de datos no etiquetados. En ese orden de ideas, teniendo en cuenta que muchas veces este tipo de aprendizaje se enfrenta a bases de datos con alta dimensionalidad (gran cantidad de variables), se utilizan algoritmos de reducción de dimensionalidad como Análisis Discriminante Lineal (LDA) o Componentes Principales (CPA)

para que, mediante la reducción del número de variables, se capture la información más importante de la base de datos con la que se está trabajando³². Esto, entre otras cosas, permite mejorar la interpretabilidad del modelo, su rendimiento y eficiencia computacional³³. El aprendizaje no supervisado puede ser usado para la segmentación de clientes, la clasificación del estado de los activos de infraestructura, la detección de patrones inusuales en el desempeño de motores o maquinaria, y el diseño de programas de política pública. Los algoritmos de *clusterización* o agrupamientos más utilizados son K-Means, K-medoids, DBSCAN y Mezclas Gaussianas (GMM), entre otros.

Adicionalmente, los modelos de **aprendizaje por refuerzo** buscan tomar las mejores decisiones con base en la experiencia que se forja a través de ensayo y error³⁴. Para esto, el aprendizaje se da mediante “recompensas y castigos”, en donde al modelo no

32 Brown, I. Feature selection vs feature extraction: Navigating Dimensionality Reduction in Machine Learning. (2024, marzo). Recuperado de <<https://medium.com/ai-in-plain-english/feature-selection-vs-feature-extraction-navigating-dimensionality-reduction-in-machine-learning-7c60e6742710>>

33 Ibidem.

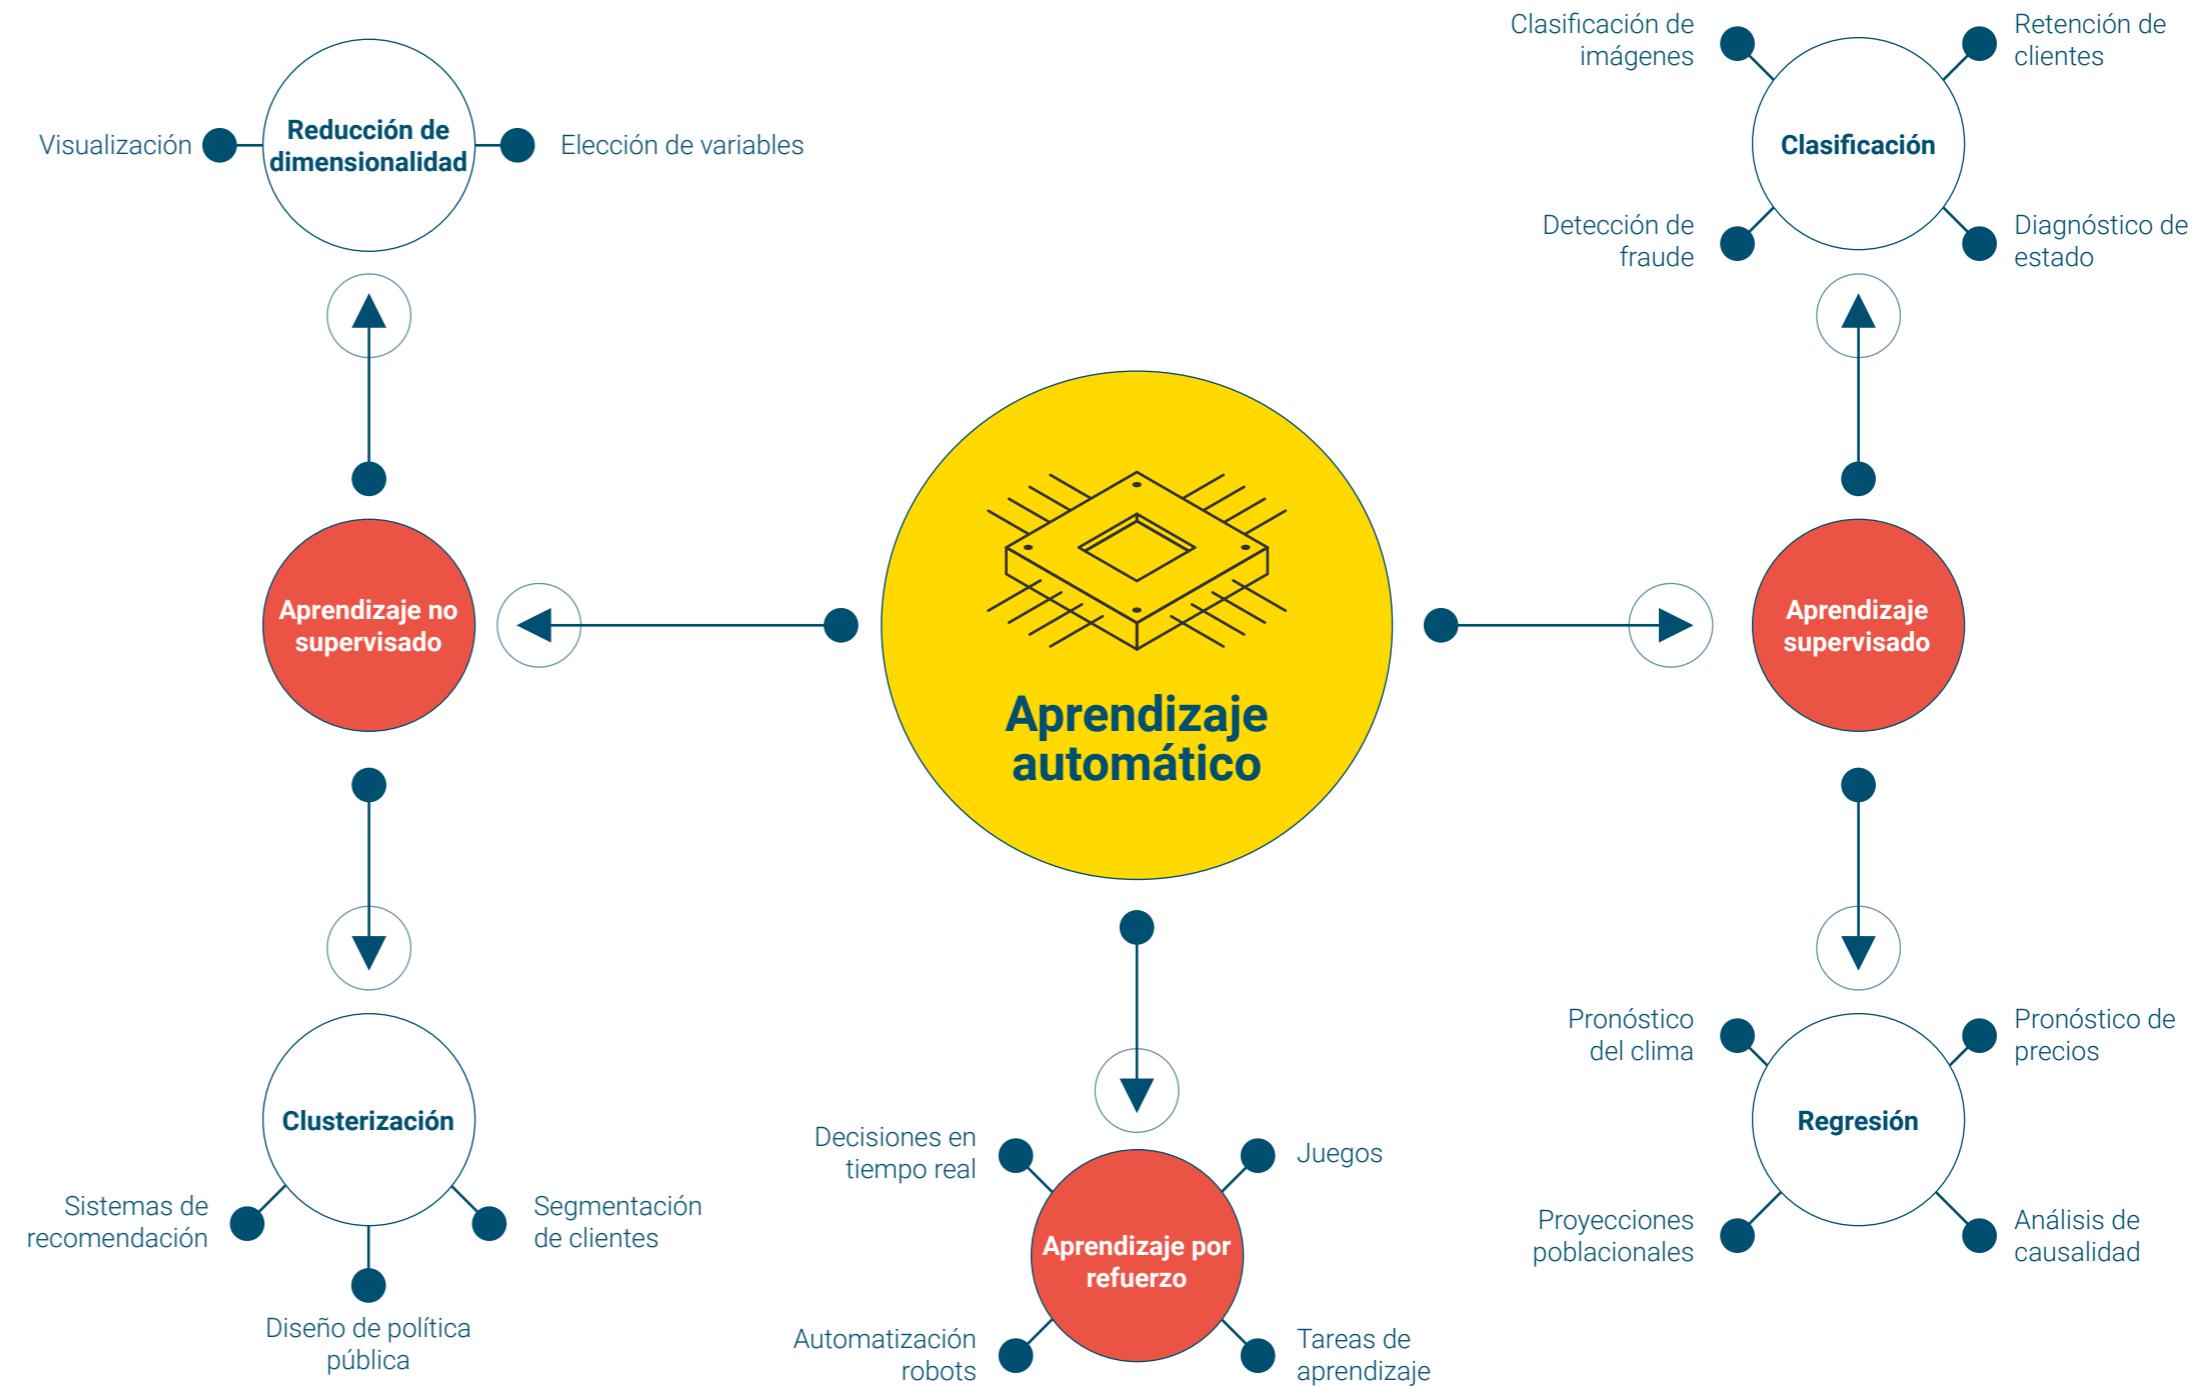
34 AWS. ¿Qué es el aprendizaje mediante refuerzo? Recuperado de <[https://aws.amazon.com/es/what-is/reinforcement-learning/#:~:text=El%20aprendizaje%20por%20refuerzo%20\(RL,utilizan%20para%20lograr%20sus%20objetivos.](https://aws.amazon.com/es/what-is/reinforcement-learning/#:~:text=El%20aprendizaje%20por%20refuerzo%20(RL,utilizan%20para%20lograr%20sus%20objetivos.)>

se le indica que decisiones tomar, pero sí el objetivo que debe cumplir, así como también el tipo de “recompensa” y “castigo” que tiene cada acción que ejecuta (Sutton & Barto, 2018). Una de las características fundamentales de este tipo de aprendizaje es que tiene la capacidad, conforme avanza en su entrenamiento, de encontrar la ruta óptima para cumplir con su objetivo teniendo en cuenta el impacto a largo plazo de sus decisiones, es decir, en el camino intencionalmente puede recibir “castigos” para conseguir el objetivo (Rebala *et al.*, 2019). Las aplicaciones más destacadas de este tipo de aprendizaje se relacionan con la autonomía de robots, la gestión de tráfico vehicular a partir de la administración de los semáforos, vehículos autónomos y el entrenamiento de juegos, por ejemplo, AlphaGo³⁵. Los algoritmos más usados en este tipo de aprendizaje son: Q-Learning, Deep Q-Network (DQN), Proximal Policy Optimization (PPO) y Monte Carlo Tree Search (MCTS), entre otros.

La **Figura 5** resume los tipos de aprendizaje principales en los sistemas de ML, así como los problemas que tratan y algunas de las aplicaciones en que son utilizados.

³⁵ Para más información consultar: <<https://deepmind.google/technologies/alphago/>>; y AlphaGo <<https://www.youtube.com/watch?v=WXuK6gekU1Y&t=1028s>>

Figura 5. Esquema de los tres principales tipos de aprendizaje en ML



Fuente: Adaptación propia de Artificial Intelligence. Machine Learning Definition (Complete Guide). Recuperado de <<https://medium.com/@artificialintelligenceai/machine-learning-definition-complete-guide-4cd615dd424d>>

Cabe señalar que los modelos de IA dependen significativamente de los datos de insumo. En este sentido, quienes desarrollan estos modelos pueden enfrentar problemas relacionados con la escasez o baja calidad de la información, los sesgos existentes en los datos disponibles, y los limitantes de tipo legal y ético relacionados con el procesamiento de datos personales. Una herramienta que enfrenta estos retos es el uso de datos sintéticos. Este tipo de datos se define generalmente como información generada artificialmente mediante algoritmos o simulaciones que recrean el comportamiento de los datos “reales” (Lu *et al.*, 2024). Si bien el uso de este tipo de datos genera artificialmente grandes cantidades de datos de entrenamiento cuando los datos son escasos, de baja calidad o tienen sesgos, los datos sintéticos no siempre capturan la complejidad e interacciones presentes en los datos reales. En este sentido, las conclusiones del análisis de datos y comprobación de hipótesis son generalmente más débiles cuando se usan datos sintéticos que cuando se utilizan datos reales, por lo que la significancia estadística de dichos análisis debe ser adecuadamente ajustada. Adicionalmente, el uso de datos sintéticos dificulta realizar vínculos entre diferentes conjuntos de datos reales y poder crear así bases de datos más amplias que contengan nueva información sobre las correlaciones entre los conjuntos de datos enlazados (Jordon *et al.*, 2022).

Para la creación de los datos sintéticos de imágenes y videos se suelen utilizar modelos generativos que están entrenados para recrear las características y propiedades de los datos del mundo real³⁶. Para esto, por lo general suelen utilizarse modelos tipo Red Generativa Antagónica (GAN), Autocodificadores variacionales (VAEs) y modelos autorregresivos, entre otros. Por ejemplo, en la detección de fraude en el consumo de agua o energía, es común generar variables sintéticas que complementen la limitada disponibilidad de datos reales.

Otra técnica relevante que soluciona el problema de insuficiencia de información es el *aumento de datos (data augmentation)*. Esta técnica incrementa de forma artificial el conjunto de datos modificando los datos originales en una baja cantidad, lo que permite no solo incrementar el muestreo sino también incluir diversidad en los datos de entrenamiento con el fin de mejorar la generalización del modelo³⁷.

Finalmente, en los modelos de clasificación un problema constante es el desbalance de las categorías. Esto puede generar que los predictores de clase tengan un bajo rendimiento, en la medida que pocas veces predicen la clase minoritaria (la que cuenta con menos datos) y por lo tanto la evaluación del modelo solo tiene en cuenta el rendimiento en la clase mayoritaria. Algunas soluciones a este problema están relacionadas con el submuestreo de la clase dominante, con las réplicas a la clase minoritaria o con las ponderaciones de cada clase de tal manera que el peso total de cada una de las clases resulte balanceado mediante pesos distintos, entre otras soluciones (Ávalos *et al.*, 2021).

36 Shah, D. What is Synthetic Data in Machine Learning and How to Generate it. (2022, junio). Recuperado de <<https://www.v7labs.com/blog/synthetic-data-guide#h1>>

37 AWS. What is Data Augmentation. Recuperado de <[https://aws.amazon.com/what-is/data-augmentation/#:~:text=Data%20augmentation%20is%20the%20process,machine%20learning%20\(ML\)%20models.](https://aws.amazon.com/what-is/data-augmentation/#:~:text=Data%20augmentation%20is%20the%20process,machine%20learning%20(ML)%20models.)>



IA EN SECTORES DE INFRAESTRUCTURA: OPORTUNIDADES Y APLICACIONES

3.1

La importancia de las infraestructuras críticas

La infraestructura económica es un componente central de la base de capital de los países que habilita la actividad económica y el funcionamiento de la sociedad, y tiene efectos positivos en el bienestar y calidad de vida de las personas. El Foro Económico Mundial -FEM (2012) define la infraestructura económica como el conjunto de proyectos que generan crecimiento económico y habilitan el funcionamiento de la sociedad en sectores como el transporte -terrestre, aéreo, fluvial, marítimo-, servicios públicos -agua, gas y electricidad-, defensa ante inundaciones, y gestión de residuos, entre otros.



En atención a la relevancia de la infraestructura económica, diferentes sistemas y elementos de este tipo han sido denominados infraestructuras críticas, ya que, en adición al impacto económico y social que generan, su afectación representa un riesgo considerable para los países. En este sentido, una infraestructura se define como crítica cuando se considera que una posible interrupción podría generar una crisis socioeconómica significativa. Esto a su vez podría tener repercusiones estratégicas, políticas, y de seguridad para la sociedad (Laubshtein, 2023).

La literatura económica ha analizado la contribución económica de los sectores de infraestructura y ha encontrado que dichos sectores tienen efectos significativos y positivos en el desarrollo económico de los países³⁸. Por ejemplo, el Fondo Monetario Internacional – IMF (2016) señala que existe una relación positiva entre la calidad de la infraestructura y el nivel de desarrollo de los países, medido, por ejemplo, mediante el ingreso per cápita. Según esta organización, la inversión en infraestructura contribuye al crecimiento económico futuro, y el estado de la infraestructura representa un determinante

importante de la competitividad y de los flujos de inversión en los países. En el mismo sentido, de acuerdo con la OECD (2023), los sectores de transporte y telecomunicaciones pueden actuar como catalizadores del crecimiento económico al facilitar que las empresas creen conexiones con los mercados a nivel nacional, regional y mundial, mientras que una infraestructura de calidad en los sectores de energía y agua contribuye a la sostenibilidad y transición verde de los países, y a que dicha transición beneficie a los ciudadanos.

Adicionalmente, diferentes autores han encontrado que existe una relación positiva entre la inversión en infraestructura y la creación de empleo. Moszoro (2021), por ejemplo, evaluó el impacto en creación de empleo de la inversión pública en infraestructura crítica en 41 países en un periodo de 19 años. Encontró que cada USD \$1 millón de inversión pública en infraestructura puede inducir una creación de 3 a 6 empleos en economías avanzadas, 10 a 17 trabajos en economías emergentes, y 16 a 30 empleos en economías de menor ingreso. Con esto, a nivel global, un aumento de 1% del PIB global en la inversión pública en estos sectores puede crear más de 7 millones de empleos.

3.2

Oportunidades y aplicaciones de la IA en sectores de infraestructura

IA y la transformación digital de los sectores de infraestructura

La IA se ha convertido en una de las tecnologías con mayor potencial para habilitar las transformaciones económicas en los mercados durante los próximos años, en la medida en que su adopción abre la puerta a múltiples oportunidades de creación de valor tanto para las organizaciones como para los consumidores. Deloitte (2021) señala seis formas en que la IA crea valor para las organizaciones:

- **Reducción de costos:** La IA es utilizada para reducir costos mediante la automatización de tareas que son repetitivas y de bajo valor, y de esta manera aumentar la eficiencia y calidad.
- **Velocidad en la ejecución:** La IA mejora el tiempo requerido para alcanzar resultados operativos y de negocios.

38 Ver por ejemplo: Zhang Y. & Cheng L. (2023), Hong J., Chu Z., & Wang Q. (2011), Jiwattanakulpaisarn P., Noland R., & Graham D. (2012).

- **Reducción de la complejidad:** Esta tecnología contribuye a mejorar el entendimiento del negocio y la toma de decisiones mediante analítica de datos “más proactiva, predictiva y capaz de detectar patrones en fuentes cada vez más complejas”.
- **Transformación del involucramiento:** La IA hace posible modificar la interacción de las personas con la tecnología, lo que permite a los negocios conectar con los clientes en términos humanos.
- **Impulso a la innovación:** La IA habilita la innovación en nuevos productos, mercados y modelos de negocios, lo que induce una redefinición en la estrategia de los negocios.
- **Fortalecimiento de la confianza:** Esta tecnología contribuye a proteger los negocios de riesgos asociados como el fraude y la ciberdelincuencia, así como mejorar la calidad, la consistencia, la transparencia y la confianza de los usuarios.

La IA también ofrece un enorme potencial de creación de valor para el desempeño de los gobiernos y para el logro de sus funciones y objetivos. Los organismos públicos aprovechan la IA para transformarse en organizaciones más inteligentes,

más eficientes y receptivas, que desarrollan mejores procesos de toma de decisiones (Pombo et.al, 2018).

En este contexto, el desarrollo y la adopción de la IA ofrece oportunidades significativas para el impulso de la transformación digital en los sectores de infraestructura económica en los países, entendida esta transformación como el aprovechamiento de los datos y la adopción de tecnologías digitales, como la IA, para reestructurar procesos, organizaciones o sistemas, con el objetivo de crear valor³⁹.

Los sectores de infraestructura económica tienen características comunes que habilitan su transformación digital basada en IA, como que están compuestos de sistemas complejos, organizados mediante arquitecturas de red,

en los que intervienen múltiples actores, y que son intensivos en capital físico, así como en la generación y consumo de datos. Las organizaciones en estas áreas económicas enfrentan de esta manera desafíos comunes en los que la IA se está convirtiendo en una herramienta fundamental, como el desarrollo de pronósticos de oferta y demanda, el seguimiento a la construcción de proyectos, la inspección y el mantenimiento de los activos, la detección de pérdidas en redes, la sostenibilidad de los sistemas, y la resiliencia de la infraestructura frente al cambio climático y desastres naturales.

Así mismo, en los sectores de infraestructura la transformación digital ha tenido un rol disruptivo en tres niveles (Calatayud et al. 2022): (i) la mejora en eficiencia de unidades productivas, (ii) la reconfiguración de las cadenas productivas, y (iii) la formación de nuevos mercados mediante el surgimiento de plataformas bilaterales conocidas como *marketplaces*. Si bien la velocidad de adopción tecnológica y transformación digital en estos sectores ha sido

39 Existen diferentes definiciones sobre transformación digital. Por ejemplo, la OECD define este concepto como el impacto de las tecnologías y los datos digitales y su uso en las actividades existentes y nuevas. AWS define transformación digital como el proceso mediante el cual una organización integra tecnología digital a todas las áreas empresariales. Por su parte, McKinsey la define como es la reconfiguración de una organización, con el objetivo de crear valor mediante el despliegue continuo de tecnología a escala. Fuentes: OECD. *Digital Transformation*. Recuperado de: <<https://www.oecd.org/en/topics/digital-transformation.html>>. AWS. ¿Qué es la transformación digital? Recuperado de: <https://aws.amazon.com/es/what-is/digital-transformation/>. McKinsey & Company. *What is Digital Transformation?*. Recuperado de <<https://www.mckinsey.com/featured-insights/mckinsey-explainers/what-is-digital-transformation>>

heterogénea⁴⁰, en la mayoría de los sectores las tecnologías digitales se han convertido en un factor de cambio.

En una encuesta realizada a 275 representantes de los sectores de transporte y energía en ALC, el BID encontró que el 71% de las empresas de energía utilizan computación en la nube, y que más del 50% de las empresas tanto en este sector como en el sector transporte han adoptado herramientas de análisis de datos, así como soluciones de big data. Las organizaciones en estos sectores están empleando elementos de captura, procesamiento y análisis de datos que incluyen sensores, drones, redes eléctricas, a partir de los cuales están implementando sistemas que les permiten mejorar los procesos de interacción con los clientes, efectuar monitoreos en tiempo real, y administrar la oferta y demanda, entre otras aplicaciones (Irigoyen y Mayorga, 2024).

Las tecnologías emergentes, asociadas a etapas de digitalización más avanzadas como la IA, recién están comenzando a captar la atención de los sectores económicos en ALC. En los sectores de infraestructura, la encuesta mencionada evidenció un creciente interés por avanzar en el

despliegue de IA en los próximos años, en adición al desarrollo y adopción de tecnologías para reducir el impacto ambiental.

De esta manera, las oportunidades de creación de valor que la IA ofrece a las organizaciones en los sectores de infraestructura, y que generan impactos positivos en diversas fases del ciclo de vida de los proyectos, se presentan en las fases de: (i) **Planeación y diseño**, que abarca la identificación de necesidades, formulación, estructuración y diseño; (ii) **Construcción y gestión de activos**, que incluye el despliegue de la infraestructura y la gestión de los activos relacionados; y (iii) **Operación y mantenimiento**, que se refiere al funcionamiento de la infraestructura, el mantenimiento de los activos, la prestación de servicios y la consolidación de sistemas en términos de sostenibilidad y resiliencia climática.

En cada una de estas fases, la IA brinda oportunidades significativas. En la fase de planeación y diseño, facilita el modelado avanzado de sistemas y mejora los análisis de riesgos y la toma de decisiones basada en datos y predicciones avanzadas. Durante la construcción y gestión de activos, contribuye a aumentar la eficiencia en la ejecución y supervisión de obras, lo que optimiza la

identificación, monitoreo y mantenimiento de los activos. Además, en la fase de operación y mantenimiento, la IA impulsa la incorporación de mejoras en la eficiencia y sostenibilidad de los sistemas, habilita la optimización de los tiempos de mantenimiento, fortalece la gestión de los activos y el monitoreo de la calidad de los servicios, y contribuye a fortalecer los procesos de relacionamiento con los usuarios.

Oportunidades y aplicaciones en los sectores de infraestructura

Planeación y diseño de los sistemas de infraestructura

La IA ofrece a las organizaciones de sectores de infraestructura oportunidades para optimizar los procesos de planeación y diseño de proyectos y sistemas. En el sector de energía, los avances tecnológicos, el crecimiento poblacional, el aumento de la producción y la mejora en las condiciones de vida de la población han generado que en las últimas décadas se haya incrementado considerablemente el consumo de energía eléctrica a nivel global (Bedi & Toshniwal, 2019). En este contexto, en los últimos años ha aumentado la utilización de modelos de predicción de demanda para realizar

⁴⁰ El sector de energía ha sido tradicionalmente un adoptante temprano de tecnología, en comparación con otros sectores tradicionales como el de agua y saneamiento.

proyecciones de corto y largo plazo, así como para proyectar el consumo a nivel micro (consumidores individuales) y a nivel macro (ciudades e incluso países) (Del Real *et al.* 2020).

Así mismo, en diferentes países se han utilizado modelos de IA para optimizar el diseño de plantas generadoras de energía eléctrica y calibrar su dimensionamiento (Kumar & Saini, 2021). Al respecto, Senthil kumar *et al* (2013) utilizaron un modelo de redes neuronales artificiales (ANN) para predecir la carga de sedimentos en cuencas hidrográficas, lo que permitió optimizar el diseño y la capacidad de generación de una planta hidroeléctrica. Los algoritmos de IA se han utilizado también para identificar qué tipo de elementos afectan la generación de una planta para, de esta manera, optimizar su diseño (Kumar & Saini, 2021). En Irak, por ejemplo, investigadores pronosticaron la producción de energía de una planta hidroeléctrica pequeña en la represa de Himreen Lake utilizando un modelo basado en ANN, y encontraron que las variables que tienen mayor incidencia en la generación de energía son el caudal del agua y la altura neta de la turbina (Hammid *et al.*, 2018).

De igual manera, la IA ofrece oportunidades para mejorar el diseño de parques eólicos de manera que se optimice el uso de la tierra y el número de turbinas instaladas. Un ejemplo

de esto es el uso de algoritmos genéticos⁴¹ que pueden ayudar a hacer eficiente la instalación de los parques eólicos y a maximizar la capacidad de producción de energía (Grady *et al.*, 2005). Estos algoritmos consideran las variaciones en la dirección y velocidad del viento en la ubicación de las turbinas, y, de esta manera, identifica el diseño óptimo que minimiza el costo por unidad de energía generada (Grady *et al.*, 2005).

En materia de planeación del transporte, las sociedades enfrentan retos de movilidad, congestión, seguridad vial, aprovechamiento del espacio público y emisión de gases, entre otros. Desarrollar sistemas de transporte bien conectados y multimodales es uno de los objetivos más importantes para los organismos encargados de la planeación, como un medio para aumentar la eficiencia, y disminuir las barreras de acceso y la congestión en las áreas metropolitanas (Yang *et al.*, 2018).

Los modelos de IA juegan un papel preponderante en este campo, ya que permiten, por ejemplo, aumentar la precisión de las matrices origen-destino para adaptar la gestión de los semáforos al flujo vehicular, u optimizar la operación del transporte público para responder a los choques de demanda de franjas horarias específicas. Algunos de los modelos más utilizados son las regresiones⁴² que predicen el flujo de tráfico entre diferentes puntos de origen y destino basados en variables como la ubicación, la franja horaria, el día de la semana y el clima (Gutiérrez Puebla *et al.*, 2020; Yang *et al.*, 2018). De igual manera, es común la utilización de modelos de redes neuronales, de teoría de grafos y de simulación, entre otros (Rodrigues *et al.*, 2019).

Algunas ciudades han habilitado en sus modelos de transporte el procesamiento de los datos provenientes de nuevas fuentes de información como redes sociales (X, Instagram, TikTok, Waze, Strava, entre otras), servicios web (Google Maps, Waze), teléfonos inteligentes, tarjetas inteligentes de transporte, y sensores instalados en infraestructura pasiva -semáforos, cámaras de seguridad-, así como de la información georreferenciada de los buses, bicicletas, taxis y demás medios de transporte públicos (Gutiérrez Puebla *et al.*, 2020). Así mismo,

⁴¹ Un algoritmo genético es una técnica de búsqueda computacional para encontrar soluciones aproximadas a modelos de optimización y problemas de búsqueda. Está inspirado en el proceso de evolución natural, en donde se seleccionan las mejores soluciones para un problema, se combinan y se mutan para crear nuevas soluciones, todo dentro un proceso iterativo que se detiene cuando encuentra la mejor solución posible. Para más información consultar: <<https://www.sciencedirect.com/topics/engineering/genetic-algorithm>>

⁴² Regresión de tipo lineal, logística y polinomial, entre otras.

en el caso de ALC, la División de Transporte del BID desarrolló un análisis exhaustivo sobre las características y costos de la congestión urbana en diez ciudades de la región, en el que utilizó Big Data e IA para analizar la dinámica de la congestión en cada una de estas ciudades y su impacto en los costos directos e indirectos para los países (Calatayud *et al.*, 2021).

Otro caso de uso relevante es la aplicación de modelos predictivos de oferta y demanda para la planeación de sistemas de transporte. Un ejemplo es el modelo de predicción desarrollado por el BID para el Área Metropolitana de San Salvador, en El Salvador. Para la construcción del modelo, el BID empleó la metodología *Smart Steps*⁴³ de LUCA-Telefónica mediante la cual, a través de información provista por registros de llamadas -*Call Detail Record (CDR)*⁴⁴-, y con información de

tráfico obtenida por medio de crowdsourcing en Google, los investigadores identificaron los viajes realizados y crearon matrices de origen y destino (Rendón Rodríguez *et al.*, 2020).

El modelo reseñado proporciona información sobre las vías más transitadas, el flujo vehicular, la infraestructura crítica del sistema, la ocupación del transporte público y las franjas horarias de mayor estrés, lo que hace posible evaluar el impacto de varios proyectos de infraestructura mediante simulaciones. Entre los proyectos que pueden ser analizados se incluyen la reorganización de rutas y estaciones de transporte público, cambios en los sentidos viales, la ampliación de la malla vial, y la inclusión de nuevos modelos de transporte (Rendón Rodríguez *et al.*, 2020).

La IA también es utilizada desde la planeación para ampliar la capacidad de respuesta de la infraestructura de transporte, energía y recursos hídricos ante eventos meteorológicos y desastres naturales. En el sector de energía hidroeléctrica, como se mencionó, la proyección de caudales representa uno de los principales desafíos de planeación. Tradicionalmente, los operadores de centrales han utilizado datos históricos y modelos básicos para predecir los flujos de entrada, pero con la creciente

variabilidad meteorológica estos métodos tradicionales han perdido confiabilidad. En respuesta a esto, la IA procesa grandes cantidades de datos provenientes de múltiples fuentes, generando predicciones de caudales más precisas y oportunas. En India, por ejemplo, la empresa HydroGrid ayudó a un operador hidroeléctrico a gestionar su central de manera segura durante la temporada de lluvias por vientos estacionales (monzones). Según esta empresa, la solución de planeación inteligente basada en IA permitió a este operador aumentar la eficiencia e ingresos durante este periodo, y mejorar la seguridad de la población local⁴⁵.

Otro ejemplo de estas aplicaciones son las orientadas a la predicción de los flujos de aguas residuales para la correcta planeación y administración de las plantas de tratamiento (Q. Zhang *et al.*, 2019). Algunos modelos de predicción de flujos de aguas residuales se han centrado en simular el comportamiento de los sistemas de recolección; sin embargo, este tipo de modelos puede presentar desafíos en relación con los supuestos requeridos, porque el comportamiento de las lluvias, las filtraciones, el derretimiento de la nieve y la adaptación de la

43 Es el primer servicio de Big Data de Telefónica que recopila, anonimiza y agrega datos móviles de la red de Telefónica para entender cómo se comportan los segmentos de la población en conjunto. Con un enfoque diferencial según el sector bajo estudio, se analizan las tendencias y los comportamientos de las multitudes, mas no de individuos.

44 Hace referencia a un registro detallado de una llamada. La información que por lo general captura este tipo de registros es: la hora y la fecha de la llamada, la duración, los números involucrados, la ubicación, el costo y alguna información de la calidad de la llamada.

45 Fuente: International Water Power (2024). Harnessing AI to transform hydropower. Disponible en: <<https://www.waterpowermagazine.com/analysis/harnessing-ai-to-transform-hydropower/>>

infraestructura ya instalada, no resultan fáciles de simular. En consecuencia, se han desarrollado modelos de predicción con técnicas de IA de aprendizaje profundo que utilizan los datos recolectados por las plantas de tratamiento. Al respecto, un ejercicio realizado con la información de la planta de tratamiento de Ontario, Canadá, en el que se implementó un modelo de redes neuronales multicapa, obtuvo una predicción satisfactoria (Q. Zhang *et al.*, 2019).

Construcción, despliegue y gestión de activos de los sistemas

El sector de energía eléctrica es intensivo en capital en la medida en que su funcionamiento se soporta en infraestructuras de generación, redes de transmisión y distribución, y otros activos físicos. En este sector, las actividades de monitoreo e inspección de la infraestructura generalmente son costosas debido a que parte de los activos pueden ubicarse en lugares alejados y de difícil acceso, demandan personal altamente especializado (Lekidis *et al.*, 2022), y generalmente deben realizarse con los equipos en operación. En atención a esto, diferentes empresas han diseñado programas de inspección remota y monitoreo en tiempo real con el fin de optimizar la gestión y mantenimiento de la infraestructura, contar con alertas tempranas, reducir el tiempo de los operarios en campo, disminuir los accidentes y mejorar los indicadores de disponibilidad de los equipos.

En este campo, se destacan tres aproximaciones soportadas en tecnología -incluida la IA- que están siendo utilizadas por las empresas de este sector: i) el uso de vehículos aéreos no tripulados (*Unmanned Aerial Vehicles - UAVs*) en conjunto con algoritmos de análisis de imágenes y video, que disminuyen los costos de toma de topografía, el tiempo de trabajo y mejoran la precisión (Rennie *et al.*, 2020); ii) el uso de Internet de las Cosas (IoT) mediante el despliegue de sensores en diferentes componentes de la infraestructura y el desarrollo de analítica avanzada basada en la información recolectada (Rennie *et al.*, 2020); y iii) el desarrollo de “gemelos digitales” (DT, por sus siglas en inglés) con el fin de modelar a través de técnicas de aprendizaje automático el comportamiento de los elementos de la red y simular dicho comportamiento.

Al respecto, durante los últimos años se han venido utilizando modelos de IA que procesan los datos recopilados por UAVs con el objetivo de detectar objetos e identificar fallas y anomalías. Estos modelos⁴⁶ identifican todos los elementos de la red, y reconocen el estado de estos elementos, de

manera que se puedan elevar alertas para mantenimientos preventivos. Adicionalmente, estos modelos permiten elaborar esquemas de clasificación⁴⁷ de fallas y anomalías, para optimizar las actividades de mantenimiento correctivo. Por ejemplo, el operador de una planta hidroeléctrica en Grecia implementó un piloto de monitoreo e inspección basado en UAVs, el cual incluyó un componente de análisis de imágenes y videos a través de redes neuronales convolucionales. A partir de esto, se logró reducir en cerca de 70% el número de accidentes por año, aumentar la tasa de identificación de fallas y anomalías en un 80% y generar un ahorro aproximado del 85% del presupuesto de mantenimiento (Lekidis *et al.*, 2022; Liu *et al.*, 2020).

Programas similares están siendo desarrollados en diferentes países de la región. En Colombia, Interconexión Eléctrica - ISA, una empresa de transmisión de energía eléctrica, ha utilizado IA para detectar fallas en la infraestructura de transmisión eléctrica e incorporar mayor eficiencia a la planeación del mantenimiento. La herramienta de IA analiza las fotografías

⁴⁶ En secciones posteriores del documento se explica con más detalle este tipo de modelos con el fin de conocer su alcance, oportunidades y limitaciones, no obstante, por lo general para el tipo de soluciones aquí descritas se han utilizado Redes Neuronales Convolucionales (CNN) y YOLO (You Only Look Once).

⁴⁷ En secciones posteriores del documento se explica con más detalle este tipo de modelos con el fin de conocer su alcance, oportunidades y limitaciones, no obstante, por lo general para el tipo de soluciones aquí descritas se han utilizado modelos de clusterización como DBSCAN y modelos de clasificación como Random Forest y XGBoost (Extreme Gradient Boosting).

asociadas a los reportes de inspección en campo y, mediante algoritmos de detección de objetos, construye modelos de clasificación para identificar fallas o anomalías, lo que ha reducido de manera significativa los tiempos de intervención⁴⁸.

Existen también sistemas basados en IA que monitorean el estado de los transformadores en las redes eléctricas, con el objetivo de gestionar dicho estado, planear los mantenimientos y prevenir las fallas. Estos sistemas generalmente utilizan información de gases generados, temperatura, corriente, voltaje, entre otros, recopilada por sensores (Li, 2023). Un ejemplo de esto es *Ronin AI*, una plataforma en la nube desarrollada por la firma Seetalabs que permite monitorear en tiempo real el estado de los transformadores para prevenir cortes de energía abruptos y planear el adecuado mantenimiento de estos equipos⁴⁹.

Por su parte, como se mencionó, los gemelos digitales es una herramienta que utiliza algoritmos de aprendizaje

automático y que tiene gran potencial de uso en sectores de infraestructura. Esta herramienta consiste en una representación virtual y en tiempo real de un objeto, sistema, proceso o infraestructura física, que está conectada bidireccionalmente a su contraparte física (Fuller et al., 2020; Latorre et al., 2024; Sharma et al., 2022). Dicha conexión propicia que los gemelos digitales recopile, procese y analice datos del objeto físico en tiempo real, lo que permite monitorear, simular y optimizar el funcionamiento del elemento, así como predecir los requerimientos de mantenimientos preventivos (Fuller et al., 2020; Latorre et al., 2024; Sharma et al., 2022). Una característica importante de esta herramienta es que no solo replica el estado y comportamiento de la infraestructura física, sino que también predice su desempeño futuro, lo que contribuye a optimizar su funcionamiento. Así mismo, permite simular los efectos de cambios en el objeto físico sin que sufra daños reales, lo que hace posible probar modificaciones a los procesos a un bajo costo (Fuller et al., 2020; Latorre et al., 2024; Sharma et al., 2022).

La herramienta de gemelos digitales ha sido comúnmente aplicada en el sector de energía para optimizar la operación de las plantas generadoras y de los sistemas de transmisión y distribución (Latorre et al., 2024). Por ejemplo, la empresa de

energía eléctrica española Endesa⁵⁰ que opera principalmente en España y Portugal, ha implementado gemelos digitales en las 38 principales centrales hidroeléctricas, las cuales representan aproximadamente el 70% de la capacidad instalada; esto le ha permitido analizar información relevante como temperatura, velocidad, presión, y vibración, entre otros, para optimizar el control del funcionamiento de las centrales, así como alertar sobre anomalías y posibles fallas. De igual manera, en Finlandia el operador del sistema de transmisión -Fingrid- implementó con la empresa Siemens un modelo de gemelos digitales para optimizar la red de transmisión de este país; esto ha permitido mejorar la eficiencia, precisión y consistencia de modelos utilizados para la gestión de la red (Sharma et al., 2022; Gámiz et al., 2020).

De otra parte, en el sector transporte un área relevante de creación de valor de la IA es la mejora en los procesos de monitoreo y mantenimiento de los activos desplegados. De una parte, los modelos de IA permiten anticipar las fallas y anomalías de la infraestructura, lo que hace posible realizar

⁴⁸ ISA Intercolombia le apuesta a la Inteligencia Artificial para detectar modos de falla en líneas de transmisión. (2023, 18 diciembre). Recuperado de <<https://news.microsoft.com/es-xl/isa-intercolombia-le-apuesta-a-la-inteligencia-artificial-para-detectar-modos-de-falla-en-lineas-de-transmision/>>

⁴⁹ Fuente: Seetalabs. Disponible en: <<https://seetalabs.com/product/>>

⁵⁰ Endesa aplica la inteligencia artificial para crear "gemelos digitales" de sus centrales hidroeléctricas. (2024, 8 enero). Recuperado de <<https://elperiodicodelaenergia.com/endesa-aplica-inteligencia-artificial-crear-gemelos-digitales-centrales-hidroelectricas/>>Endesa – Sobre Endesa. (2024). <<https://www.endesa.com/es/sobre-endesa/nuestro-negocio/>>

mantenimientos preventivos orientados a aumentar su disponibilidad y fiabilidad. En segundo lugar, cuando se presentan las fallas, los modelos identifican con mayor precisión la necesidad de intervención, y generan información relevante para la reparación efectiva de las averías, lo que permite a su vez optimizar los presupuestos de mantenimiento, en contextos de recursos limitados (Calatayud *et al.*, 2022).

El uso de la tecnología, y específicamente de la IA, para la detección temprana de las fallas en la infraestructura vial contribuye a disminuir el número de accidentes viales en los países. Un caso de referencia en la región es la herramienta *Pavimenta2* que fue desarrollada por el BID y que ha sido implementada por autoridades de transporte y seguridad vial en once países de ALC. Esta solución utiliza videos de las vías y, con base en modelos de aprendizaje profundo y visión computacional, hace posible diagnosticar las condiciones del pavimento y de las señales viales, con el fin de priorizar las actividades de mantenimiento vial y optimizar los recursos a destinar. Esta herramienta, que es de código abierto, ha facilitado el análisis de 50 mil kilómetros de vías en ALC y ha permitido aumentar la eficiencia de los procesos de detección del estado de los activos viales en los países en los que ha sido implementada (**Figura 6**).

Otro caso enfocado en la detección de fallas de seguridad vial es *VíaSegura*, una solución de IA basada en aprendizaje automático y visión artificial desarrollada por el BID e IRAP⁵¹. Esta aplicación realiza un monitoreo preciso de las carreteras y detectar elementos de seguridad vial como el trazado y la cantidad de carriles, la iluminación, y la presencia de estaciones de servicio, entre otros, con el fin de generar alertas de mantenimiento preventivo y correctivo⁵². Esta solución de uso libre ha permitido el procesamiento de más de 61.000 kilómetros en Brasil, Ecuador, Guatemala y Perú⁵³ (**Figura 7**). De manera similar, el Ministerio de Transporte y Obras Públicas de Uruguay, en colaboración con el BID, realizó un ejercicio piloto de relevamiento de fallas en la red vial del país, que se basó en el análisis de imágenes mediante un modelo de IA. Los resultados de esta prueba permitieron a este ministerio contar con elementos para hacer más eficientes las actividades de inspección y mantenimiento⁵⁴.

Otro componente relevante de la gestión de la malla vial es la identificación de carreteras en zonas rurales. Esta labor resulta difícil en la medida que abarca áreas de los países que por su ubicación y topografía se encuentran apartadas. En diferentes países, la forma convencional de identificar y monitorear este tipo de vías ha sido manual, mediante cuadrillas que se desplazan a identificar las vías y reportan su estado.

En Colombia, el Departamento de Planeación Nacional (DNP) desarrolló una aplicación que mediante el análisis de imágenes satelitales y utilización de modelos de machine learning permitió realizar el inventario de la red vial terciaria del país; este inventario sirvió de insumo para la formulación de la Estrategia Integral para la Red Vial de Colombia (Consejería Presidencial para asuntos económicos y transformación digital, 2020).

51 International Road Assessment Programme (iRAP), es una organización benéfica que busca salvar vidas eliminando las carreteras de alto riesgo en todo el mundo. Más información disponible en: <<https://irap.org/about-us/>>

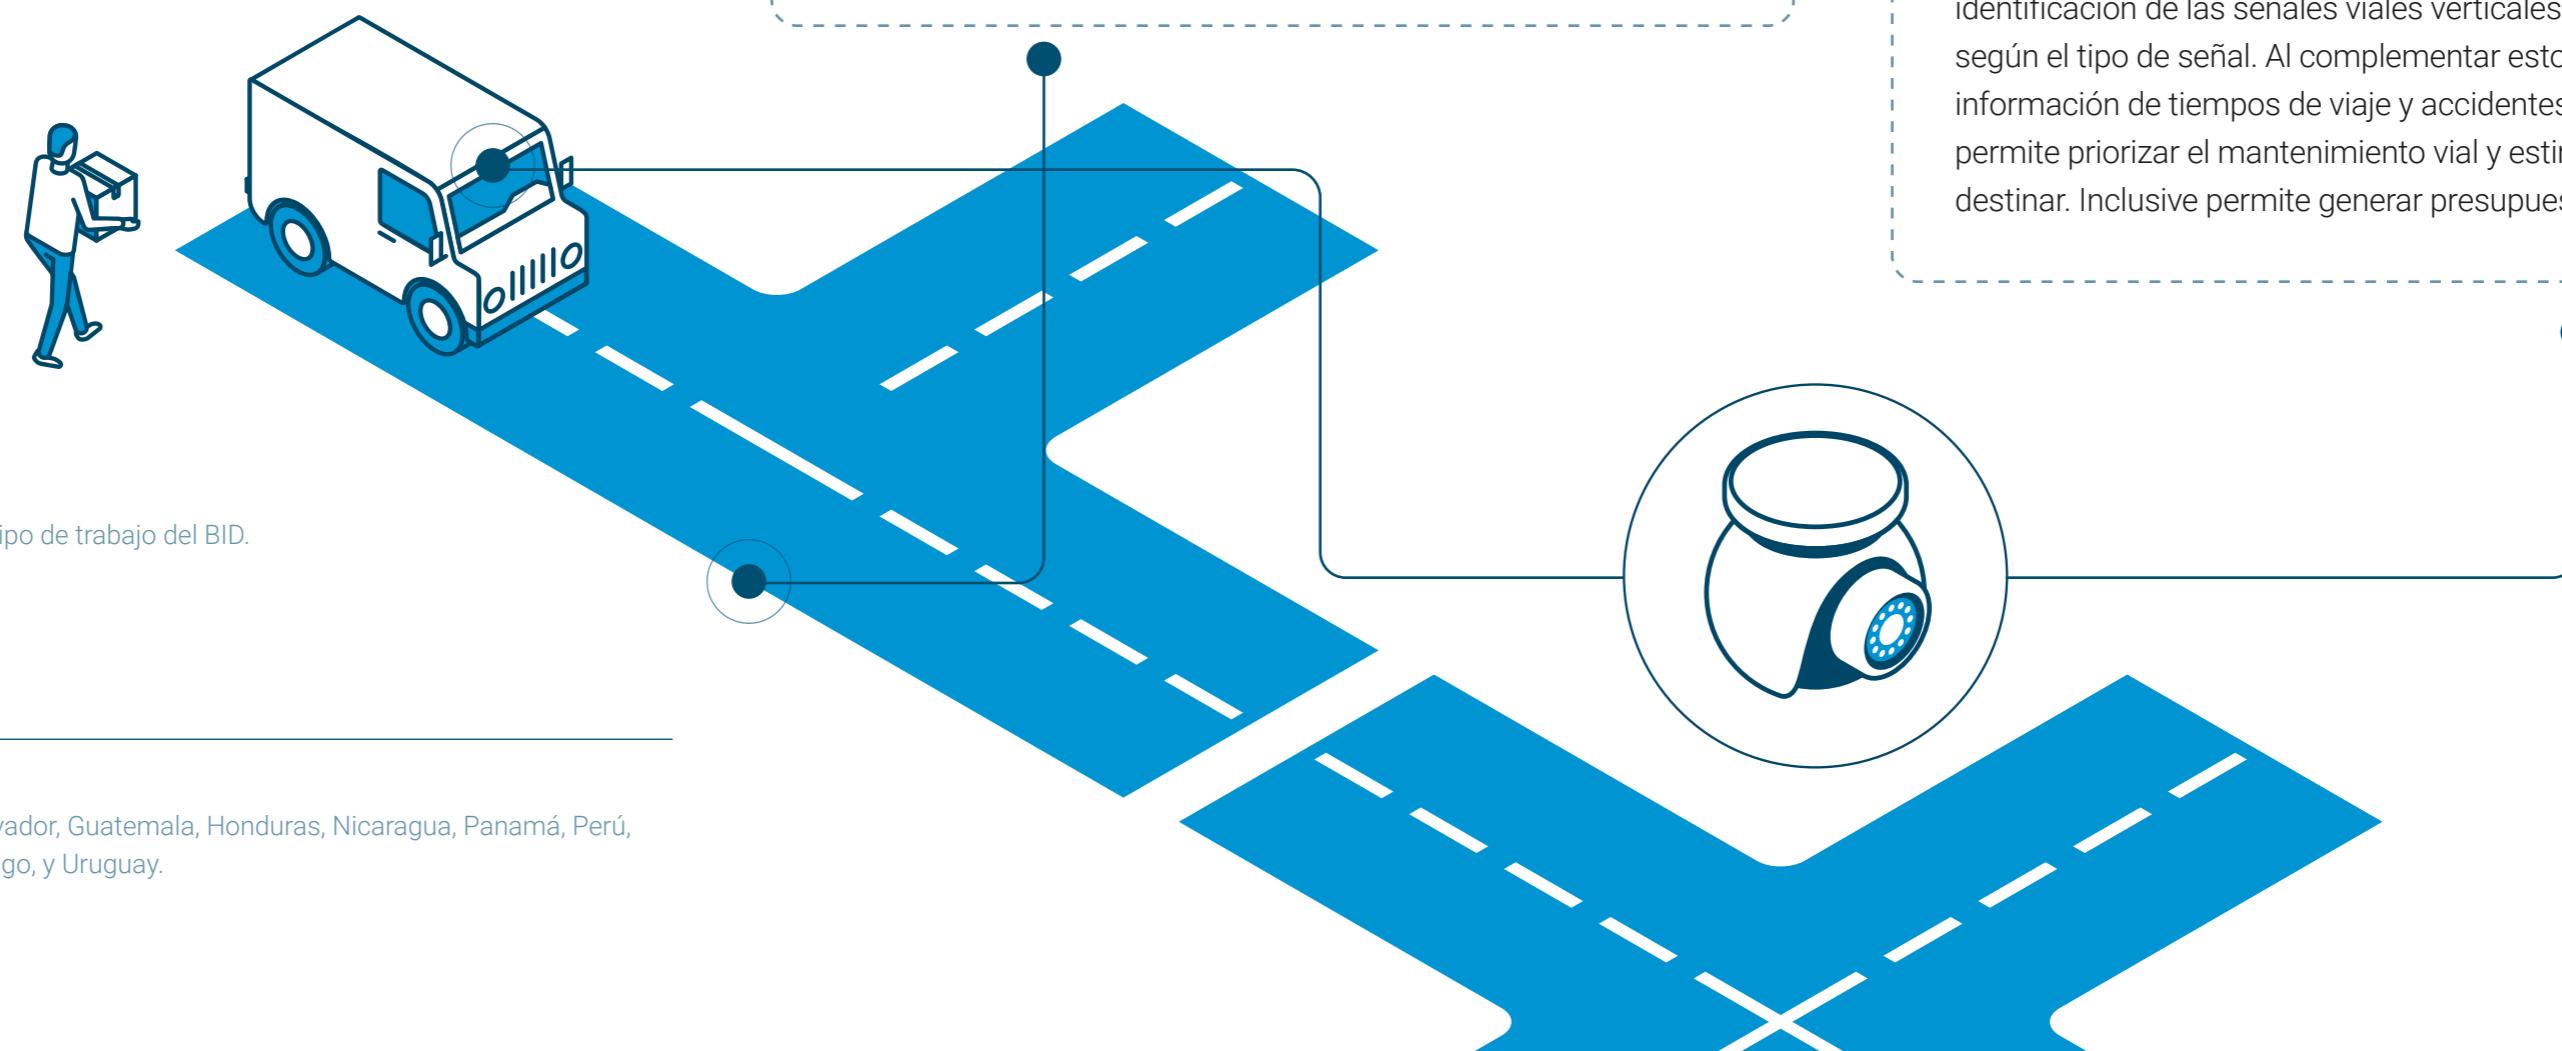
52 *VíaSegura*. Recuperado de <https://irap.org/es/rap-tools/light-ratings/viassegura/>

53 *VíaSegura*. Recuperado de <<https://fairlac.iadb.org/piloto/viassegura>>

54 Fuente: entrevista realizada con funcionarios del Ministerio de Transporte y Obras Públicas de Uruguay.

Figura 6. Descripción del caso Pavimenta2

Pavimenta2 es una solución basada en IA desarrollada por el BID que facilita la gestión del inventario de los activos viales ya que detecta el estado de las señales viales y del pavimento. Esta herramienta ha sido utilizada por entidades de transporte y de seguridad vial en once países de América Latina y el Caribe⁵⁵.



Fuente: BID, entrevistas al equipo de trabajo del BID.

⁵⁵ Brasil, Costa Rica, El Salvador, Guatemala, Honduras, Nicaragua, Panamá, Perú, Surinam, Trinidad y Tobago, y Uruguay.

Resultados e impacto

La implementación de Pavimenta2 ha facilitado el análisis de 50 mil kilómetros de vías en la región y ha brindado eficiencia al proceso de detección del estado de los activos viales con niveles de precisión superiores al 85%. Además, la adopción de Pavimenta2 ha permitido disminuir en 53 veces los costos y 39 veces los tiempos del proceso de análisis de la malla vial, en comparación con la alternativa manual. Así mismo esta solución ha contribuido a reducir los errores humanos, y a fomentar una mejor toma de decisiones con respecto a la infraestructura por medio de visualizaciones. Adicionalmente, en 2023 el BID lanzó el curso “Inteligencia Artificial en el Transporte”. Este es un curso virtual y de acceso gratuito orientado a participantes de ALC cuyo campo de acción profesional se relaciona con el sector transporte. El curso introduce una visión general de la IA y presenta algunas aplicaciones disponibles actualmente en el sector transporte. El curso también examina tecnologías específicas como los modelos de *machine learning* desarrollados para la solución Pavimenta2.

Conclusiones

Pavimenta2 ha permitido, según los entrevistados, georeferenciar la malla vial y sus defectos, priorizar las intervenciones y el tipo de reparación a realizar. La implementación de Pavimenta2 ha contado con receptividad de los beneficiarios en atención a las ventajas de esta herramienta. Dentro de las lecciones aprendidas se encuentra la importancia de las habilidades digitales que permitan el manejo de herramientas similares, el involucramiento de otros sectores como la academia, y la importancia de contar con la infraestructura informática necesaria. Código disponible: <https://github.com/EL-BID/pavimentados>
Curso Inteligencia Artificial en el Transporte: <https://cursos.iadb.org/es/indes/rea-inteligencia-artificial-en-el-transporte>

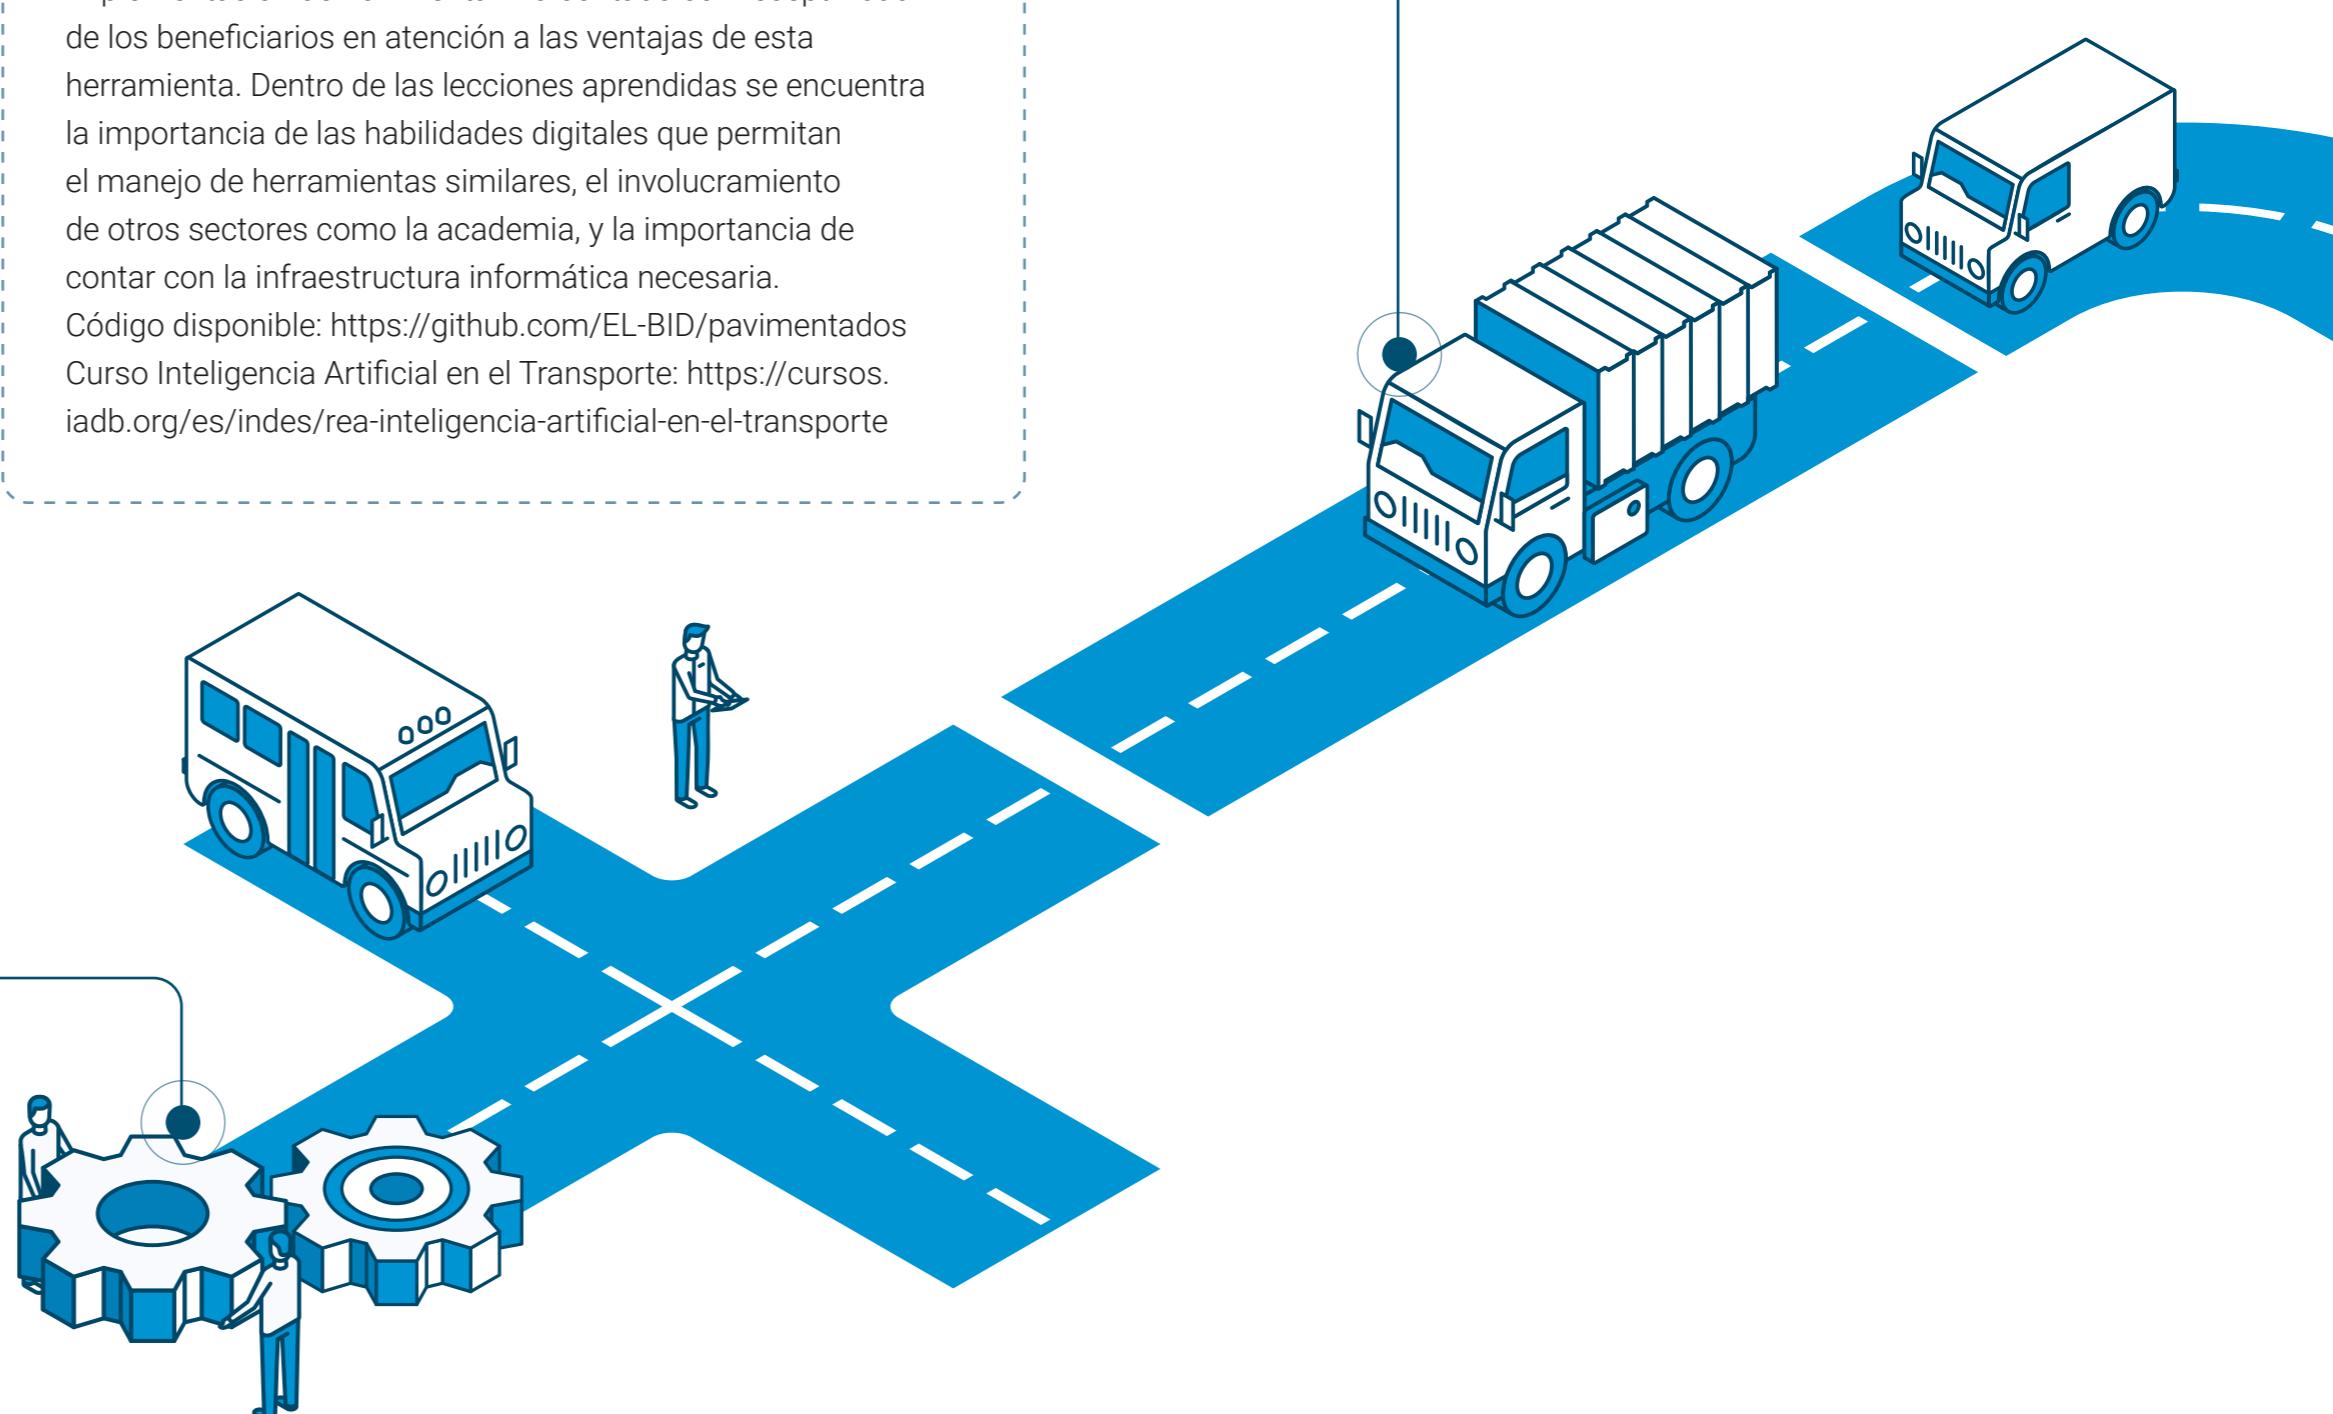


Figura 7. Descripción del caso VíaSegura

VíaSegura es un proyecto piloto desarrollado en conjunto por el BID y por el Programa Internacional de Evaluación de Carreteras (iRAP). Este proyecto utilizó IA para detectar de forma temprana el estado de las vías y mejorar la seguridad vial en cuatro países de la región (Brasil, Ecuador, Guatemala y Perú).

Problemática por resolver

Los defectos en la infraestructura vial pueden causar lesiones y muertes en las personas que sufren siniestros. A raíz de esto, iRAP creó un protocolo (Star Rating) para determinar el nivel de seguridad de la infraestructura vial para diferentes actores mediante una clasificación manual de las vías a partir de imágenes y videos en una escala de 1 a 5, donde uno es el menos seguro y cinco el más seguro. VíaSegura permitió automatizar mediante IA este proceso y, en este sentido, optimizar la identificación de diferentes elementos de la seguridad vial como la delineación y la iluminación de las vías, el número de carriles, y otros aspectos como la calidad de las curvas y la resistencia al deslizamiento, entre otras.

Descripción de la solución

VíaSegura automatiza el análisis de la clasificación de las vías mediante herramientas de IA, en particular machine learning (aprendizaje supervisado), aprendizaje profundo y visión artificial. Estos modelos fueron entrenados con más de 60.000 imágenes viales de Brasil.

Resultados e impacto

Este proyecto ha permitido etiquetar exitosamente imágenes de la infraestructura vial de manera más rápida y eficiente en más de 61.000 kilómetros de vías de la región, lo que ha permitido a las autoridades de transporte tomar acciones correctivas sobre esta infraestructura. De hecho, BID e iRAP han mencionado que con la herramienta se ha logrado disminuir el tiempo de inspección de la infraestructura vial de 78 a 2 semanas por cada 10 mil kilómetros de vías, con una precisión superior al 85%. Esto a su vez ha generado reducciones importantes en los costos asociados.

Código disponible en <https://github.com/EL-BID/VIAsegura>.



Por su parte, en el sector de agua y saneamiento, las pérdidas físicas de agua en los sistemas de acueducto representan uno de los mayores desafíos de la industria, ya que tienen un impacto significativo en la facturación de las empresas. Estas pérdidas generalmente se asocian con fugas en las tuberías de distribución creadas por problemas como el deterioro en la infraestructura y los hundimientos del suelo.

Las estrategias tradicionales de control de pérdidas técnicas se basan en la atención a las fugas reportadas por los usuarios (control pasivo), en encuestas periódicas o en monitoreos por zonas o sectores. La supervisión generalmente recae en la experticia del operario de turno y la precisión de la identificación puede verse afectada por la subjetividad del funcionario y el nivel de entrenamiento que tenga. Por esta razón, recientemente han surgido aplicaciones basadas en IA que buscan aportar valor al establecer mecanismos de clasificación con la suficiente precisión para detectar fugas de agua con base en la información recolectada (Mounce *et al.*, 2010; Vanijjirattikhan *et al.*, 2022).

Una solución de este tipo es la de la empresa estatal Servicio de Agua Potable y Alcantarillado de Lima (SEDAPAL), que opera en el Área Metropolitana de Lima. Esta empresa, en alianza con el BID, la fundación FEMSA y los gobiernos de

Suiza e Israel, realizó un piloto, que utiliza computación en la nube y modelos de IA para gestionar los sistemas de agua y tratamiento de residuos. Con este piloto la empresa pudo detectar 7.000 eventos, que incluyen pérdidas del recurso hídrico, incremento de flujo, fallas en los medidores o de telemetría, y cambios en la presión (Brzezinski, 2023).

Operación y mantenimiento de los sistemas

Uno de los factores determinantes de la gestión de los sistemas de generación y distribución de energía es la necesidad de garantizar la eficiencia de la operación y mantenimiento de estos para poder atender el aumento permanente de la demanda y proporcionar un suministro eléctrico confiable.

Una gestión eficiente de capacidad de la red prioriza la generación de energía que resulte menos costosa⁵⁶, tanto en términos monetarios como ambientales. Así mismo, la gestión energética puede centrarse en la optimización

de la capacidad de los sistemas locales. Algunos trabajos empíricos han encontrado que la implementación de una estrategia de monitoreo del consumo en conjunto con un sistema de almacenamiento que permita disminuir el consumo de la red en momentos de estrés del sistema, reduce considerablemente el costo de operación y las emisiones de CO₂ (H. Zhang *et al.*, 2012). Un caso de uso de la IA en este sentido es el de los sistemas de gestión inteligente que integran la administración de la capacidad y uso de los sistemas de almacenamiento de energía con modelos de predicción de precio y demanda, para determinar los horarios óptimos de cague y utilización del almacenamiento, ya sea de la red de distribución o del sistema de baterías (Abdalla *et al.*, 2021; Ahmad *et al.*, 2022).

En el mismo sentido, soluciones basadas en IA que resultan relevantes para los proveedores del servicio de energía eléctrica se están desarrollando en torno a las redes de energía inteligentes o *Smart Grids*, las cuales utilizan medidores inteligentes, tecnologías avanzadas de telecomunicaciones y sistemas de control remoto para coordinar de modo eficiente a todos los agentes de la red. Estos sistemas habilitan la comunicación de doble vía entre centrales de información y los usuarios y producen información que alimenta los modelos de administración de demanda con el fin de desarrollar

56 Por lo general, en los países para determinar la energía que entra al sistema, un modelo de optimización con múltiples restricciones evalúa la capacidad y el costo promedio de generación de las diferentes plantas, sean estas térmicas (gas o carbón), hídricas, nucleares, granjas solares o parques eólicos, escogiendo aquellas que resulten más eficientes y cumplan con la seguridad energética del sistema.

aplicaciones como la gestión de la demanda máxima, mediante la cual se administra el consumo dependiendo de los niveles de carga en el sistema (Johannesen *et al.*, 2019). Adicionalmente, se han desarrollado aplicaciones basadas en IA que, con base en información recolectada en dispositivos de medición, realiza la identificación y monitoreo en tiempo real de la topología y estado físico de la red en los sistemas de distribución de energía (Li *et al.*, 2020), lo que optimiza su operación y control (Chung *et al.*, 2023) y mejorar su confiabilidad y resiliencia.

En Francia, una empresa desarrolló una aplicación⁵⁷ que analiza el nivel de consumo de energía eléctrica en este país, y envía señales a los usuarios dependiendo del nivel de estrés del sistema. En la plataforma, se observa información en tiempo real, tanto de la demanda como de los precios mayoristas, así como modelos de pronóstico para que los consumidores puedan planear su consumo de energía eléctrica a lo largo del día. Así mismo, en países con altos niveles de pérdidas -técnicas y no técnicas-, el uso de este tipo de redes ha permitido identificar eficazmente dichas pérdidas y por ende desarrollar planes para prevenirlas (Levy *et al.*, 2018).

Otro caso de soluciones orientadas a la eficiencia y sostenibilidad en la operación son los sistemas de gestión de energía de edificios (*Building Energy Management Systems - BEMS*) que incluyen modelos de predicción de demanda, y que han sido implementados para mejorar la planeación y administración del consumo de energía, optimizar los recursos, y disminuir la huella de carbono (Runge & Zmeureanu, 2021). Una empresa británica desarrolló una aplicación que combina la información del sistema de administración de energía de un edificio con información meteorológica para optimizar el uso de la energía en tiempo real⁵⁸ mediante algoritmos de IA. Este software se conecta a medidores inteligentes y a la red central de energía, lo que permite a los administradores optimizar el consumo con base en los precios mayoristas. Esto ha generado ahorros cercanos al 10% en el costo de energía de los edificios que han implementado esta herramienta y una reducción aproximada de hasta el 40% en las emisiones de carbono⁵⁹.

La detección de pérdidas de energía, pérdidas físicas en las redes (pérdidas técnicas) o por consumo no autorizado asociado a piratería o fraude (pérdidas no técnicas), es otro de los principales desafíos que enfrentan las empresas de energía eléctrica. En relación con las pérdidas no técnicas, se han desarrollado soluciones soportadas en IA que permiten a las empresas realizar predicciones sobre la posibilidad de consumo no autorizado por parte de ciertos clientes, lo que hace posible optimizar las actividades de monitoreo e inspección. Un caso relevante en la región es el de la herramienta *Energizados*, la cual fue desarrollada por el BID y que ha sido implementada por empresas de energía en Brasil, Guatemala y Costa Rica. Esta solución analiza datos históricos de consumo y utiliza modelos de aprendizaje automático para identificar las conexiones con alta probabilidad de fraude. Con la utilización de *Energizados* en dos empresas de la región, el índice de recuperación de la inversión (Relación beneficio-costo) por fiscalización ha sido de 2,9, mientras que con el método tradicional el resultado de este índice es de 1,7. Además, en estos casos fue posible incrementar la detección de fraude eléctrico 1,65 veces en promedio (**Figura 8**).

57 Ecowatt. Recuperado de <<https://www.monecowatt.fr/>>

58 Grid Edge. Recuperado de <<https://grideedge.ai/ai-for-flexibility/>>

59 Case study: Artificial Intelligence for Building Energy Management Systems. (2019, 20 junio). Recuperado de <<https://www.iea.org/articles/case-study-artificial-intelligence-for-building-energy-management-systems>>

Figura 8. Descripción del caso Energizados

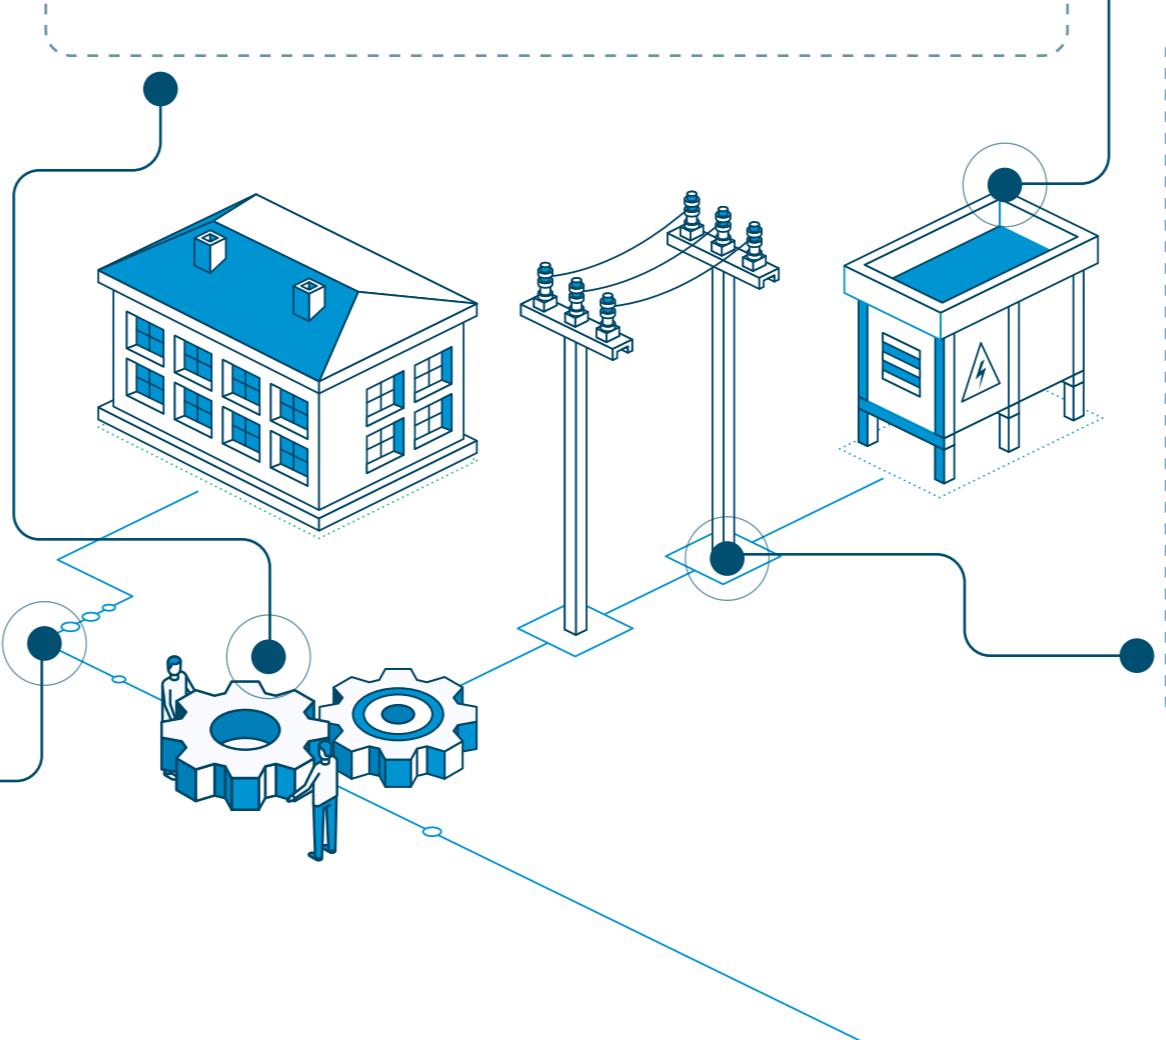
Energizados es una herramienta desarrollada por el BID que identifica mediante IA las pérdidas no técnicas de las entidades en el sector eléctrico. Esta solución ha sido implementada en la Compañía Estatal de Energía Eléctrica de Río Grande del Sur en Brasil, en la Empresa Eléctrica de Guatemala y en la Compañía Nacional de Fuerza y Luz de Costa Rica.

Problemática por resolver

En ALC el sector eléctrico enfrenta pérdidas de alrededor del 15% de la oferta eléctrica total. Las pérdidas no técnicas, asociadas a robos de energía, fraudes o errores de medición, impactan la sostenibilidad financiera de las empresas de energía, aumentan los costos para la población, y son un riesgo para la salud de las comunidades en el caso de las conexiones ilegales. Energizados busca solucionar estos problemas al mejorar el funcionamiento de la red eléctrica y al aumentar la eficiencia de las actividades de distribución eléctrica.

Descripción de la solución

Energizados es una solución de código libre que utiliza datos históricos de consumo para identificar las conexiones con una alta probabilidad de ser fraudulentas mediante herramientas de IA como modelos supervisados, semi-supervisados, y de reglas analíticas. Estos modelos han facilitado el análisis de la totalidad de las conexiones eléctricas de las empresas, y la identificación de anomalías y fraude, los cuales han sido verificados posteriormente por inspecciones manuales que retroalimentan los modelos. Adicionalmente, Energizados presenta los resultados mediante visualizaciones geográficas que facilitan los análisis territoriales y contribuyen a una mejor toma de decisiones, al brindar mayor eficiencia a la planeación de las inspecciones.



Fuente: BID, entrevistas al equipo de trabajo del BID.

Resultados e impacto

Con la utilización de Energizados en dos empresas, el índice de recuperación de la inversión por fiscalización (relación beneficio–costo) aumentó de 1,7 a 2,9. Además, con esta herramienta la detección de fraude eléctrico se pudo incrementar en 1,65 veces. En el caso de la Compañía Estatal de Energía Eléctrica de Río Grande del Sur en Brasil, la adopción de Energizados permitió aumentar la tasa de identificación de fraude del 17%-23% al 28%. De esta manera, en los casos en que ha sido implementada, Energizados ha permitido aumentar la precisión y eficiencia a las inspecciones y reducir sus costos.

Conclusiones

Según los entrevistados, Energizados es un ejemplo de una solución asequible y fácil de implementar en otros países de la región que transforma el sector mediante la utilización de IA, ya que alcanza mayores niveles de precisión en las inspecciones a un menor costo y en menos tiempo. Dentro de los factores de éxito de este proyecto están la disponibilidad de los datos, el compromiso por parte de la dirección de las empresas con la innovación, y la articulación entre los científicos de datos, los desarrolladores del producto, y los clientes. Código disponible: <https://github.com/EL-BID/Energizados>

Adicionalmente, ha tomado fuerza en este sector el desarrollo e implementación de modelos de predicción de precios mayoristas que se utilizan como insumo para la formulación de planes de producción de los generadores así como para el diseño de estrategias de puja de los comercializadores; esto permite a los proveedores avanzar en la optimización de sus procesos y en la reducción de sus costos, lo que resulta en mayor eficiencia en la utilización de los recursos naturales, mejor programación del consumo y menores tarifas para el usuario final (Pourdaryaei *et al.*, 2024). Por ejemplo, en la fase de operación y mantenimiento, los modelos de pronóstico ayudan a optimizar la variabilidad del flujo de entrada del agua para la hidroeléctricas y reducir sus pérdidas (Arch *et al.*, 2019). De igual manera, en el campo de la comercialización este tipo de modelos robustecen la automatización de las ofertas comerciales lo que aumenta la probabilidad de cierre de contratos (Arch *et al.*, 2019). En este contexto, durante los últimos años en el desarrollo de estos modelos se han incorporado componentes de IA que enfrentan de mejor manera desafíos como analizar los choques no lineales⁶⁰ relacionados

con el comportamiento de los precios, inferir relaciones ocultas entre variables, y desarrollar capacidades de aprendizaje sobre el pasado con el fin de mejorar la precisión de las predicciones (Castelli *et al.*, 2020; Pourdaryaei *et al.*, 2019).

En el sector transporte, existen diferentes herramientas de IA enfocadas en la gestión del tráfico, conocidas como Sistemas Avanzados de Gestión de Tráfico (ATMS)⁶¹ que contribuyen a disminuir la congestión, atender los accidentes en la vía de manera oportuna y disminuir la tasa de siniestralidad, entre otros⁶². Los ATMS están basados en modelos predictivos de tráfico que generan alertas a la administración para solucionar problemas en infraestructura existente o aumentar su capacidad, así como evaluar los impactos de una posible intervención (Boukerche *et al.*, 2020).

En el mismo sentido, existen soluciones que generan valor utilizando modelos de aprendizaje automático orientadas a la predicción de la congestión vial, las cuales analizan imágenes capturadas a través de cámaras de seguridad, drones o fotos

de inspectores, para estimar los volúmenes de vehículos, su velocidad y trayectoria⁶³. Esto aumenta la eficiencia en la gestión del tráfico, evaluar las posibles intervenciones viales y administrar la distribución de agentes de tránsito para maximizar el recurso humano⁶⁴. Un ejemplo de esto son los sistemas de monitoreo basados en IA que analizan las imágenes de las cámaras de vigilancia y modelan los flujos vehiculares para mejorar la gestión en tiempo real de los semáforos⁶⁵ y descongestionar las vías⁶⁶. Este tipo de modelos han sido usados en ciudades como Pittsburgh en Estados Unidos, Bengaluru en India, y Shanghái en China, entre otras⁶⁷. Así mismo, el gobierno de Singapur estableció un cobro dinámico por el uso de las vías (Electronic Road Pricing - ERP), en el que las tarifas son establecidas mediante modelos de aprendizaje automático, los cuales permiten simular tráficos

⁶⁰ El concepto de relación no lineal entre las variables hace referencia a que dicha relación involucra dependencias complejas que no pueden ser representadas a través de una línea recta y por lo tanto se requieren otras formas para su representación como por ejemplo a través de una función cuadrática, polinomial o con patrones irregulares.

⁶¹ Advanced Traffic Management Systems-ATMS

⁶² US. Department of Transportation Federal Highway Administration. (2023, agosto). Recuperado de <https://ops.fhwa.dot.gov/atdm/approaches/atm.htm>

⁶³ Inteia. Recuperado de <<https://inteia.com.co/estudios-de-movilidad/>>

⁶⁴ Ibidem.

⁶⁵ Gestión adaptativa de señales de tráfico (Adaptive Signal Control Technology-ASCT).

⁶⁶ Lopez Conde, M., & Twinn, I. (2019). How artificial intelligence is making transport safer, cleaner, more reliable and efficient in emerging markets: Traffic management operations. (2019, noviembre). Recuperado de <<https://www.ifc.org/content/dam/ifc/doc/mgrt/emcompass-note-75-ai-making-transport-safer-in-emerging-markets.pdf>>

⁶⁷ Ibidem.

y predecir el nivel de congestión futuro, para calcular un nivel óptimo que induzca una disminución en el nivel de congestión real. Para esto, desde el año 2020 el gobierno instaló sensores con tecnología GPS en los vehículos (Lehe, 2019).

Otro elemento fundamental de la gestión de los sistemas de movilidad es la identificación de la ubicación de los usuarios, ya sea estática o dinámica, la cual analiza los patrones de viaje y administrar de manera más eficiente la operación de los sistemas; esta identificación es posible gracias a los sistemas globales de navegación por satélite (*Global Navigation Satellite System - GNSS*)⁶⁸. Al respecto, en Madrid, España, Romanillos *et al.* (2018) realizaron, en coordinación con la Compañía de Transporte Municipal de la ciudad, un análisis⁶⁹ de más de 250.000 rutas del sistema de bicicletas públicas de la ciudad, BiciMAD, lo que permitió estudiar a profundidad los patrones de viaje de los usuarios, y obtener información

sobre ocupación de calles con el fin de identificar cuáles de estas podrían ser habilitadas ciertos días para ser usadas por peatones y bicicletas. Adicionalmente, con base en las matrices de origen-destino y la información de recorridos, los autores identificaron opciones de ampliación de los carriles exclusivos para bicicletas (Romanillos *et al.*, 2018).

De igual manera, se han desarrollado diferentes modelos de predicción de siniestros viales que identifican los tramos menos seguros, así como patrones de ubicación y mortalidad, y probabilidad de ocurrencia. La información generada por estos modelos es utilizada por las autoridades de transporte para mitigar las causas de los accidentes (García De Soto *et al.*, 2018), y priorizar las soluciones a implementar (Sameen & Pradhan, 2017; Santos *et al.*, 2021). Un ejemplo es el modelo basado en aprendizaje profundo que fue desarrollado por un grupo de investigadores de MIT y del Centro para la IA de Catar, que predice accidentes de tránsito con un alto nivel de precisión, el cual ha obtenido buenos resultados en ciudades en donde ha sido aplicado⁷⁰. Este modelo, puede ser utilizado para planear la construcción de nueva infraestructura vial

68 "Los GNSS son constelaciones de satélites coordinados para posicionar dispositivos en cualquier parte del globo terrestre", siendo el más conocido el Global Positioning System (GPS) de los Estados Unidos, sin que esto signifique que no hay más sistemas de este tipo desarrollados por otros países, como por ejemplo el BEIDOU de China, el GLONASS de Rusia y GALILEO de la Unión Europea, solo por mencionar algunos (Gutiérrez Puebla *et al.*, 2020).

69 El estudio incluye análisis de la distribución de los viajes, longitud de las distancias recorridas, velocidad, flujos en la red por franja horaria y tiempos de viaje, entre otros.

debido a que tiene la capacidad de predecir accidentes en lugares que no cuentan con registros históricos⁷¹.

En el mismo sentido, existen aplicaciones de IA dirigidas a los vehículos cuyo objetivo es contribuir a reducir el número de accidentes de tránsito y su nivel de complejidad. El BID apoyó al gobierno de San Salvador en la implementación de un piloto de un sistema para prevenir colisiones y accidentes de manera automática -*Collision Avoidance System (CAS)*- en el servicio de transporte público. Este sistema está integrado por una serie de alarmas, cámaras y sensores que alerta a los conductores del servicio en caso de que peatones, vehículos u otros componentes ajenos se aproximen de forma inminente⁷². De igual manera, este sistema detecta señales de tráfico y excesos de velocidad, controla las luces, define distancias seguras entre vehículos, y avisa sobre las salidas de carril y sobre posibles colisiones frontales y laterales con peatones y bicicletas⁷³.

Después de ocho (8) semanas de implementación, el porcentaje

71 Ibidem.

72 ¿Pilotos de innovación en el transporte público sin costo alguno para los países? Sí, es posible. (2018, septiembre). Recuperado de <<https://blogs.iadb.org/transporte/es/innovacion-en-el-transporte-publico-sin-costo alguno-para-los-paises-si-es-posible/>>

73 Ibidem.

de conductores que redujeron las alertas generadas superó el 40%. Este tipo de sistemas contribuyen a disminuir los choques entre vehículos hasta un 30%⁷⁴.

Otro aspecto fundamental en la gestión inteligente del tráfico es la atención de accidentes de tránsito. Actualmente se están desarrollando herramientas que aumentan los niveles de automatización de las respuestas para atender este tipo de emergencias. Una de ellas consiste en el análisis en tiempo real de los videos de las cámaras de seguridad utilizando redes neuronales convolucionales (CNN) para detectar objetos en tiempo real. Una vez se identifica el accidente y su posición geográfica se envía una alerta a las unidades de emergencia cercanas, lo que reduce considerablemente los tiempos de respuesta y aumenta la efectividad de la intervención (Desai *et al.*, 2021).

En el sector de puertos y logística los modelos de IA han sido utilizados, entre otros aspectos, para gestionar los flujos de tráfico de los vehículos de carga que transitan en los terminales (Valenciaport, 2020). De esta manera, mediante imágenes aéreas de los puertos se identifican situaciones

críticas en términos de congestión, lo cual permite que la administración gestione la velocidad con la que se aproximan los buques y de esta forma mitigar la congestión y reducir las emisiones de CO₂ generadas por los barcos⁷⁵. Un ejemplo de esto fue la implementación en el puerto de Barcelona de un sistema que permite la trazabilidad y gestión del flujo de contenedores en el puerto⁷⁶. Los contenedores tienen un código que no resulta fácil de identificar por parte del personal en tierra, ya que los contenedores pueden estar en diferentes posiciones y además algunos de los códigos no resultan legibles⁷⁷. Por lo anterior, los administradores del puerto utilizaron algoritmos de análisis de videos para poder obtener los códigos de los contenedores y de esta forma realizar el control del flujo de manera automática⁷⁸.

Finalmente, resulta generalizada la preocupación en torno a los niveles de contaminación y la participación que tiene el sector transporte en el aumento de partículas en suspensión que afecta a la población. De acuerdo con el BID, a nivel mundial el 25% de las emisiones anuales de gases efecto invernadero son producidas por el sector transporte, lo que lo convierte en el segundo mayor contribuyente de este tipo de emisiones, por detrás de la generación de electricidad y calefacción (Calatayud *et al.*, 2023). En ese sentido, un avance importante para mejorar el entendimiento de estos niveles de contaminación es el monitoreo de la ruta de los gases efecto invernadero. Para esto, el Laboratorio de Física Aplicada (APL) de la Universidad de Johns Hopkins desarrolló un modelo de aprendizaje profundo el cual, a través de imágenes satelitales e información pública de las carreteras y calles, estima de manera precisa las emisiones contaminantes producidas por el sector transporte en las 500 ciudades con más emisiones en el mundo⁷⁹.

75 Quantil. Recuperado de https://www.linkedin.com/posts/quantil-math-inteligencia-artificial-en-puertos-activity-7188503860242513920-lyPm?utm_source=share&utm_medium=member_desktop & ORCA AI. Recuperado de <https://www.orca-ai.io/>

76 Caso de éxito: puerto de Barcelona. Recuperado de <<https://www.allread.ai/es/casos-de-exito/puerto-barcelona-usan-inteligencia-artificial-identificar-contenedores-vagones/>>

77 Ibidem.

78 Ibidem.

79 Ibidem.

de sectores como el de agricultura, la salud pública y la conservación medioambiental. Un componente importante en los sistemas de gestión de agua son las plantas de tratamiento y distribución, pues estas garantizan el suministro continuo a la comunidad. Al respecto, la red de distribución requiere un monitoreo continuo del flujo para evitar fugas que generen pérdidas del recurso; así mismo, las plantas de tratamiento requieren de procesos avanzados de detección de contaminantes y separación de residuos (Nova, 2023).

Una solución relevante para hacer eficiente la gestión del recurso hídrico es el uso de medidores inteligentes. Estos medidores, por un lado, facilitan la inspección de las redes al detectar consumos inusuales, y por el otro, a los hogares y empresas les facilita la administración de su consumo. Si bien los medidores inteligentes no son por sí mismos una aplicación de IA, si son un habilitador para realizar este tipo de modelos, pues generan y capturan la información necesaria para realizar análisis de clasificación y predicción. Un ejemplo es el de la Empresa de Acueducto y Alcantarillado de Bogotá (EAAB), que lanzó el proyecto de Medición Inteligente de Agua que busca que los grandes consumidores controlen sus consumos y de esta manera conseguir estadísticas y fijar alarmas para monitorear sus procesos productivos e incluso

identificar oportunamente fugas internas⁸⁰. Sistemas de telemedición similares están siendo instalados en diferentes ciudades de ALC⁸¹, en buena medida porque crean valor al fortalecer la digitalización de los sistemas de distribución y tratamiento de agua, así como la optimización del consumo por parte de los usuarios⁸².

De otra parte, de manera similar al sector de energía, uno de los mayores problemas que enfrentan las empresas del sector de agua son las pérdidas en las redes de distribución, conocidas como agua no remunerada (Non-Revenue Water-NRW), ya sea por consumo no autorizado (piratería o fraude) -conocidas como pérdidas no técnicas-, o por pérdidas físicas del recurso (Vanijirattikhan *et al.*, 2022) -pérdidas técnicas-.

Una aplicación de la IA destacada en este sector es el desarrollo e implementación de modelos para detectar pérdidas no técnicas de agua en los sistemas de acueducto. Un caso de referencia en la región es *Aquadata*⁸³, una solución desarrollada por el BID e implementada en 2023 por la Empresa Pública Metropolitana de Agua Potable y Saneamiento (EPMAPS) de Quito, Ecuador. (**Figura 9**).

80 Bogotá estrena la medición inteligente del agua (MIA). (2022, octubre). Recuperado de <<https://www.acueducto.com.co/wps/portal/EAB2/Home/general/sala-de-prensa/boletines/detalle/bogota+estrena+la+medicion+inteligente+del+agua+%28mia%29>>

81 Análisis de participación y tamaño del mercado de medidores inteligentes de América del Sur y Central: Tendencias y pronósticos de crecimiento (2024-2029). Recuperado de <<https://www.mordorintelligence.com/es/industry-reports/south-and-central-america-smart-meters-market-industry>>

82 La provincia de Neuquén instaló 300 medidores inteligentes de agua sobre red Sigfox. Recuperado de <<https://www.grupodatco.com/neuquen-despliega-medidores-de-agua-inteligentes-con-tecnologia-sigfox/>>

83 BID fAIr LAC. Acuadata. <<https://fairlac.iadb.org/piloto/acuadata>>. Entrevistas al equipo de trabajo de EPMAPS y del BID.

Figura 9. Descripción del caso Aquadata

Aquadata es una solución desarrollada por el BID e implementada por la Empresa Pública Metropolitana de Agua Potable y Saneamiento de Quito (EPMAPS) en el año 2023. Esta solución detecta las pérdidas no técnicas del recurso hídrico mediante modelos de inteligencia artificial y datos históricos.

Problemática por resolver

El propósito de Aquadata es contribuir a disminuir las pérdidas no técnicas y comerciales de agua en los sistemas de acueducto, que pueden llegar a representar el 40% del recurso, y aumentar la efectividad en la identificación de anomalías en el consumo hídrico, con menores requerimientos de controles e inspecciones.

Descripción de la solución

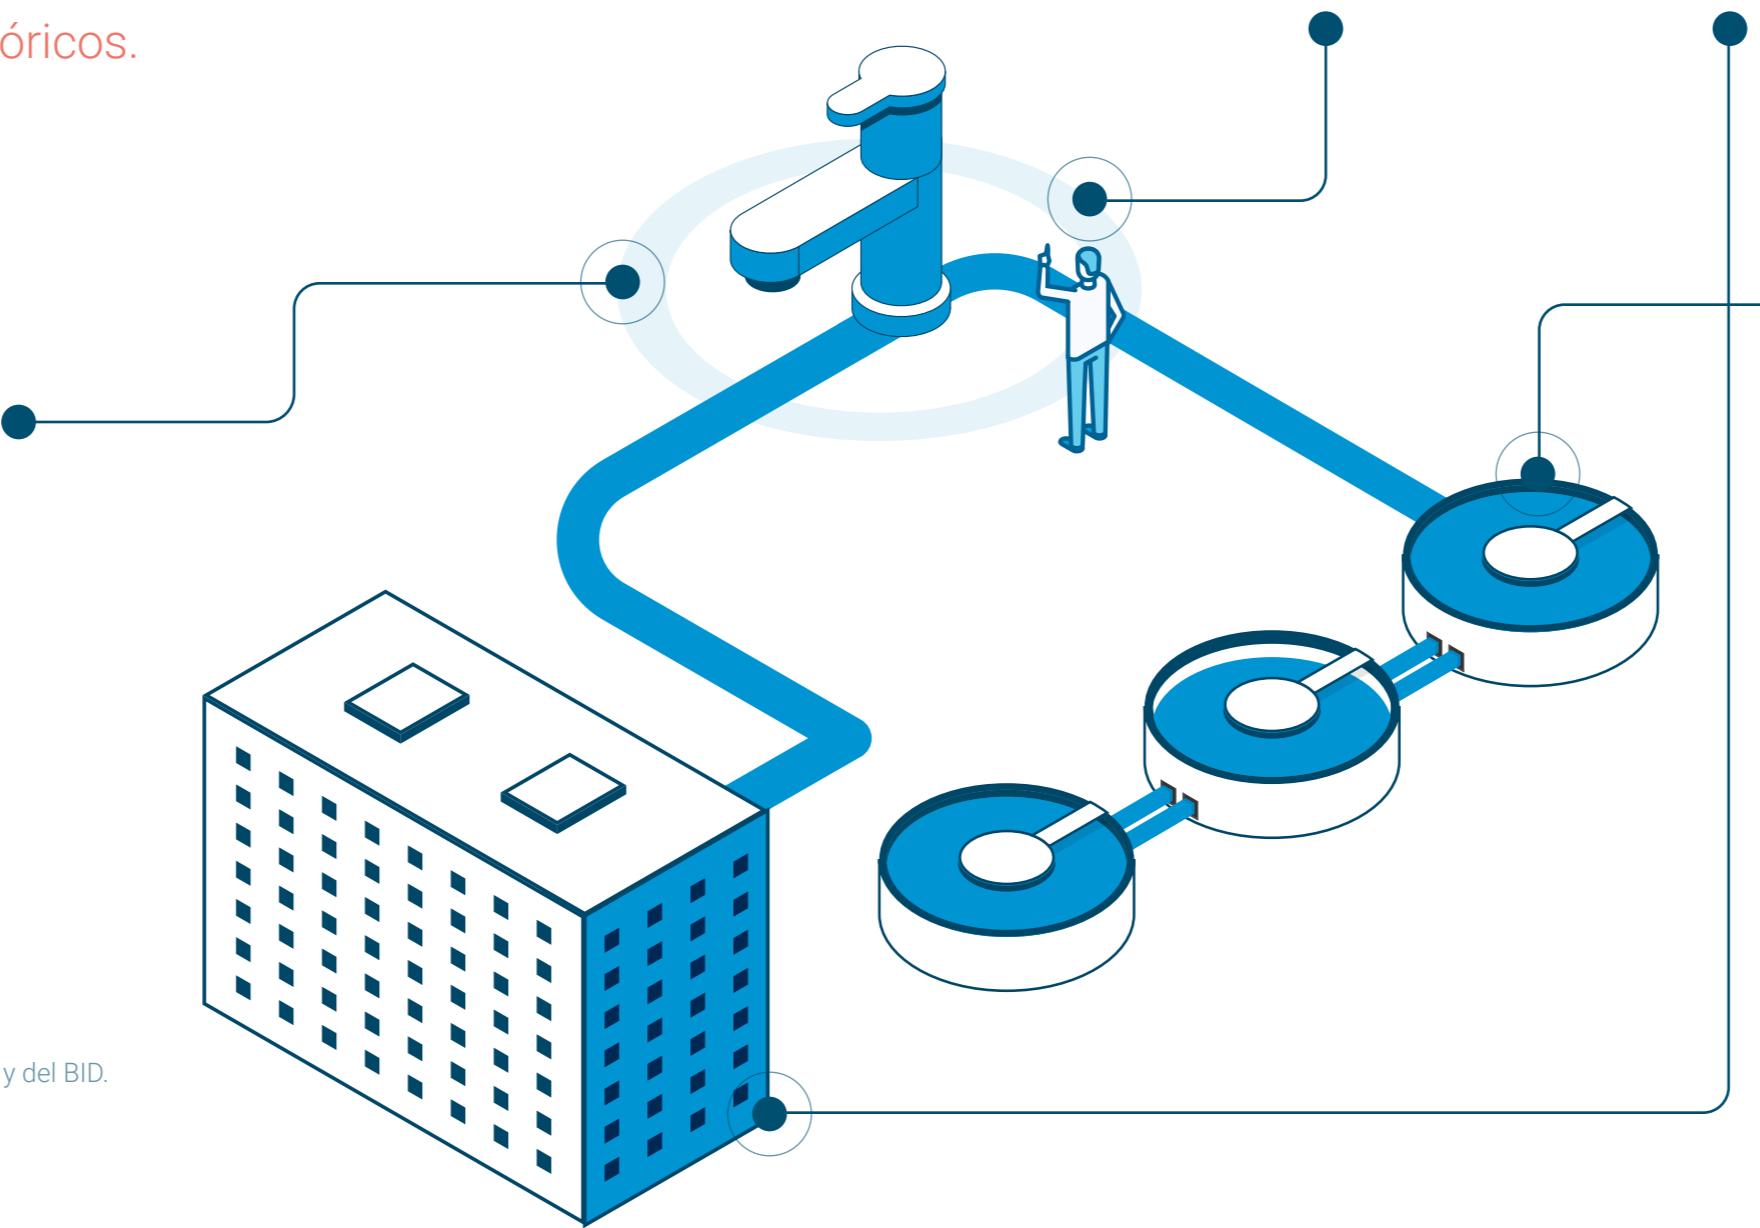
Aquadata utiliza modelos de aprendizaje automático de IA, específicamente modelos supervisados de clasificación y el modelo de aceleración de gradiente a partir de datos de 2010-2022 de un millón de clientes para identificar su probabilidad de fraude. Durante las pruebas, EPMAPS comprobó los buenos resultados de la herramienta realizando fiscalizaciones en campo.

Resultados e impacto

Aquadata ha permitido que EPMAPS detecte un mayor número de anomalías en el consumo de agua con un nivel de confianza superior al 90%. Esto ha permitido mayor efectividad por parte de los inspectores de campo, cuyos niveles de asertividad (imposición de multas) aumentaron del 13% al 34% de las inspecciones, así como identificar averías en más del 18% de los medidores del agua.

Conclusiones

Según las entrevistas a miembros de los equipos de EPMAPS y del BID, este proyecto ha permitido fortalecer los resultados financieros de la entidad y ha contribuido a preservar los recursos hídricos de la ciudad. Algunos de los factores de éxito de este proyecto son las capacitaciones y la transferencia de conocimiento, y el trabajo de equipos multidisciplinarios. Algunos de los retos enfrentados incluyen el escepticismo inicial, las dificultades asociadas a la captura y formato de los datos, y el almacenamiento de estos, en cumplimiento de la normativa local.



De otra parte, uno de los problemas principales que enfrentan las plantas de tratamiento es el alto nivel de contaminación del agua, que por lo general es causado por la existencia de bacterias, parásitos, fármacos, fertilizantes, insecticidas, y pesticidas, entre otros, que por lo general son difíciles de clasificar en la fase de tratamiento, en parte porque no alteran de forma permanente el color del agua y no son fáciles de reconocer por el ojo humano (Maroju *et al.*, 2023). En atención a esta problemática, existen diferentes estudios de caso que se han centrado en la aplicación de algoritmos de aprendizaje automático y profundo para identificar los elementos de contaminación en el agua. Por ejemplo, investigadores de la Universidad de Chicago utilizaron IA para crear sondas químicas capaces de detectar y eliminar sustancias perjudiciales en el agua⁸⁴.

También existen empresas que se encargan de implementar sistemas de automatización de plantas de tratamiento de agua con el fin de potencializar su administración. A partir de un modelo digital de la planta de tratamiento, se monitorea el rendimiento, lo que permite mejorar su funcionamiento y proporcionar información sobre las necesidades de

mantenimiento⁸⁵. Este tipo de sistemas también adapta los procesos de depuración de aguas residuales a las nuevas tecnologías, por ejemplo, mediante algoritmos de clasificación para detectar cuerpos extraños en las fuentes de agua y eliminar los deshechos mediante tratamiento biológico⁸⁶.

Así mismo, Granata *et al.* (2017) desarrollaron un modelo de predicción del nivel de contaminación en el caudal de aguas residuales, a través de algunas características y comportamientos del drenaje, con base en información de 65 comunidades en Estados Unidos, entre 1992 y 2002. Los investigadores encontraron que el modelo de aprendizaje automático⁸⁷ utilizado predice correctamente el nivel de contaminación de las aguas residuales y es generalizable, es decir, puede ser usado en otras plantas de tratamiento. Además resulta efectivo para ser usado en los sistemas de gestión de las plantas con información de los sensores en tiempo real (Granata *et al.*, 2017). Igualmente, el gobierno de Singapur utilizó una herramienta de control de la planta de

tratamiento de Ulu Pandan que le permite realizar modelos predictivos tanto de las aguas residuales como de los indicadores de calidad del agua⁸⁸. El software utiliza técnicas de aprendizaje automático para modelar el flujo y carga de las aguas residuales, así como también los niveles de oxígeno y de ciertos químicos dentro de los cuerpos de agua de la planta⁸⁹. Una ventaja de esta herramienta es que se nutre de los datos de funcionamiento de la planta; así, el modelo sigue aprendiendo, lo que le aumenta su precisión constantemente⁹⁰.

Finalmente, la IA contribuye a mejorar la gestión de los residuos sólidos. Un caso de uso es el reconocimiento de imágenes que detecta vertederos, potenciales o existentes, así como facilita la clasificación de los residuos. Por ejemplo, la fundación argentina Bunge y Born ha desarrollado mediante IA e imágenes satelitales un sistema que identifica basurales informales a cielo abierto para prevenir su expansión y su impacto negativo en términos ambientales y de salud pública (Fundación Bunge y Born, s.f y 2021).

85 Managing sustainable water treatment with IntelliFlux. Recuperado de <<https://ifctrl.com/industries/water/>>

86 Ibidem.

87 En este caso los autores utilizaron árboles de decisión y regresión de vectores de soporte, siendo este último método el que obtuvo mejores resultados.

88 IWA (2020). Digital Water, Artificial Intelligence solutions for the water sector: Predictive wastewater treatment plant control. Recuperado de <https://iwa-network.org/wp-content/uploads/2020/08/IWA_2020_Artificial_Intelligence_SCREEN.pdf>

89 Ibidem.

90 Ibidem.

84 Inteligencia artificial aplicada al tratamiento de aguas residuales municipales. (2021, mayo). Recuperado de <<https://www.bluegold.es/es/inteligencia-artificial-aplicada-al-tratamiento-de-aguas-residuales-municipales/>>

Relacionamiento con los clientes

La utilización de IA en el sector energético contribuye a mejorar la relación de las empresas con los clientes al habilitar la provisión de información relevante y al facilitar la comunicación. La adopción de IA induce ahorros por parte de los clientes debido al acceso a información sobre los costos de la energía, los momentos óptimos para usarla, así como la cantidad de energía que generan mediante fuentes renovables (Engelhardt, McClelland & Collet, s.f.). Además, herramientas de IA como bots apoyan el procesamiento de correos electrónicos y de chats en plataformas digitales. Estos pueden solicitar información faltante a los usuarios, informarles en casos de interrupciones o anomalías en los servicios, ayudarles a optimizar sus consumos con base en sus necesidades y consumos previos, y proporcionarles respuestas en un menor tiempo. Lo anterior mejora la experiencia y satisfacción de los usuarios, y a la vez impulsa la lealtad de los clientes con las empresas⁹¹.

Un caso de uso de la IA que genera valor al optimizar la operación de los sistemas de transporte y contribuir a reducir la congestión es el de las aplicaciones orientadas a los usuarios. Los modelos predictivos de tráfico que utilizan técnicas de IA⁹² permiten el desarrollo de aplicaciones que tienen como objetivo proveer a los ciudadanos de mejor información para la toma de decisiones en transporte. Tal es el caso del proyecto TIMON, dirigido por un grupo de investigación de la Universidad de Deusto en España y que optimiza rutas para los usuarios según sus necesidades, a partir de, por ejemplo, predicciones del tráfico⁹³.

Existen también aplicaciones de IA orientadas a los usuarios que les brindan información relevante para el uso eficiente de los sistemas de transporte público. Los usuarios de metro y bus de la ciudad de Nueva York, a través de la aplicación de la

Autoridad Metropolitana de Transporte (MTA)⁹⁴, acceden en tiempo real a la información relacionada con la ocupación de los vehículos, los horarios, el estado del servicio, la existencia de anomalías en los trayectos y el tiempo promedio de espera, entre otros (Calatayud *et al.*, 2022). Esta información es provista gracias a la utilización de modelos de IA que procesan los datos generados por los sensores ubicados en la infraestructura de transporte (bus, trenes y estaciones) (Calatayud *et al.*, 2022). Algunos estudios empíricos han demostrado que contar con este tipo de aplicaciones aumenta la satisfacción del usuario debido a que impacta positivamente los indicadores de fiabilidad y robustez del sistema (Chan *et al.*, 2020).

Otro ejemplo de este tipo de herramientas es la desarrollada por el BID para el aeropuerto de Santa Cruz de la Sierra, Viru Viru en Bolivia. Esta aplicación, tiene como objetivo brindarles a las personas con discapacidad visual mayor independencia para recorrer el aeropuerto⁹⁵. Esta aplicación

91 Visor AI (2021); Microsoft – Streebo Inc (2024); Infosys BPM (2024); Wipro (2019); Talbott (2024); Sergienko (2024).

92 A pesar de los buenos resultados que se están obteniendo en términos de precisión de la predicción con los modelos de aprendizaje automático en comparación con los modelos estadísticos de series de tiempo, es importante mencionar que aún falta avanzar en términos de disminuir la complejidad estructural de los modelos que a su vez aumenta la complejidad computacional y por ende demanda más recursos.

93 TIMON, Inteligencia Artificial que predice las congestiones de tráfico. (2019, enero). Recuperado de <<https://www.spri.eus/es/teics-comunicacion/timon-inteligencia-artificial-que-predice-las-congestiones-de-trafico/#:~:text=El%20objetivo%20de%20TIMON%20es,inteligencia%20artificial%20y%20big%20data.>>

94 Para más información consultar: <<https://new.mta.info/>>

95 El aeropuerto de Viru Viru en Bolivia apuesta por la accesibilidad universal y la inclusión. (2023, octubre). Recuperado de <<https://blogs.iadb.org/transporte/es/el-aeropuerto-de-viru-viru-en-bolivia-apuesta-por-la-accesibilidad-universal-y-la-inclusion/>>

captura mediante imágenes el lugar en donde se encuentra el usuario y compara en tiempo real la imagen captada con la colección de imágenes del aeropuerto que existe en la nube y mediante indicaciones de voz guía al usuario a través de la estación⁹⁶. Para la búsqueda de puestos por parte del usuario, estos están agrupados en función de su categoría, por ejemplo, aerolíneas, baños, cajeros automáticos, restaurantes, entre otros⁹⁷. Este tipo de aplicaciones permiten por un lado incluir a esta población en la utilización de una infraestructura crítica como es un aeropuerto⁹⁸, y por el otro, optimizan los recursos de operación de los aeropuertos pues provee ayuda personalizada y facilita el contacto con personas encargadas en caso de requerir ayuda.

De otra parte, un factor relevante en la planeación y gestión de la capacidad de los sistemas de transporte es la perspectiva de género en el diseño de los diferentes sistemas de transporte público y en la evaluación del impacto de su

implementación. Al respecto, algunos trabajos empíricos han utilizado modelos de aprendizaje automático, como por ejemplo las Redes Bayesianas (BN), para analizar información de demanda de los medios de transporte público con el fin de identificar las características que deben ser mejoradas para consolidar sistemas de transporte público con perspectiva de género. Un estudio en particular analizó la información del transporte ferroviario y del sistema de bicicletas públicas, entre otros servicios, y encontró que para contar con un sistema ferroviario más justo y que aumente la demanda por parte de las mujeres se hace necesario mejorar la disposición de los asientos para reducir la interacción social, aumentar el espacio personal, integrar servicios de movilidad compartida para las conexiones de última milla, construir puntos de ayuda para las usuarias en caso de agresión o necesidad, anunciar medios de contacto de ayuda, así como promover campañas para reducir los incidentes (Molero *et al.*, 2021). Dicho estudio también encontró que, para el caso del sistema de bicicletas compartidas, se requiere centrar los esfuerzos en disminuir las rutas con cierto nivel de inclinación, incluir bicicletas eléctricas, poner a disposición elementos de protección para la lluvia y la inclusión de sillas para niños, entre otros (Molero *et al.*, 2021).

⁹⁶ Ibidem.

⁹⁷ Ibidem.

⁹⁸ De acuerdo con *moviliblog* del BID, la contribución del turismo en Bolivia equivale al 4.6% del PIB y a más de 320,000 empleos directos e indirectos. Uno de los lugares fundamentales para el turismo del país es el aeropuerto de Santa Cruz de la Sierra, Viru Viru. Este es considerado el más importante dado que allí ingresan al país y salen del país un alto número de bienes y pasajeros.

De igual manera, para avanzar en la mejora de la seguridad en las estaciones, especialmente para las mujeres, en diferentes lugares se están desarrollando modelos de *machine learning* para analizar en tiempo real los videos de las cámaras de seguridad instaladas y reportar posibles comportamientos anómalos. Un ejemplo de esto es el software que está desarrollando la Universidad de Wollongong en Australia para poder detectar comportamientos como peleas y acoso en las estaciones de transporte público que puedan indicar episodios de inseguridad. En caso de identificarlos, el modelo emite alertas para que las autoridades puedan intervenir de manera oportuna⁹⁹.

La adopción de IA en el sector de agua y saneamiento induce genera valor, al igual que en el sector de energía, al mejorar el relacionamiento de las empresas con sus clientes. Mediante IA las empresas entienden los consumos de los clientes, lo que les permite personalizar servicios a bajo costo, detectar anomalías en la demanda e informarles de interrupciones del servicio y de fallas. Lo anterior genera ahorros del recurso

⁹⁹ University of Wollongong Australia. AI research to aid women's safety on public transport. Recuperado de <<https://www.uow.edu.au/media/2020/ai-research-to-aid-womens-safety-on-public-transport.php>>

hídrico y mejora la experiencia de los usuarios¹⁰⁰. Al respecto, una empresa de agua y saneamiento que ha utilizado IA para este propósito es la Autoridad de Electricidad y Agua de Dubái. Esta organización desarrolló *Rammas*, un chatbot que resuelve dudas de múltiples agentes como clientes, proveedores, potenciales trabajadores, y contratistas mediante la aplicación de la organización, y otras plataformas digitales (Deloitte, 2023). Una de las ventajas de esta herramienta es que funciona en dos idiomas permanentemente, lo que facilita la interacción de los clientes.

Así mismo, el BID a través de la alianza “Fuente de Innovación”¹⁰¹, ha implementado proyectos piloto que aplican tecnologías inteligentes de residuos (*Smart Waste Technologies*) para mejorar la gestión de los desechos sólidos domésticos. Uno de estos proyectos se está llevando a cabo con el *Consorcio Intermunicipal*

del Valle Medio de Itajaí (CIMVI) en Brasil. El proyecto pretende mejorar la comunicación con los usuarios finales y mejorar la recogida y el análisis de datos para generar indicadores de gestión y apoyar la toma de decisiones. La planta de clasificación de residuos del CIMVI en Brasil ha integrado la tecnología *Greyparrot*, que utiliza visión por computador e IA para analizar los residuos reciclables. Este sistema automatiza la auditoría y el análisis del 100% de los residuos procesados, lo que permite identificar 89 clases de residuos en 13 categorías, incluidos más de 35 tipos de plásticos rígidos y flexibles.

La tecnología proporciona datos en tiempo real sobre la composición de los residuos, y esta información se presenta en un tablero de control con información relevante sobre los tipos y las cantidades de desechos. Este esfuerzo de digitalización permite al CIMVI acceder a datos fiables y oportunos, lo que mejora la toma de decisiones y la comunicación con las partes interesadas y, en última instancia, mejora sus servicios de gestión de residuos.

100 Nestor, (2023); Talbott, (2024); Wipro, (2019); Tempest, (2023)

101 Fuente de Innovación es una alianza del Grupo BID con socios externos que promueve el desarrollo y adopción de soluciones innovadoras en el sector de agua y saneamiento básico en ALC, con el objetivo de lograr servicios inteligentes, inclusivos y sostenibles. Fuente: Sitio Web <<https://www.iadb.org/es/quienes-somos/topicos/agua-y-saneamiento/iniciativas/fuente-de-innovacion>>





CONSIDERACIONES PARA LA ADOPCIÓN DE LA IA EN LOS SECTORES DE INFRAESTRUCTURA

4.1

Metodología de desarrollo ágil de soluciones basadas en IA

Como se señaló en el Capítulo 3, las soluciones basadas en IA tienen el potencial de generar valor e impactar significativamente el desempeño de sectores de infraestructura como el de energía, transporte, agua, saneamiento, y residuos sólidos. En particular, representan una herramienta para fortalecer la planeación y diseño, la construcción, la gestión y el mantenimiento de activos, para optimizar la eficiencia operativa, y mejorar el relacionamiento con los usuarios.



La incorporación de IA puede convertirse en un factor transformacional, que implica la modificación de procesos, sistemas, relacionamiento entre áreas y, en algunos casos, la adopción de nuevos modelos de operación y negocio. Resulta entonces relevante para las organizaciones de infraestructura implementar metodologías de desarrollo e innovación en IA que sean robustas, alineadas con sus objetivos, y acordes con las mejores prácticas. El desarrollo e implementación exitosos de este tipo de soluciones implica la adopción de consideraciones técnicas, legales, éticas, matemáticas, gerenciales, culturales, tecnológicas y de gestión de proyectos. Esto requiere una comprensión holística del problema y de la solución, para lo cual es necesario implementar metodologías flexibles que incorporen eficazmente estas consideraciones. Adicionalmente, el uso de modelos de IA por lo general implica incorporar estrategias de gestión del cambio. En este sentido, la adopción de soluciones de IA demanda un gobierno responsable, que considere espacios de comunicación, transparencia, inclusión, equidad, seguridad de la información y sistemas, confiabilidad en los resultados y rendición de cuentas.

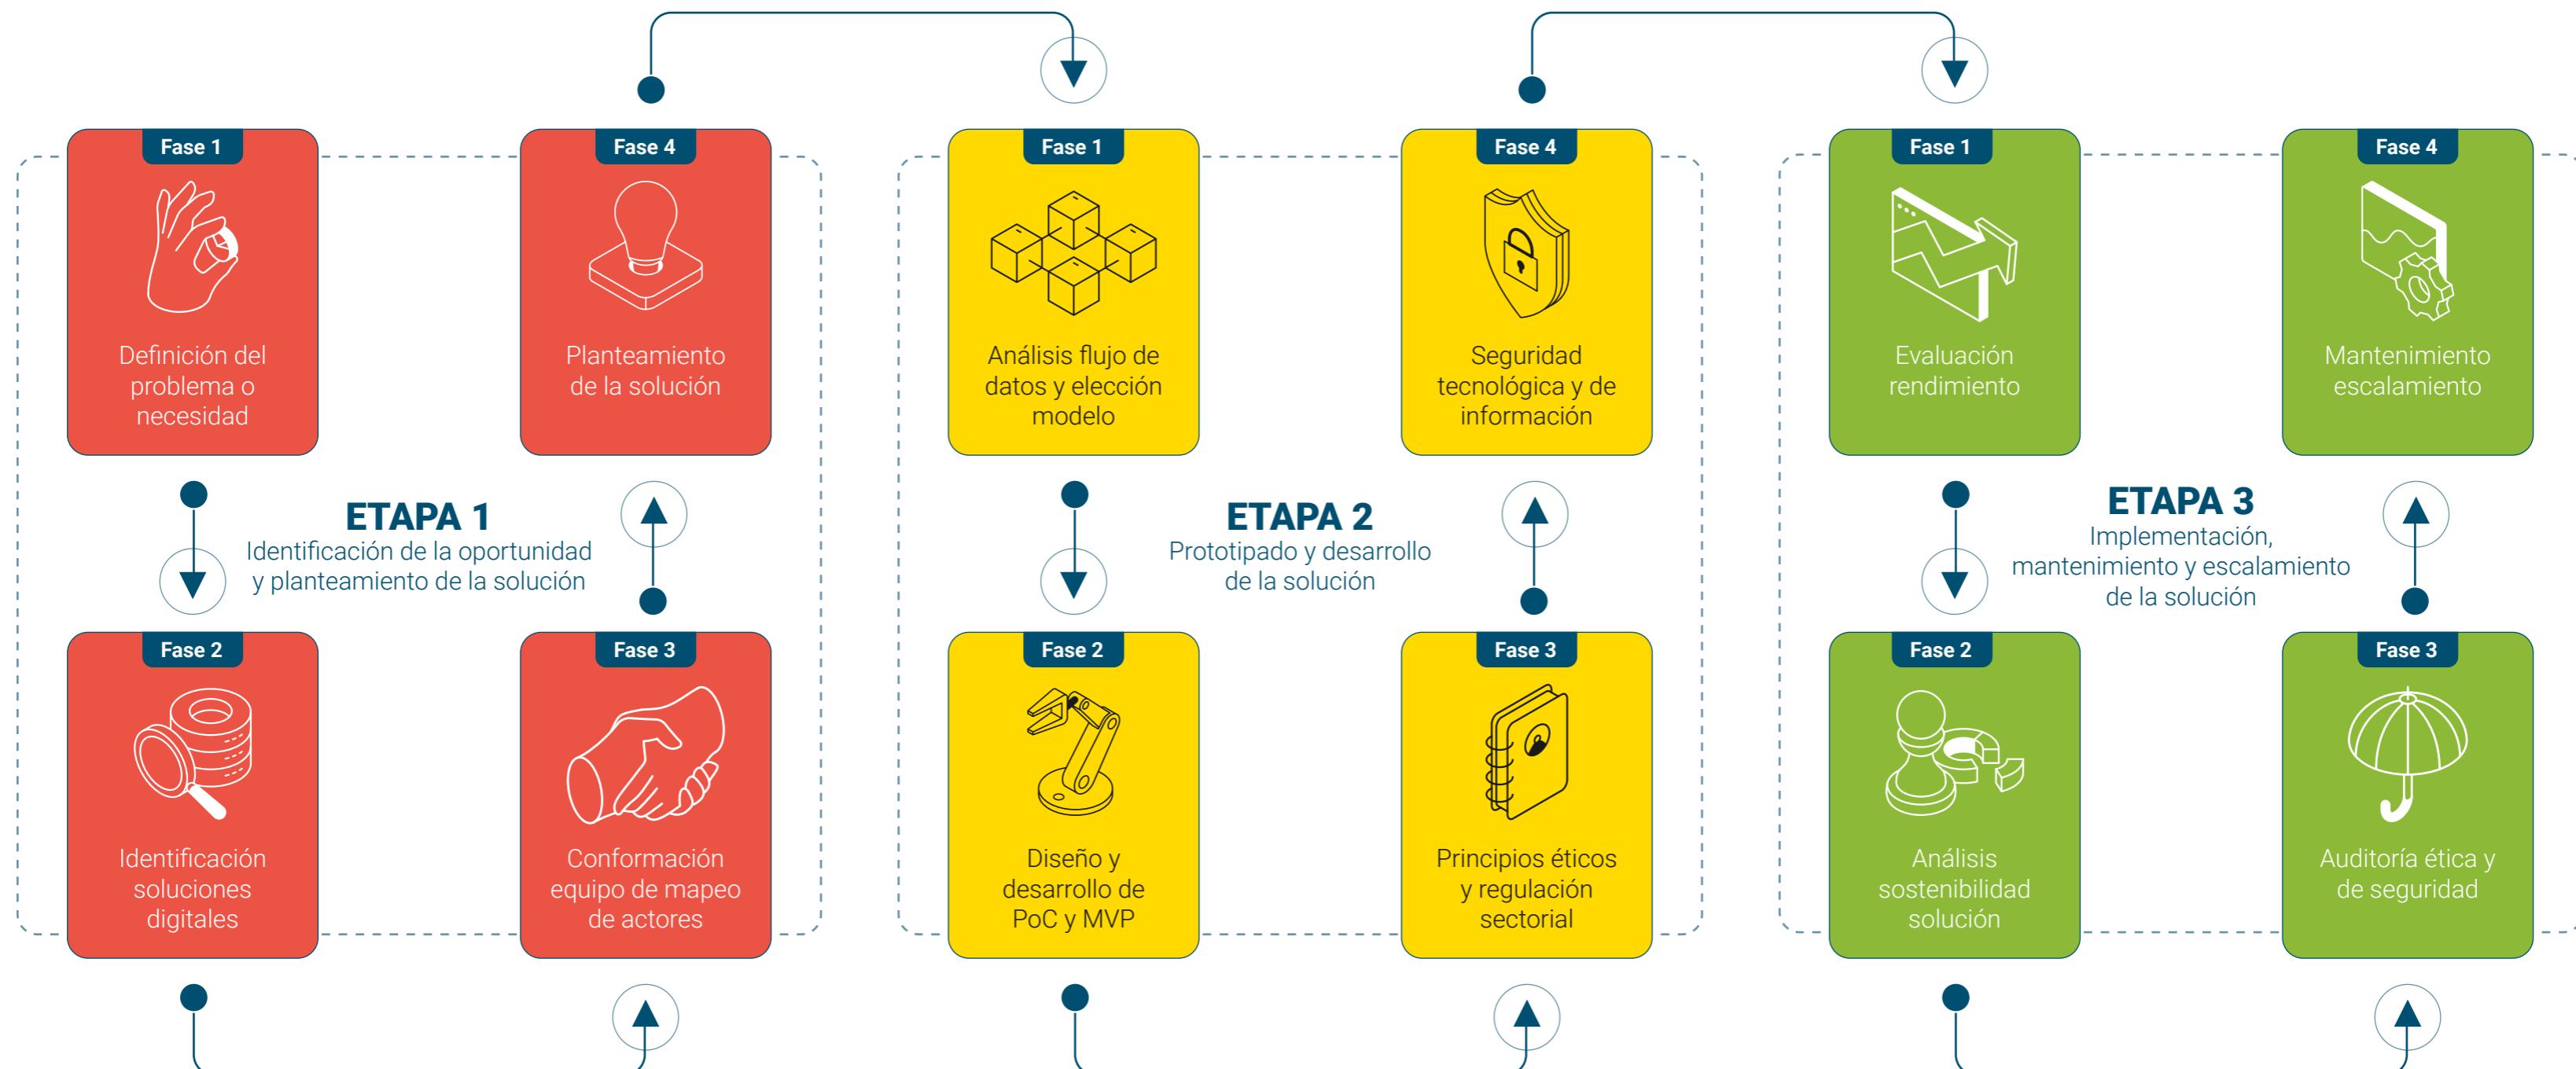
La experiencia del BID en la promoción y desarrollo de soluciones basadas en IA en sectores de infraestructura ha permitido concluir que el enfoque de desarrollo e innovación

ágil¹⁰², el cual es utilizado comúnmente en los procesos de emprendimiento e innovación tecnológica, resulta también pertinente para el desarrollo y adopción de este tipo de soluciones en estos sectores. Como su nombre lo indica, este enfoque se centra en la flexibilidad de los procesos, la capacidad de adaptación, la experimentación y la retroalimentación continua del usuario o cliente. Adicionalmente, considera iteraciones continuas a lo largo de la cadena de producción del sistema, lo que permite realizar modificaciones oportunas en la estructuración del modelo. Para ello, suele incluir el desarrollo de prototipos y pilotos que permiten experimentar sobre versiones funcionales del producto. Esta característica incorpora flexibilidad en el proceso, pues en cualquier etapa de desarrollo se puede reformular una solución diferente como consecuencia de la experimentación de los usuarios reales (Minatta *et al.*, 2022).

102 El término ágil hace referencia a un conjunto de marcos y principios que codifican un método de desarrollo de software. Este concepto describe proyectos que priorizan la simplicidad, la colaboración e interacción del equipo y el cliente con entregas frecuentes, y la creación de equipos auto-organizados, con capacidad de adaptabilidad que reflexionan y priorizan la satisfacción del cliente. Esta metodología se caracteriza por ser iterativa y difiere de la tradicional en múltiples aspectos. El término ágil es utilizado actualmente para referirse a diversas prácticas de desarrollo e innovación, e incluso es utilizado en otras áreas del conocimiento diferentes al desarrollo de software. Fuentes: (i) Agile Alliance. ¿Qué es Agile?. Disponible en: <https://www.agilealliance.org/agile101/>. (ii) Dyba T, Dingsoyr. (2009). What do we know about agile software development? IEEE Software.

El enfoque ágil permite a las organizaciones que gestionan infraestructuras críticas iterar sobre sus modelos y sistemas, incorporar continuamente comentarios y nuevas ideas, y realizar ajustes en tiempo real. Esto es crucial para garantizar la continuidad operativa, mejorar la seguridad, y asegurar que las infraestructuras puedan adaptarse rápidamente a nuevas demandas o riesgos emergentes. Además, al utilizar prototipos y pilotos en el proceso de desarrollo, las organizaciones identifican y mitigan posibles fallos antes de que impacten en el sistema global.

Teniendo en cuenta lo anterior, el enfoque de *Desarrollo e Innovación Ágil* generalmente se compone de tres (3) etapas principales, las cuales son: i) Identificación de la oportunidad y planteamiento de la solución; ii) Prototipado y desarrollo de la solución; e iii) Implementación, mantenimiento y escalamiento de la solución (**Figura 10**).

Figura 10. Esquema del Enfoque de Desarrollo e Innovación Ágil

Fuente: Elaboración propia

Como se observa en la **Figura 10** el esquema es iterativo entre etapa y etapa y, en cada una, se mantiene un ciclo constante de mejoras. Esto tiene la intención de representar la flexibilidad y adaptación del modelo ya que los cambios pueden introducirse en cualquier parte del ciclo sin afectar considerablemente su desarrollo.

A continuación, se presenta un conjunto de consideraciones clave el BID recomienda ser tenidas en cuenta por parte de los formuladores e implementadores de soluciones de IA en los sectores de infraestructura, a lo largo del proceso de desarrollo e implementación de estas soluciones. Estas consideraciones han sido identificadas a partir de la revisión de casos y prácticas internacionales, así como de la experiencia y lecciones aprendidas por el BID, en su apoyo a los países de la región, en la adopción de estas tecnologías. Estas consideraciones son fundamentales para asegurar que la integración de IA se realice de manera eficaz, alineada con los objetivos estratégicos, y que se maximicen los beneficios para la infraestructura crítica.

Etapa 1. Identificación de la oportunidad y planteamiento de la solución

La primera etapa del esquema de *Desarrollo e Innovación Ágil* es la **Identificación de la oportunidad y planteamiento de la solución** y tiene como objetivo definir y acotar el problema, así como establecer los elementos de decisión para implementar una solución de IA. Generalmente incluye cuatro (4) fases principales.

Etapa 1, Fase 1

Definición del problema o necesidad:

La organización formula un problema específico que se requiere solucionar, o también identifica una necesidad como por ejemplo el fortalecimiento de la toma de decisiones, o la innovación en productos, servicios o procesos.

Una buena definición del problema generalmente cumple con las siguientes características: ser clara, concisa y hacer referencia a una situación solucionable. Para esto, es fundamental identificar: ¿cuáles son sus causas y consecuencias?, ¿por qué es importante resolverlo?, ¿qué sucede en ausencia de intervención?, ¿qué grupos de interés se afectan?, ¿cuáles son los indicadores que soportan la existencia del problema?, ¿por qué el problema aún no se ha solucionado?

Para la definición del problema es fundamental recopilar la mayor cantidad posible de información y evidencia disponible, de tal manera que la formulación se realice sustentada en datos y hechos concretos, mas no en suposiciones¹⁰³.

Etapa 1, Fase 2

Identificación de posibles soluciones digitales:

Hace referencia a la definición de las alternativas de solución que serían más apropiadas para resolver el problema identificado y a la determinación de la pertinencia de utilizar IA en la solución. Esto representa un filtro para prevenir el riesgo de desarrollar proyectos de IA a partir de la tecnología en sí misma mas no del problema a resolver (Pombo et al., 2020).

Para analizar la conveniencia y necesidad de implementar una solución basada en IA, es importante primero entender la problemática antes de pensar en cómo resolverla. En muchas ocasiones, los grupos de trabajo inician con la relación causal contraria. Es decir, eligen

103 Departamento de Infraestructura (INE). *Guía de desarrollo de productos digitales*. [Diapositivas de PowerPoint]. Banco Interamericano de Desarrollo (BID).

la solución de IA que quieren implementar y después deciden en dónde aplicarlo. En la experiencia del BID, específicamente en sectores de infraestructura, los proyectos exitosos son aquellos que iniciaron identificando un problema, lo acotaron para no perder el foco y posteriormente decidieron las herramientas que se requerían para solucionarlo¹⁰⁴. Así entonces, en esta fase conviene formular las siguientes preguntas: ¿por qué es necesaria una solución digital para resolver el problema?, ¿qué aspectos diferenciales ofrece un producto digital en comparación con una solución que no lo sea?

Análisis de los métodos de solución existentes

Resulta prioritario entender los posibles métodos de solución y su viabilidad, así como encontrar el sustento teórico y empírico de las primeras aproximaciones a una posible solución. En este sentido, conviene proceder con un estudio de mercado de los métodos de solución y de las soluciones actuales existentes. Esto implica adelantar un análisis de las tendencias

tecnológicas y casos de uso disponibles. Así mismo, dentro del análisis de los posibles métodos de solución usualmente se considera la complejidad del desarrollo (viabilidad técnica), los costos asociados a cada opción, y los tipos de habilidades y capacidades requeridas para su implementación.

Puede suceder que en el mismo sector o en otros se hayan adoptado métodos de solución basados en IA similares a los que se están contemplando implementar en el caso concreto. En este caso, dichos métodos, así como los aprendizajes derivados de su desarrollo e implementación, podrán ser útiles para el diseño de la nueva solución. Como parte de esto, los códigos base compartidos permiten ahorrar tiempo e incorporar las buenas prácticas que se hayan tenido en anteriores proyectos. Un ejemplo son las aplicaciones desarrolladas por el BID en sectores de infraestructura¹⁰⁵, las cuales cuentan con repositorios públicos para que puedan ser aprovechadas por los formuladores e implementadores de soluciones, como *BA Obras*, *Caminos de la Villa*, *VíaSegura*, *Ciclo de Movilidad*, *Distancia2*, *Energizados*, *Pavimenta2* y *Congestíometro*, solo por mencionar algunos.

Aprovechar soluciones desarrolladas previamente por startups o aliados tecnológicos puede ser una estrategia útil y eficiente para abordar problemas similares. Vincular la experiencia de estas empresas mediante procesos de innovación abierta, alianzas o intercambios de conocimiento permite explorar nuevas ideas y posibles soluciones¹⁰⁶. Para maximizar el impacto de estas colaboraciones, es crucial definir criterios de decisión objetivos que permitan seleccionar las soluciones existentes con mayor potencial y alineación con los objetivos de la organización.

Además, esta estrategia abre oportunidades para desarrollar soluciones locales que se adapten a las necesidades particulares de la región y cumplan con los estándares internacionales. Esto no solo promueve la transparencia, la equidad y la responsabilidad en la implementación de la IA, sino también fortalece los ecosistemas regionales. Iniciativas como fAlr LAC+, impulsadas por el Grupo BID, desarrollan marcos, herramientas y mejores prácticas. fAlr LAC+ ofrece asesoría, capacitación y herramientas para apoyar a los países y emprendedores en la adopción de la IA de manera

104 Ibidem.

105 Para más información consultar: <<https://code.iadb.org/es/herramientas>>

106 Departamento de Infraestructura (INE). *Guía de desarrollo de productos digitales*. [Diapositivas de PowerPoint]. Banco Interamericano de Desarrollo (BID).

ética y efectiva. Herramientas como fAIr LAC 3S y fAIr Venture favorecen la construcción de un portafolio de soluciones regionales y de ecosistemas sólidos.

Etapa 1, Fase 3

Conformación del equipo y mapeo de actores:

En esta primera etapa conviene definir una gerencia del proyecto y un equipo interdisciplinario con la capacidad de incorporar en el proceso los conocimientos técnicos, tecnológicos, legales y de negocio para el desarrollo e implementación exitosa de la solución. Igualmente, resulta conveniente identificar los actores interesados y de los posibles aliados estratégicos.

La identificación de los actores es relevante por cuanto contribuye a dimensionar y acotar la problemática y posible solución. Así mismo, permite conocer oportunamente sus motivaciones e intereses, así como la influencia que pueden tener en el producto a diseñar e implementar. En especial, resulta importante identificar los actores que se beneficiarán con la solución de IA, así como aquellos que deberán cambiar su operación o comportamiento una vez esta se adopte¹⁰⁷.

De igual manera, conviene identificar posibles aliados estratégicos y patrocinadores del proyecto, con el fin de evaluar la viabilidad de las respectivas alianzas o de posibles apoyos que contribuyan a su exitosa implementación.

Por ejemplo, en proyectos de transporte, como la implementación de un sistema de gestión del tráfico basado en IA, el equipo interdisciplinario necesita incluir expertos en urbanismo, tecnología de transporte, y regulaciones de movilidad, además de operadores y usuarios finales, para asegurar que la solución se integre adecuadamente con la infraestructura existente y responda a las necesidades específicas del entorno urbano.

Por otro lado, en un proyecto de energía, como la optimización de redes eléctricas mediante IA, es esencial involucrar a especialistas en sistemas eléctricos, ciberseguridad, reguladores del sector energético, y expertos en sostenibilidad. La interacción con diferentes actores es crítica, ya que los proyectos energéticos suelen enfrentar desafíos únicos relacionados con la estabilidad de la red, el cumplimiento normativo, y la aceptación pública de nuevas tecnologías.

Etapa 1, Fase 4

Planteamiento de la solución:

Es importante también analizar posibles alternativas y considerar los criterios para escoger la solución más adecuada. Los elementos para valorar comprenden el análisis de las soluciones existentes, la revisión de los datos disponibles y de los posibles modelos a desarrollar, el análisis de los requerimientos en cuanto a herramientas tecnológicas, la identificación de las habilidades y capacidades, así como la formulación de consideraciones éticas, de seguridad de la información y de regulación sectorial.

El análisis de alternativas y la evaluación de criterios son esenciales en los sectores de infraestructura debido a la complejidad y el impacto a largo plazo de los proyectos. En este contexto, seleccionar la solución más adecuada implica considerar múltiples factores, como la eficiencia operativa, la sostenibilidad y la resiliencia.

La evaluación de herramientas tecnológicas es crucial para asegurar la adaptabilidad de la infraestructura a futuras innovaciones. Las consideraciones éticas y de seguridad,

¹⁰⁷ Ibidem.

junto con la conformidad con regulaciones sectoriales, son indispensables para minimizar riesgos y asegurar el éxito de los proyectos a largo plazo.

Tipo de datos y posibles modelos a desarrollar

En esta fase resulta crucial identificar y analizar las características de los datos a utilizar como, por ejemplo, su origen y disposición, es decir, si son estructurados¹⁰⁸, semiestructurados¹⁰⁹ o no estructurados¹¹⁰, si se trata de datos abiertos, personales o reservados. Así mismo, considerar el volumen de los datos¹¹¹, la representatividad, la calidad¹¹², la variabilidad de sus categorías, la relación entre las variables,

la dimensionalidad, el equilibrio en las categorías¹¹³, la fuente y periodicidad de actualización y la forma de extraerlos o capturarlos. Así mismo, es importante evaluar el nivel de sensibilidad de la información disponible; por ejemplo, como se menciona en la fase de consideraciones éticas, privacidad de la información y seguridad informática, conviene determinar si los datos de entrada son de carácter privado o tienen implicaciones éticas, pues en estos casos es posible que en las etapas de desarrollo sea necesario aplicar transformaciones para proteger la privacidad o mitigar posibles sesgos o riesgos éticos. De esta manera, en esta etapa se categoriza el tipo de información para evaluar los riesgos y de esa manera determinar el tratamiento adecuado de los datos para el procesamiento en términos de seguridad y volumen de información.

La identificación y análisis de las características de los datos a utilizar es un paso previo fundamental para la implementación de la etapa de prototipado y desarrollo de la solución, la cual se describe en la sección 4.1.2. Como se menciona en la descripción de esta etapa, un elemento central para la elección del modelo a desarrollar es el análisis e implementación del

108 Este tipo de datos cuentan con aspectos definidos como atributos, longitud, tamaño y su almacenamiento se presenta en bases de datos relacionales, en hoja de cálculo, o en formato tabla (Vélez et al., 2022).

109 Estos son datos con etiquetas que no tienen una estructura formal, como los presentados en una base de datos (Vélez et al., 2022).

110 Datos que no cuentan con una estructura formal y cuyo almacenamiento es posible en documentos de texto o pdf, videos, imágenes, chats de redes sociales y correos electrónicos, entre otros (Vélez et al., 2022).

111 La cantidad necesaria de datos varía según el tipo de modelo a implementar, la complejidad del problema y el número de parámetros requeridos (Vélez et al., 2022)..

112 Si están incompletos, desorganizados, sin metadatos y con serios indicios de errores (Vélez et al., 2022)..

flujo de datos del proyecto, el cual consiste en una serie de pasos articulados mediante los cuales se extraen, procesan y transforman los datos desde su forma bruta hasta un estado óptimo para entrenar y evaluar un modelo.

Identificación y entendimiento de la solución

Con base en el análisis de métodos de solución existentes y la identificación de los datos a utilizar y posibles modelos a desarrollar, se identifica el tipo de solución más adecuada, así como sus diferentes componentes. Para definir la solución idónea de acuerdo con el problema o necesidad determinado, se evalúan los diferentes métodos de solución identificados con base en criterios como la eficacia para solucionar el problema, la viabilidad técnica y financiera, la eficiencia operativa, las implicaciones en cuanto adquisiciones, necesidad de alianzas o desarrollos *in-house*, el horizonte de tiempo requerido, y los impactos en sostenibilidad y resiliencia, entre otros.

Adicionalmente, una vez identificada la solución, conviene desarrollar un entendimiento a profundidad de esta en aspectos como: su relación con la estrategia del negocio, su relación con la operación de la organización, la regulación relevante que se deba tener en cuenta, las ventajas de ésta en comparación con otro tipo de soluciones, los aspectos de contexto -político,

113 Especialmente en los problemas de clasificación, es importante que las diferentes clases o categorías dentro de una variable estén equilibradas de manera que no se reproduzcan sesgos en el entrenamiento (Vélez et al., 2022)..

social, de infraestructura- que resulten relevantes, y sus objetivos y resultados esperados, entre otros aspectos.

Herramientas tecnológicas

En esta fase conviene también considerar los requerimientos que se tendrán en términos de herramientas tecnológicas para el desarrollo e implementación de la solución identificada.

La infraestructura de datos para el desarrollo de soluciones de IA se divide en dos funcionalidades: almacenamiento y procesamiento. En estos dos conceptos interactúan (i) la infraestructura de los datos, (ii) el entorno de desarrollo del modelo de IA y (iii) la infraestructura tecnológica de soporte.

La infraestructura de datos se relaciona con la forma en que está organizada la información, es decir si se encuentra estructurada en tablas relacionales¹¹⁴ o no relacionales¹¹⁵. Así

114 Las bases de datos de tipo relacional son aquellas que almacenan la información en tablas, conocidas como relaciones, donde cada una es una colección de datos organizados en filas (registro) y columnas (atributos) ¿Qué es una base de datos relacional (sistema de gestión de bases de datos relacionales)? Recuperado de <<https://www.oracle.com/co/database/what-is-a-relational-database/>>

115 Este sistema de bases de datos no sigue un esquema rígido, en lugar de filas y

mismo, esta infraestructura también se compone del modelo de ingeniería de datos que se adopte, ya sea ETL (Extraer, Transformar y Cargar)¹¹⁶ o ELT (Extraer, Cargar y Trasformar)¹¹⁷ y de la infraestructura de almacenamiento de los datos, que puede consistir en un data warehouse¹¹⁸, un data lake¹¹⁹, o una combinación de los dos anteriores, data lakehouse¹²⁰.

columnas, utiliza diferentes modelos de almacenamiento y recuperación de datos lo que le permite mejorar en términos de escalabilidad con respecto a las bases de tipo relacional. ¿Qué es NoSQL? Recuperado de <<https://aws.amazon.com/es/nosql/>>

116 Consiste en combinar datos que provienen de diferentes fuentes y aplicarles reglas de negocio, validación y estadísticas para limpiarlos y ordenarlos con el fin de almacenarlos en un repositorio centralizado. AWS. ¿Qué es extracción, transformación y carga (ETL)? Recuperado de <<https://aws.amazon.com/es/what-is/etl/>>

117 Según AWS “el enfoque de ELT carga los datos tal como están y los transforma en una etapa posterior, según el caso de uso y los requisitos de análisis”. Recuperado de <<https://aws.amazon.com/es/compare/the-difference-between-etl-and-elt/>>

118 Según AWS, un data warehouse “es un repositorio central de información que se puede analizar para tomar decisiones mejor informadas”. Recuperado de <<https://aws.amazon.com/es/what-is/data-warehouse/>>

119 Hace referencia a un repositorio centralizado dedicado al almacenamiento de información estructurada, semiestructurada y no estructurada en cualquier magnitud, sin necesidad de transformarlos previamente en un esquema predefinido. What is a Data Lake? Recuperado de <<https://aws.amazon.com/what-is/data-lake/>>

120 Es una conjugación del data warehouse y el data lake en el sentido que combina la capacidad de almacenamiento de información sin procesar con los beneficios de control y gestión de datos estructurados que ofrece el modelo de data warehouse. Fuente: Google. What is a data lakehouse? Recuperado de <<https://cloud.google.com/discover/what-is-a-data-lakehouse#:~:text=data%20management%20features.,What%20is%20a%20lakehouse%3Forganized%20sets%20of%20structured%20data.>>

En relación con el entorno de desarrollo del modelo de IA generalmente se deben tomar decisiones sobre la capacidad de procesamiento y la velocidad con la que se entrenarán los modelos. Para esto, en proyectos en infraestructura en los que se utilizan imágenes, por lo general se contempla contar con Unidades de Procesamiento Gráfico (GPU)¹²¹ con el fin de soportar las sesiones de entrenamiento del o los modelos de IA que se estén desarrollando. El desarrollo de las GPU ha permitido avances significativos en los modelos de machine learning, principalmente en la velocidad de procesamiento comparado con lo que alcanzan las CPU tradicionales, la eficiencia energética pues ofrece un mejor rendimiento por vatio en comparación con las CPUs y la posibilidad de implementar procesamiento paralelo pues su arquitectura está diseñada para llevar a cabo múltiples tareas simultáneamente¹²².

121 GPU (Graphics Processing Unit) es un procesador especializado en gráficos y renderizado de imágenes. No obstante, al tener alta capacidad de procesamiento se ha utilizado para realizar cálculos matemáticos intensivos y procesamientos paralelos facilitando el trabajo de cómputo del entrenamiento de modelos complejos de machine learning. What is a GPU? Recuperado de <<https://www.intel.com/content/www/us/en/products/docs/processors/what-is-a-gpu.html#:~:text=What%20does%20GPU%20stand%20for,video%20editing%2C%20and%20gaming%20applications.>>

122 NVIDIA. Why GPUs are great for AI. (2023, diciembre). Recuperado de <<https://blogs.nvidia.com/blog/why-gpus-are-great-for-ai/>> & What is a GPU? Recuperado de <<https://www.intel.com/content/www/us/en/products/docs/processors/what-is-a-gpu.html#:~:text=What%20does%20GPU%20stand%20for,video%20editing%2C%20and%20gaming%20applications.>>

Adicionalmente, resulta crucial considerar la infraestructura tecnológica de soporte, que consiste en un lugar físico o virtual donde se desarrollará el almacenamiento y procesamiento de los datos. Es fundamental definir si este espacio se construye en la nube, sea esta privada, pública o híbrida, o si por el contrario se alojará en infraestructura local (servidores). Esta elección impactará el tiempo de desarrollo, los costos, la seguridad y las competencias del equipo requeridas.

Al respecto, existen entonces dos opciones principales: el uso de servicios de computación en la nube o la utilización de una solución basada en infraestructura local, también denominada solución “on-premise”. La computación en la nube corresponde a la distribución de recursos de TI escalables y virtualizados por demanda a través de Internet mediante un esquema de pago por uso. Estos servicios, generalmente soportados en servidores distribuidos a lo largo del mundo, se basan en la compartición de recursos físicos subyacentes, que permiten ofrecer capacidad de almacenamiento, potencia de procesamiento, administración y acceso de información, ejecución de aplicaciones o entrega contenidos o servicios, de manera rápida y flexible¹²³.

123 ¿Qué es la nube? Recuperado de <https://azure.microsoft.com/es-es/resources/>

Por su parte, así como existen diferentes modalidades de desarrollo de la computación en la nube, también existen diferentes modelos de negocio para contratar su servicio. Las opciones más comunes son: Infraestructura como Servicio (IaaS, por sus siglas en inglés); Plataforma como Servicio (PaaS, por sus siglas en inglés); y Software como Servicio (SaaS)¹²⁴. El modelo IaaS consiste en el servicio de infraestructura, es decir, la operación de máquinas virtuales, capacidad de almacenamiento, procesamiento y redes, de manera que los clientes las puedan configurar de acuerdo con sus necesidades. El modelo PaaS se enfoca en ofrecer acceso al entorno necesario para el desarrollo, gestión y lanzamiento de aplicaciones con base en el uso de la respectiva infraestructura de soporte. Por último, el modelo SaaS consiste en el servicio de uso de soluciones finales de acuerdo con las necesidades de los clientes sin que estos tengan que gestionar el back office y el mantenimiento, ni la infraestructura tecnológica que la soporta (World Bank, 2022; García & Iglesias, 2022).

[cloud-computing-dictionary.what-is-the-cloud](https://cloud-computing-dictionary.what-is-the-cloud.com/what-is-the-cloud) & ¿Qué es la computación en la nube? Recuperado de <<https://aws.amazon.com/es/what-is-cloud-computing/>>

124 IBM. What are IaaS, PaaS and SaaS? Recuperado de <<https://www.ibm.com/topics/iaas-paas-saas#:~:text=IaaS%20PaaS%20and%20SaaS%20are,types%20of%20cloud%20service%20offerings.>>

Para los proyectos relacionados con energía, transporte, agua, saneamiento y residuos sólidos existen algunas ventajas de desarrollar las soluciones de IA en la nube¹²⁵:

- **Accesibilidad:** Almacenamiento y acceso a la información desde cualquier terminal y lugar geográfico.
- **Escalabilidad y flexibilidad.** La nube soporta el aumento de tráfico y usuarios con relativa facilidad, así mismo, se ajusta a reducciones, por lo que es una infraestructura que se adapta a la medida de la aplicación.
- **Agilidad para el desarrollo del producto.** Esto permite realizar experimentos en torno al tráfico -aumentar y disminuir el uso de la aplicación- y a las funcionalidades de la solución.
- **Reducción de costos.** Una buena administración y planeación de los recursos de almacenamiento, procesamiento y ejecución de aplicaciones en la nube permite una reducción significativa de costos en comparación con una solución basada en servidores

125 Ibidem.

locales. Esto en la medida que solo se paga por lo que verdaderamente se está usando, evitando costos asociados a infraestructura ociosa. Otro aspecto para considerar consiste en la sostenibilidad ambiental de la solución a implementar. De acuerdo con cálculos de Microsoft Cloud, la computación en la nube puede tener un consumo más eficiente de energía -entre 22 y 93% en comparación con la solución on-premise¹²⁶. Así, a inicios del año 2024, Google Cloud reportó que el 100% de su demanda de electricidad anual es solventada con fuentes renovables, mientras que Microsoft Azure ha reportado ser carbono neutral desde 2012¹²⁷.

● Capacidad de almacenamiento de datos: La nube ofrece una capacidad de almacenamiento prácticamente ilimitada y adaptable a las necesidades de la aplicación. A diferencia de la infraestructura local, donde el espacio puede ser limitado y costoso de expandir, la nube permite escalar el almacenamiento de manera sencilla

y según demanda, lo que facilita la gestión de grandes volúmenes de datos sin preocuparse por la infraestructura subyacente. Esto es especialmente relevante para la efectividad y precisión de las soluciones de IA, ya que en estos casos el desarrollo y entrenamiento de los modelos hace necesario manejar volúmenes masivos de datos.

Por su parte, el modelo *on-premise* hace referencia a que la infraestructura y los recursos donde se despliegan las aplicaciones son propiedad de la entidad y están ubicados en sus instalaciones¹²⁸. Esto permite pleno control del hardware, es decir, la organización es responsable del servidor, del ensamblaje, del almacenamiento, del enfriamiento de los equipos, de la UPS¹²⁹, de la administración del acceso y resguardo de la información, entre otros¹³⁰. Esta alternativa generalmente se utiliza para procesar datos sensibles que

tienen especial protección, pues en algunos casos la regulación prohíbe alojar estos datos fuera del país¹³¹. Sin embargo, es importante tener en cuenta que, aunque se tiene control directo de la infraestructura, el modelo *on-premise* demanda una estructura de operación y mantenimiento constante y tiene un limitante en cuanto a capacidad, ya que el crecimiento requiere comprar más servidores y eso implica más espacio, consumo de energía y necesidad de enfriamiento.

Otra decisión relevante en materia de tecnología es si la solución de IA se desarrolla al interior de la organización o si se contrata con un tercero. Al respecto, la primera opción (desarrollo *in-house*), tiene un mayor control y adaptación según las necesidades particulares del proyecto y generalmente implica menores costos; sin embargo, requiere que la organización cuente con el conocimiento y habilidades necesarias. Por su parte, el desarrollo externo puede evitar a la organización el problema de incorporar o desarrollar conocimiento y habilidades con las que la organización no cuenta. Sin embargo, el costo del desarrollo externo suele ser mayor y en todo caso se requerirá un equipo interno con responsabilidades relevantes como la gerencia del proyecto,

126 Sustainability with on-prem and cloud simulation. (2022, octubre). Recuperado de <<https://softwaresim.com/blog/sustainability-with-on-prem-and-cloud-simulation/>>

127 Hive. Who has the greenest cloud? The most sustainable cloud tech in 2024. (2024, febrero). Recuperado de <<https://www.hivenet.com/post/who-has-the-greenest-cloud-the-most-sustainable-cloud-tech-in-2024>>

128 TIC Portal. (en local). (diciembre, 2023). Recuperado de <<https://www.ticportal.es/glosario-tic/on-premise>>

129 UPS (Uninterruptible Power Supply) o Sistema de Alimentación Interrumpida es un dispositivo que proporciona energía de respaldo a equipos eléctricos cuando la fuente de alimentación principal falla. USAID. Uninterruptible Power Supplies. Recuperado de <<https://www.usaid.gov/energy/powering-health/system-components/uninterruptible-power-supplies>>

130 TIC Portal. (en local). (diciembre, 2023). Recuperado de <<https://www.ticportal.es/glosario-tic/on-premise>>

131 Ibidem.

la adquisición de la información, el diseño de una estrategia adecuada de integración de los sistemas, y la posterior actualización del modelo.

Finalmente, en definición de las herramientas tecnológicas para desarrollar la solución basada en IA existen consideraciones adicionales relevantes sobre el nivel de preparación de la organización para el uso y aprovechamiento de estas herramientas. Estas consideraciones incluyen: (i) el nivel de madurez de los negocios y procesos para la adopción o uso de las tecnologías, (ii) los riesgos asociados a su adopción, incluidos los aspectos éticos y legales, (iii) las barreras existentes para la adopción, y (iv) las normativas o regulaciones relacionadas con dichas tecnologías que deban ser tenidas en cuenta para el desarrollo e implementación de la solución.

Identificación de habilidades y capacidades requeridas

Como se señaló en la descripción de la Fase 3 de esta Etapa, resulta conveniente que la organización integre un equipo interdisciplinario con las habilidades y capacidades para incorporar en el proceso los conocimientos técnicos, tecnológicos, de negocio y legales para el desarrollo e implementación exitosos de la solución. Una vez identificada la

solución a implementar, se podrán determinar las habilidades técnicas específicas requeridas para la construcción y aplicación de los modelos.

Aunque en ocasiones se externaliza la construcción de los modelos, su uso y mantenimiento recae en el personal interno, que, si no está preparado, puede subutilizar el potencial de la solución o incluso no utilizarla, lo que compromete la sostenibilidad del modelo. La experiencia del BID en el desarrollo de soluciones de IA en infraestructura resalta la importancia de incluir en el equipo profesionales con conocimientos en las áreas de ciencia de datos, *machine learning* y tecnologías de la información, así como incorporar profesionales con conocimiento del negocio. Esto permitirá revisar desde el diseño que el modelo responde a las necesidades de la organización, así como recibir retroalimentación sobre las funcionalidades y resultados del modelo en el contexto sectorial en donde se esté desarrollando.

Consideraciones éticas, privacidad de la información y seguridad informática

Resulta recomendable elaborar una matriz de riesgos asociados a la implementación de la futura solución que incorpore riesgos éticos,

reputacionales, normativos y ESG (ambiental, social y de gobernanza), así como su posible impacto y su plan de mitigación. De igual manera, como se mencionó, es relevante identificar si los datos de entrada del modelo son de carácter personal para aplicar algún tipo de transformación, como la anonimización, para proteger su privacidad.

Aunque no es el caso en la mayoría de los desarrollos de IA en sectores de infraestructura, es importante analizar si la información de entrenamiento del modelo incluye variables sensibles como, por ejemplo, la nacionalidad, el género o la etnia. En caso de existir este tipo de variables, puede no ser conveniente limitarse a eliminarlas en el modelo, ya que podrían existir otras variables correlacionadas con éstas en la base de datos que mantengan los sesgos existentes (Mehrabi *et al.*, 2022). En estos casos se acostumbra a utilizar metodologías de tratamiento especial de este tipo de variables¹³², con el fin de mitigar los posibles sesgos

132 Algunas de ellas son: (i) Técnicas de privacidad diferencial (*differential privacy*) como la anonimización de los datos (Ponomareva *et al.*, 2023); (ii) Ajustes en la función de perdida, remuestreo o ponderación de los datos; y (iii) *Adversarial debiasing*, el cual consiste en entrenar un modelo de tal manera que un adversario (otro modelo) no pueda predecir el atributo sensible a partir de las representaciones aprendidas.

identificados. Así mismo, puede resultar conveniente utilizar como referencia los indicadores relacionados con equidad algorítmica, descritos en la sección 4.1.3.

En términos de seguridad se recomienda evaluar posibles vulneraciones que podrían surgir durante las actividades de desarrollo. Como se trata de una etapa inicial, en la que el prototipado no ha comenzado, este ejercicio resulta conveniente para interiorizar las medidas de ciberseguridad que deberán implementarse.

Etapa 2. Prototipado y desarrollo de la solución

El **Prototipado y desarrollo de la solución** da paso a la experimentación a través de pruebas funcionales del producto que permiten el aprendizaje y la interacción con el mundo real y los usuarios. Esta etapa es un componente central del enfoque de *Desarrollo e innovación Ágil* en la medida en que a través de prueba y error se moldea y robustece la solución final.

Mahmoudian, Haniyeh. Using Adversarial Debiasing to Reduce Model Bias. (2020, abril). Recuperado de <<https://towardsdatascience.com/reducing-bias-from-models-built-on-the-adult-dataset-using-adversarial-debiasing-330f2ef3a3b4>>

Etapa 2, Fase 1

Análisis del flujo de datos y elección del modelo:

Análisis del flujo de datos

En esta Etapa, una vez planteada la solución, un elemento central para la elección del modelo a desarrollar es el análisis del flujo de datos del proyecto. Este flujo consiste en una serie de pasos articulados en los que se extraen, procesan y transforman los datos desde su forma bruta hasta un estado óptimo para entrenar y evaluar el modelo. La implementación de este flujo tiene como propósito preparar los datos para el entrenamiento y puesta en producción del modelo. En el proceso de gestión de datos interactúan diferentes tareas de identificación, recolección, limpieza, entrenamiento y evaluación de los datos, conocido como el flujo o pipeline de datos. En la

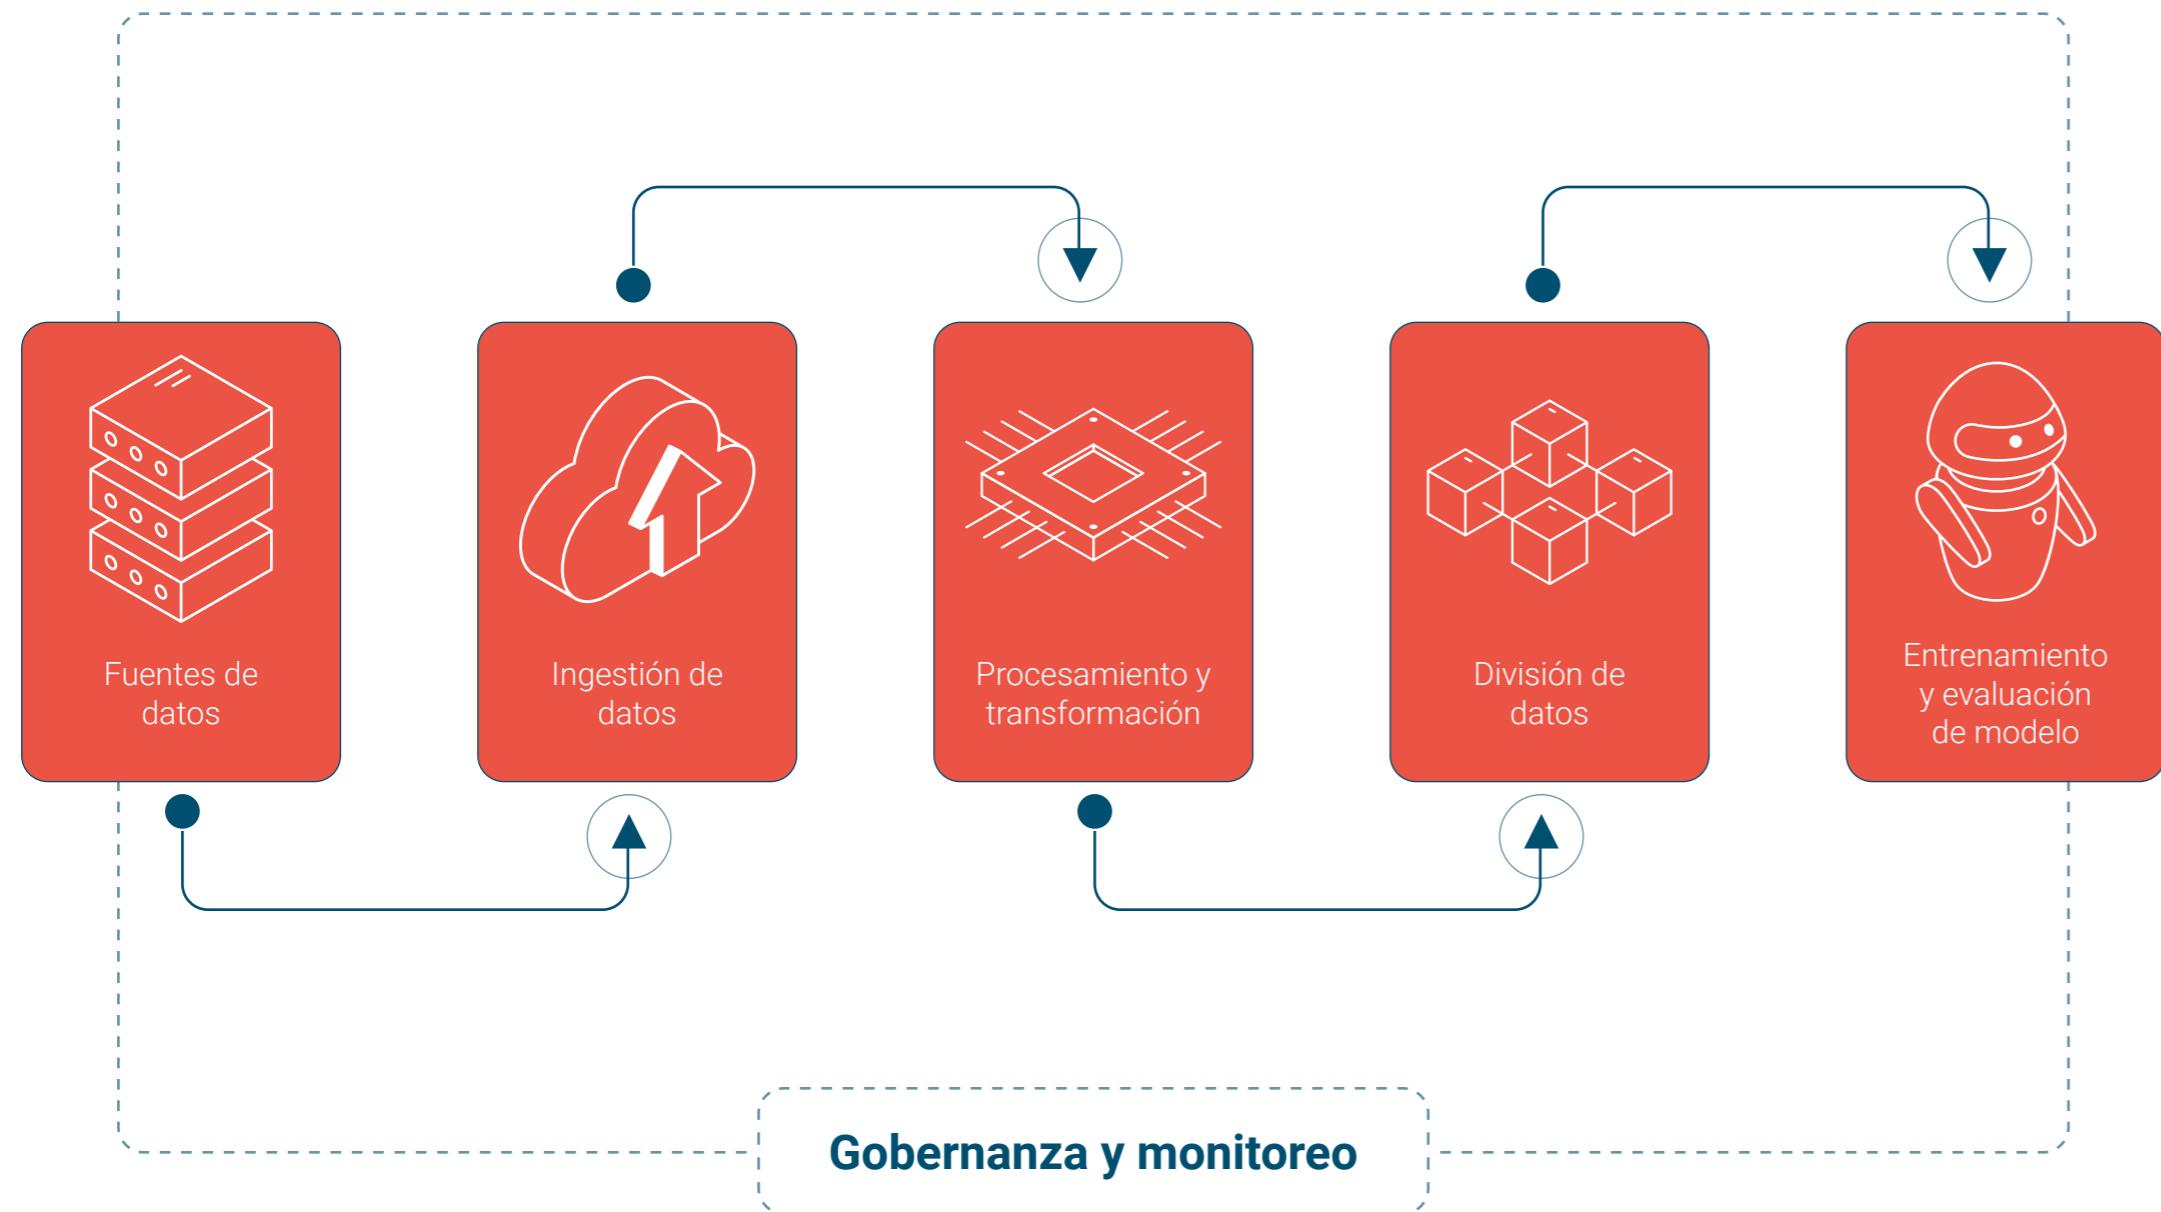
Figura 11 se presenta el pipeline con sus principales fases.

En proyectos de energía, agua, residuos sólidos y transporte, la **recolección de información** es crucial para alimentar modelos IA. Para ello, se emplean diversas tecnologías, como sensores IoT que monitorean en tiempo real el consumo energético, niveles de agua y flujos de tráfico, junto con sistemas de gestión de

infraestructuras que registran datos históricos sobre patrones climáticos, comportamientos de usuarios y mantenimiento. Además, se utilizan drones y satélites para capturar imágenes y datos geoespaciales.

El proceso que se conoce como **ingestión de datos** consiste en recopilar los datos para luego transferirlos a una única base de datos centralizada en donde se puedan acceder, almacenar y analizar¹³³. La recopilación de los datos se puede realizar mediante diferentes mecanismos: (i) datos generados mediante sistemas de información internos, (ii) datos adquiridos de fuentes externas, (iii) datos obtenidos de fuentes públicas de acceso abierto, y (iv) una combinación de las anteriores. Generalmente, en esta fase también se decide si la entidad adopta un modelo de tipo ETL o ELT. Así mismo, se determina la infraestructura de almacenamiento y gestión de los datos, como, por ejemplo, si se trata de un data warehouse, de un data lake o un data lakehouse.

133 Astera. ¿Qué es la ingestión de datos? Recuperado de <<https://www.astera.com/es/type/blog/data-ingestion/#:~:text=La%20ingesti%C3%B3n%20de%20datos%20es,lotes%20o%20en%20tiempo%20real.>> & Cognizat. Ingesta de datos. Recuperado de <<https://www.cognizant.com/es/es/glossary/data-ingestion>>

Figura 11. Pipeline de datos

Fuente: Adaptación propia con base en: *A Guide to Data Pipelines (and how to design one from scratch)*. Recuperado de <<https://www.striim.com/blog/guide-to-data-pipelines/>>

Durante **el procesamiento y transformación** de la información, por lo general se identifican anomalías, duplicados, datos atípicos o faltantes, problemas de escala (estandarización y normalización), y se realizan combinaciones de variables, suavización de datos, creación de variables dicotómicas, y análisis descriptivos, univariados, bivariados, multivariados, además de su representación a través de modelos de visualización¹³⁴. Se consideran las actividades relacionadas con la limpieza de la información, lo cual incluye la detección e imputación de faltantes, la estandarización de variables, la unificación de nombres de columnas, y el tratamiento de datos atípicos¹³⁵. Así mismo, se puede realizar la anonimización¹³⁶ o seudonimización¹³⁷.

134 Zhong, S. Mastering Exploratory Data Analysis (EDA): Everything you need to know. (abril, 2024). Recuperado de <<https://medium.com/data-and-beyond/mastering-exploratory-data-analysis-eda-everything-you-need-to-know-7e3b48d63a95>>

135 Patel, H. Feature Engineering Explained. Recuperado de <<https://builtin.com/articles/feature-engineering#:~:text=Apr%202019%202024,Feature%20engineering%20is%20the%20process%20of%20selecting%2C%20manipulating%20and%20transforming,used%20in%20a%20predictive%20model.>>

136 La anonimización de la información corresponde al procesamiento de datos personales para que estos no puedan atribuirse a individuos específicos. Fuente: Unión Europea. Agencia Española de Protección de Datos. (2020). *10 misunderstandings related to anonymisation*.

137 La seudonimización de la información corresponde al procesamiento de datos personales para que estos no puedan atribuirse a individuos específicos sin utilizar información adicional. Fuente: Unión Europea. (2016). Reglamento General de Protección de Datos (GDPR). Artículo 4.

de la información con el objetivo de cumplir con las reglas y normas de privacidad, en caso de que estas apliquen.

Como se señaló en el Capítulo 2, un problema constante en los modelos de clasificación es el desbalanceo de las clases. Esto ocurre cuando una clase tiene muchos más datos que otra, lo que puede llevar a que el modelo tenga buen rendimiento general, pero un desempeño deficiente al predecir la clase minoritaria, que es la que tiene menos datos. En estos casos, la evaluación del modelo solo está tomando en cuenta el rendimiento en la clase mayoritaria (Ávalos *et al.*, 2021). Algunas soluciones a este problema consisten en aplicar un submuestreo de la clase dominante -ajustando los casos hacia arriba para evitar errores de calibración-, la duplicación de la clase minoritaria o la modificación de los pesos ponderadores de cada clase para balancear la influencia de cada clase, entre otras soluciones (Ávalos *et al.*, 2021).

Elección del modelo

En esta Fase comúnmente se realiza el **entrenamiento y evaluación de los modelos** para elegir el que mejor se adapte a los objetivos del proyecto. Para esto, se comienza por un modelo básico y se aumenta su complejidad,

hasta identificar el modelo óptimo. En este proceso se consideran factores como, el tipo de problema, la disponibilidad de los datos, los requerimientos tecnológicos, las restricciones de tiempo y los limitantes presupuestales.

Una buena práctica consiste en empezar por el modelo más sencillo e incrementar su complejidad gradualmente. Sin embargo, una mayor complejidad del modelo disminuye la comprensión de los procesos de toma de decisiones por parte de los humanos, capacidad que se conoce como **explicabilidad**¹³⁸. No obstante, en diversas aplicaciones de IA, modelos complejos tales como redes neuronales suelen obtener significativamente mejores resultados¹³⁹, por lo que conviene al equipo de trabajo enfocarse en los objetivos de rendimiento y en el proceso de evaluación de la solución que se describe más adelante.

Otro elemento para considerar en la escogencia del modelo es la **naturaleza del problema**. Como se mencionó en

el Capítulo 2, los problemas que tratan los modelos de *machine learning* pueden ser aglutinados en tres grandes categorías, según Rebala *et al* (2019): i) clasificación, que busca identificar la o las categorías a la que pertenece cada elemento que se está analizando; ii) agrupamiento, que busca encontrar características similares entre los elementos para así congregarlos; y iii) predicción, que consiste en utilizar información histórica para pronosticar el comportamiento futuro de la variable objetivo. Así entonces, para la primera categoría se pueden utilizar algoritmos como máquinas de soporte vectorial (SVM), árboles de decisión, random forest, redes neuronales y redes neuronales convolucionales (CNN). En lo que respecta a la segunda categoría, se pueden usar algoritmos como, K-means, K-medoids, DBSCAN, Clustering jerárquico y Gaussian Mixture Models (GMM). Por su parte, para los problemas de predicción, suele utilizarse algoritmos de regresión logística, regresión polinómica, random forest, LSTM y Xgboost (Extreme Gradient Boosting), entre otros¹⁴⁰.

El **tipo, cantidad y calidad de la información** con la que se cuenta, es un factor igualmente relevante en la selección del

138 Hosni, Y. Brief Guide for Machine Learning Model Selection. (2021, diciembre). Recuperado de <<https://medium.com/@yousefhosni/brief-guide-for-machine-learning-model-selection-a19a82f8bdcd>>

139 Ibidem.

140 Rebala (2019), McMillan & Varga (2022), Betanzos (2020), Smola & Vishwanathan (2008), Nevala (2027), McKinsey Analytics (2018).

modelo a desarrollar. En ese sentido, es importante cuantificar el volumen de información disponible. Esto implica conocer la forma en que esta se almacena, el mecanismo de acceso y los procesos de obtención. De igual manera, se analiza si los datos se encuentran estructurados o no estructurados y si son de carácter cualitativo o cuantitativo¹⁴¹.

Un criterio adicional de elección del modelo consiste en la capacidad computacional requerida para entrenarlo. A este criterio se le conoce como **tiempo y capacidad computacional**. Esto hace referencia a la cantidad de recursos demandada, así como al tiempo que se necesitaría para entrar el modelo¹⁴². Por ejemplo, puede resultar más rápido y fácil entrenar un modelo de regresión logística, que un modelo de redes neuronales de cinco (5) capas. La complejidad del modelo es directamente proporcional a los recursos de procesamiento para su entrenamiento.

Por otra parte, los **indicadores de rendimiento y las métricas de equidad** son dos elementos importantes al momento de

escoger el mejor modelo posible. El primer tipo de indicadores informan qué tan bien el modelo está interpretando los datos que lo están alimentando y por ende la calidad de la respuesta al problema planteado que está produciendo¹⁴³. Por su parte, el segundo tipo de métricas evalúan la no existencia de sesgos a nivel de grupo y de individuo.

Para la **puesta en funcionamiento del modelo seleccionado** se define la información que se utilizará en el entrenamiento del modelo. Aunque no existe una regla específica con respecto a esta división, por lo general se utiliza el 80% de los datos para entrenarlo y el 20% para validarlos. En la medida de lo posible, resulta ideal que el modelo sea testeado con información externa con el fin de conocer su nivel de generalización.

El **tipo, cantidad y calidad de la información** con la que se cuenta, es un factor igualmente relevante en la selección del modelo a desarrollar. En ese sentido, es importante cuantificar el volumen de información disponible. Esto implica conocer la forma en que se almacena, el mecanismo de acceso y los procesos de obtención de esta. De igual manera, se analiza si

141 Hosni, Y. Brief Guide for Machine Learning Model Selection.(diciembre, 2021). Recuperado de <<https://medium.com/@yousefhosni/brief-guide-for-machine-learning-model-selection-a19a82f8bdcd>> Op.cit.

142 Hosni, Y. Brief Guide for Machine Learning Model Selection. Op.cit.

los datos se encuentran estructurados o no estructurados y si son de carácter cualitativo o cuantitativo¹⁴⁴. En otras palabras, llevar a cabo las fases 1,2 y 3 del *pipeline* de datos descrito en la Figura 11.

Etapa 2, Fase 2

Diseño y desarrollo de Prueba de Concepto y Producto Mínimo Viable

Una vez se realizan las validaciones iniciales y se resuelven las dudas sobre el funcionamiento de la posible solución, se acostumbra a proceder con la fase de elaboración de prototipos. Estos buscan representar cómo podría funcionar el producto y por lo general se testean con los usuarios aspectos de funcionalidad y usabilidad de tal manera que la retroalimentación permita realizar iteraciones que mejoren la robustez del producto¹⁴⁵. Como parte de esto, la Prueba de Concepto (PoC) es un ejercicio que valida la viabilidad técnica de la idea, de manera que se demuestre desde el punto de vista técnico que la propuesta es realizable o al menos tiene

144 Hosni, Y. Brief Guide for Machine Learning Model Selection. (diciembre, 2021). Recuperado de <<https://medium.com/@yousefhosni/brief-guide-for-machine-learning-model-selection-a19a82f8bdcd>> Op.cit.

145 Ibidem.

sustento teórico o empírico¹⁴⁶. Este ejercicio permite aprender de manera relativamente rápida qué aspectos de la solución deben ser revisados o modificados. Estas pruebas se llevan a cabo en un entorno controlado, con el apoyo de recursos técnicos o administrativos según sea necesario¹⁴⁷.

Algunos ejemplos de las PoC en proyectos de infraestructura crítica incluyen las que pueden ser implementadas para el desarrollo de iniciativas como el monitoreo en tiempo real de redes eléctricas inteligentes para gestionar el consumo de energía y detectar fallas tempranas, la optimización de la distribución de agua potable mediante sensores en la red para identificar fugas, y el mantenimiento predictivo de infraestructuras de transporte a través de drones que inspeccionan y previenen el desgaste. También pueden abarcar la seguridad cibernética en redes de control, utilizando plataformas de monitoreo para detectar amenazas, y la gestión inteligente de residuos en ciudades, mediante contenedores con sensores que optimizan las rutas de recolección. Estos pilotos prueban la viabilidad de tecnologías

innovadoras antes de su implementación a gran escala. Al respecto, el BID ha realizado algunas pruebas de concepto en infraestructura como aquellas relacionadas con el aforo de vehículos, el uso de tecnología en el borde, el uso de imágenes satelitales para definir la transitabilidad de una vía, el uso de imágenes satelitales para calcular la generación de potencia distribuida con paneles solares. Algunas de estas ideas han generado resultados satisfactorios, mientras que otras han encontrado dificultades para convertirlas en un Producto Mínimo Viable (MVP).

Una vez se evalúa la viabilidad técnica con base en las PoC, se procede con la fase de prototipado en donde en algunas ocasiones se ponen a prueba versiones funcionales específicas, como por ejemplo la plataforma del usuario, para testear la experiencia de usuario (UX) y/o diseño de servicios, con el objetivo de identificar oportunamente las funcionalidades clave que los usuarios y demás grupos de interés requerirán o preferirán¹⁴⁸. En este proceso, un aspecto fundamental es que tanto los integrantes del equipo que desarrollan el modelo, como los demás miembros del área

de negocios que participan en este desarrollo, tengan claro su rol en el proyecto. Por ejemplo, resulta conveniente que el propietario del producto (Product Owner - PO en inglés), participe en todas las etapas del proceso, ya que esto podrá asegurar que el ciclo de desarrollo se mantenga en sintonía con los requerimientos reales de los usuarios finales.

La siguiente fase de construcción de la solución es el desarrollo de lo que se conoce como el MVP. En esta fase se desarrolla una versión básica pero funcional y estable del producto, en este caso, un modelo entrenado con datos reales, con el fin de probar hipótesis y testear los resultados en relación con el desempeño del modelo, y también con la respuesta que este otorga a las expectativas y necesidades de los usuarios. Un punto para resaltar en el proceso de desarrollo del MVP es su utilidad para la adaptación de la solución a los cambios del entorno, pues este producto valida hipótesis de manera relativamente rápida y eficiente, y de esta manera hace posible desarrollar productos funcionales que iteran continuamente con base en el conocimiento del mercado que se obtiene de la exposición a los usuarios. Así mismo, conviene verificar que las herramientas, imágenes y contenidos utilizados en este producto cumplen con todas las respectivas licencias y revisar si tienen costos asociados que deban ser considerados.

146 Departamento de Infraestructura (INE). *Guía de desarrollo de productos digitales*. [Diapositivas de PowerPoint]. Banco Interamericano de Desarrollo (BID).

147 Proof of concept (POC). Op.cit.

148 Departamento de Infraestructura (INE). *Guía de desarrollo de productos digitales*. [Diapositivas de PowerPoint]. Banco Interamericano de Desarrollo (BID).

Finalmente, en el caso en el que el MVP sea desarrollado por un proveedor externo, conviene verificar la entrega de todos los componentes relacionados como wireframes, elementos de interfaz de usuario, sistemas de diseño y flujos detallados. Así mismo, en los casos que aplique, el acceso y control sobre los datos, el código fuente y los modelos utilizados.

Etapa 2, Fase 3

Principios éticos y regulación sectorial:

Durante la etapa de prototipado y desarrollo de la solución se deben considerar principios de diseño asociados a la transparencia, rendición de cuentas y consideración de aspectos éticos que sean relevantes. Esto permite desarrollar soluciones de IA bajo los marcos de gestión de los riesgos existentes¹⁴⁹, así como promover una mayor confianza en su uso.

De igual manera, los sistemas de IA interactúan con el entorno, por lo que sus procesos deben contemplar el cumplimiento de la regulación sectorial. En ese sentido, en esta etapa se

realiza un análisis de la normatividad sectorial aplicable, de los aspectos legales relevantes de los sistemas tecnológicos a utilizar, de la regulación existente en privacidad y protección de datos, y de la normatividad específica en IA, si es que existe.

Como se ha mencionado, uno de los riesgos asociados al desarrollo de modelos de IA es que estos puedan replicar sesgos existentes en la sociedad y que, con esto, sus resultados puedan generar afectaciones en grupos específicos de la población. Una forma de afectación se puede dar a través de los sesgos algorítmicos¹⁵⁰. Estos sesgos incluyen los sesgos de procesamiento, confirmación y exclusión. Los primeros se refieren a las distorsiones que pueden introducirse en los datos antes de que se utilicen para entrenar el modelo. Los sesgos de confirmación son los que se producen cuando las soluciones de IA corroboran estereotipos o creencias previas, y los sesgos de exclusión describen lo que sucede

cuando ciertos grupos poblacionales son excluidos del set de entrenamiento de manera sistemática¹⁵¹.

En este contexto, la vigilancia ética se da a través de la identificación y mitigación de sesgos, y también mediante la aplicación de principios de comportamiento. El principio de *transparencia* en las soluciones de IA implica la capacidad de entender cómo y por qué un modelo de IA toma determinadas decisiones. Así mismo, se debe tener en cuenta el principio de *responsabilidad*, que se refiere a la capacidad de atribuir acciones y decisiones de una solución basada en IA a un responsable específico, quien rinde cuentas por los posibles efectos de estos sesgos e incorpora medidas de mitigación.

Otro aspecto para resaltar se relaciona con el tratamiento de información personal o reservada en los casos en que este tratamiento aplique. Al respecto, cuando se tiene información con estas características se puede realizar un ejercicio

149 Departamento de Infraestructura (INE). *Guía de desarrollo de productos digitales*. [Diapositivas de PowerPoint]. Banco Interamericano de Desarrollo (BID).

150 Este se refiere a los errores sistemáticos y repetibles de un sistema de IA "que crean resultados injustos, como privilegiar a un grupo arbitrario de usuarios frente a otros". Awan, A. A. ¿Qué es el sesgo algorítmico? (abril, 2024). Recuperado de <<https://www.datacamp.com/es/blog/what-is-algorithmic-bias>>

151 Awan, A. A. ¿Qué es el sesgo algorítmico? (abril, 2024). Recuperado de <<https://www.datacamp.com/es/blog/what-is-algorithmic-bias>>

de anonimización¹⁵² o seudonimización¹⁵³ para entrenar al modelo sin infringir normativas existentes sobre datos personales. Un ejemplo de este tipo de consideraciones es el tratamiento de la información utilizada para el desarrollo e implementación de la herramienta Distancia2, una plataforma tecnológica desarrollada por el BID para las ciudades, que fue implementada en 46 ciudades de ALC durante la pandemia, y cuyo objetivo fue contribuir a mitigar el riesgo de contagio en áreas con grandes aglomeraciones. Esta solución utiliza las imágenes de video grabadas por las cámaras instaladas en las ciudades y, a través de algoritmos de IA, estima el distanciamiento entre las personas para propósitos de análisis y generación de alarmas de salud pública. Durante el diseño y desarrollo de esta herramienta se utilizó como requerimiento que esta no utilizara información privada de los individuos, ni que analizara rasgos particulares o

características únicas de estos. De esta manera, el modelo implementado se limita a detectar personas de manera anónima y a estimar la distancia entre ellas¹⁵⁴.

Etapa 2, Fase 4

Seguridad tecnológica y de la información:

Los modelos de IA consideran una serie de retos en materia de seguridad. Los riesgos en esta materia incluyen, por ejemplo, la generación de datos de entrada maliciosos o las fugas de seguridad en los marcos que se utilizan en la producción de los modelos¹⁵⁵. Para prevenir estos ataques o vulnerabilidades, se recomienda adoptar el enfoque de *security-by-design* que integra medidas preventivas de seguridad desde el diseño mismo del modelo¹⁵⁶.

Los sectores de infraestructura incluyen activos críticos con altos niveles de interdependencia, lo que los hace vulnerables a ataques

152 En el proceso de anonimización de datos un único y nuevo conjunto de datos es creado. Independientemente del análisis que se haga con este, no es posible identificar características personales de la observación. Agencia Española de Protección de Datos (AEPD). Anonimización y seudonimización. (octubre, 2021). Recuperado de <<https://www.aepd.es/prensa-y-comunicacion/blog/anonimizacion-y-seudonimizacion>>

153 Durante el proceso de seudoanonymización se crean dos conjuntos de datos, los datos seudoanonymizados y los datos para revertir este proceso, los cuales deberán cumplir con todas las normas del caso. Agencia Española de Protección de Datos (AEPD). Anonimización y seudonimización. (octubre, 2021). Recuperado de <<https://www.aepd.es/prensa-y-comunicacion/blog/anonimizacion-y-seudonimizacion>>

154 Fuente: BID. Distancia2. Recuperado de <<https://fairlac.iadb.org/piloto/distancia2>>

155 Riesgos de la inteligencia artificial en ciberseguridad. Recuperado de <<https://globalt4e.com/riesgos-de-la-inteligencia-artificial-en-ciberseguridad/>>

156 Ibidem.

cibernéticos que pueden desencadenar crisis sistémicas. En ese sentido, las organizaciones que aplican soluciones de IA en sus procesos deben entender la relevancia de la seguridad cibernética como un elemento fundamental.

Al respecto, resulta esencial incorporar un enfoque de seguridad desde el diseño, que integre la ciberseguridad en toda la cadena de producción del modelo. Este enfoque garantiza un proyecto seguro, protocolos de privacidad de los datos, arquitectura segura, capacitación y concientización de las vulnerabilidades y pruebas de seguridad continuas¹⁵⁷. En cuanto a esto último, una práctica común es la realización de pruebas de penetración, fuzzing y ataques adversarios en los modelos de prueba y en las etapas de pre-producción y producción del modelo¹⁵⁸.

157 National Cyber Security Centre. AI and cyber security: what you need to know. Recuperado de <https://www.ncsc.gov.uk/guidance/ai-and-cyber-security-what-you-need-to-know#section_5>

158 National Cyber Security Centre. Guidelines for security AI system development. Recuperado de <<https://www.ncsc.gov.uk/collection/guidelines-secure-ai-system-development>>

Etapa 3. Implementación, monitoreo y evaluación de la solución

La **implementación, mantenimiento y escalamiento de la solución**, generalmente incluye cuatro (4) fases, las cuales son: i) evaluación de rendimiento; ii) sostenibilidad de la solución; iii) auditoría ética y de seguridad; y iv) actualización del modelo.

Etapa 3, Fase 1

Evaluación de rendimiento:

En esta fase se analiza el rendimiento del modelo de IA desarrollado. Para esto, generalmente se definen e implementan un conjunto de indicadores para evaluar el desempeño de la solución y promover la confianza en sus resultados. Este tipo de métricas estiman la eficacia de un modelo en la ejecución de su tarea específica y en el logro de los resultados esperados. Estos indicadores sirven para varios propósitos entre los que se destacan, medir la precisión, ajustar hiper-parámetros, facilitar la interpretabilidad e identificar sobreajuste o sub-ajuste, entre otros.

Los indicadores de evaluación dependen tanto de las características de los datos que se están usando como del tipo de problema que se está solucionando. Así entonces, los indicadores de rendimiento más usados para problemas

de clasificación¹⁵⁹ son, por ejemplo, Exactitud¹⁶⁰, Precisión¹⁶¹, Sensibilidad¹⁶², F1 Score¹⁶³, ROC-AUC y PR-AUC y la Matriz de confusión¹⁶⁴. Por su parte, las métricas más comunes para

problemas de regresión¹⁶⁵ son: Error Absoluto Medio (MAE)¹⁶⁶, Error Cuadrático Medio (MSE)¹⁶⁷, Raíz del Error Cuadrático Medio (RMSE)¹⁶⁸, Coeficiente de Determinación (R^2)¹⁶⁹, Error Porcentual Absoluto Medio (MAPE)¹⁷⁰, y Coeficiente de Determinación Ajustado (R^2 ajustado)¹⁷¹.

159 Halder, N. Decoding Machine Learning Success: Evaluating Performance Metrics with Python. (febrero, 2024). Recuperado de <<https://medium.com/gitconnected/decoding-machine-learning-success-evaluating-performance-metrics-with-python-2f98a452bbc4>>

160 **Exactitud (Accuracy)**: Hace referencia a la “proporción de observaciones predichas correctamente respecto al total”. Es una métrica intuitiva y ofrece una medida simple de efectividad del modelo, no obstante, cuando existe desbalance de los datos puede inducir a errores (Halder, 2024).

161 **Precisión (Precision)**: Corresponde a la “proporción de observaciones positivas predichas correctamente respecto al total de positivas predichas”. Esta es una métrica bastante útil cuando el costo de un falso positivo no es bajo (Halder, 2024).

162 **Sensibilidad (Recall)**: Se refiere a la “proporción de observaciones positivas predichas correctamente con respecto a todas las observaciones de clase real”. Esta es una métrica bastante útil cuando existe un alto costo asociado a obtener un falso negativo (Halder, 2024).

163 **F1 Score**: Corresponde al promedio ponderado de los indicadores *Precision* y *Recall*. Esta métrica resulta apropiada cuando existe un balance entre los dos indicadores reseñados, especialmente en categorías desbalanceadas (Halder, 2024).

164 La **matriz de confusión** es una representación tabular de las categorías predichas y las reales permitiendo que el investigador de manera relativamente fácil identifique los tipos de errores que comete el modelo. En este tipo de matrices se pueden identificar los siguientes componentes: verdaderos positivos (TP), que son los casos identificados correctamente como positivos; verdaderos negativos (TN), que son los casos identificados correctamente como negativos; falsos positivos (FP), que son los casos negativos identificados de manera incorrecta como positivos; falsos negativos (FN), que son los casos positivos identificados de manera incorrecta como negativos. En términos generales, las filas representan las categorías o clases reales, las columnas representan las clases predichas por el modelo, la diagonal principal muestra las predicciones correctas y los elementos por fuera de la diagonal hacen referencia a los errores. Para más información, consultar <<https://www.sciencedirect.com/topics/engineering/confusion-matrix#:~:text=A%20confusion%20matrix%20represents%20the,by%20model%20as%20other%20class.>>

165 Halder N. Decoding Machine Learning Success: Evaluating Performance Metrics with Python. Op.cit.

166 **Error Absoluto Medio (MAE)**: Es el “promedio de las diferencias absolutas entre los valores predichos y los reales”. Esta métrica permite hacerse una idea de la desviación de las predicciones (Halder, 2024).

167 **Error Cuadrático Medio (MSE)**: Corresponde al promedio de las diferencias al cuadrado entre los valores predichos y los reales. El MSE sanciona más los errores grandes que el MAE, lo que puede llegar a ser o una ventaja o un inconveniente dependiendo del caso (Halder, 2024).

168 **Raíz del Error Cuadrático Medio (RMSE)**: Es la raíz cuadrada del error cuadrático medio o MSE, lo que permite tener un indicador en la misma escala que los valores originales (Halder, 2024).

169 **Coeficiente de Determinación (R^2)**: Representa la proporción de la varianza de la variable objetivo o dependiente que es explicada por los predictores o variables independientes. Corresponde a la bondad de ajuste de estas predicciones (Halder, 2024).

170 **Error Porcentual Absoluto Medio (MAPE)**: mide la media de los errores absolutos entre las predicciones del modelo y los valores reales, expresados como un porcentaje de los valores reales.

171 **Coeficiente de Determinación Ajustado (R^2 ajustado)**: Corresponde a un ajuste del R^2 de acuerdo con cuántos predictores hay en el modelo. Fuente: Investopedia. Recuperado de <<https://www.investopedia.com/ask/answers/012615/whats-difference-between-rsquared-and-adjusted-rsquared.asp#:~:text=Adjusted%20R%2Dsquared%20is%20less%20than%20expected>>

No se acostumbra a utilizar un único parámetro para determinar la eficacia un modelo de IA, aunque el desempeño mínimo que se espera es una precisión superior al 50%. Cuando se evalúa el rendimiento de un modelo usualmente se tiene en cuenta su función de costos, que mide la distancia entre los resultados del modelo y la realidad¹⁷². El objetivo que usualmente se plantea es el de minimizar esa distancia, y esto se hace por lo general con un algoritmo conocido como gradiente descendente (*gradient descent* en inglés). Resulta recomendable optimizar el modelo desde puntos aleatorios de los datos y ajustar la tasa de aprendizaje de este durante el entrenamiento, con el fin de asegurar que los resultados obtenidos son consistentes¹⁷³.

De esta manera, dependiendo del tipo de problema que esté resolviendo el modelo se seleccionan las métricas de rendimiento para identificar las fortalezas y debilidades de los algoritmos utilizados. Así mismo, se recomienda utilizar más de un indicador para poder tener una evaluación más robusta y detallada del modelo.

Etapa 3, Fase 2

Estrategia de sostenibilidad de la solución:

Esta fase hace referencia al conjunto de acciones que se deben adoptar para que la solución, una vez desarrollada, sea utilizada y actualizada de manera continua en la organización. En ese sentido, un factor clave de éxito en la implementación de IA es la voluntad institucional para garantizar la sostenibilidad de la solución, entendida esta sostenibilidad como la capacidad de adoptar la solución, integrarla a los procesos existentes, y asegurar los recursos humanos, tecnológicos y financieros requeridos para su aprovechamiento continuo. En algunos casos esto puede requerir un cambio en la cultura institucional en relación con el desarrollo y adopción de innovaciones tecnológicas.

En esta fase resulta conveniente implementar una iniciativa de comunicación sobre la existencia de la herramienta,

su funcionamiento y los resultados que esta genera. En el mismo sentido, conviene evaluar y comunicar el retorno de la inversión relacionada con la adopción de la solución, con el fin de retroalimentar el proceso de desarrollo e implementación, y promover la adopción y continuidad. Así mismo, resulta relevante que las áreas de la compañía logren interiorizar que la IA es de ayuda para reducir costos de inversión y operación; de esta manera, los costos del proyecto podrán ser considerados como inversión, y se podrán asegurar flujos futuros que permitan contar con un presupuesto adecuado para su mantenimiento y mejora continua.

En el mismo sentido, conviene crear o fortalecer una cultura de experimentación y aprendizaje continuo, que habilite la innovación con enfoque ágil en la organización, y que contribuya a garantizar la sostenibilidad en la adopción de la solución. Los experimentos controlados en conjunto con la realimentación directa de los usuarios iteran con mayor rapidez y al final tener resultados con mayor impacto¹⁷⁴. Los errores al final del proyecto resultan más costosos que el crecimiento con pequeños experimentos, no solo desde

¹⁷² Understanding Cost Functions in Machine Learning: Types and Applications. (2023). Recuperado de <<https://medium.com/@anishnama20/understanding-cost-functions-in-machine-learning-types-and-applications-cd7d8cc4b47d>> & Machine learning fundamentals (i): Cost functions and gradient descent. (2017, noviembre). Recuperado de <https://towardsdatascience.com/machine-learning-fundamentals-via-linear-regression-41a5d11f5220> & Gradient Descent for Dummies. (2021, mayo). Recuperado de <https://raed-asdi.medium.com/gradient-descent-for-dummies-1eda90f269b> & para más información consultar <<https://www-sciencedirect-com.ezproxy.uniandes.edu.co/topics/engineering/gradient-descent>>

¹⁷³ Ibidem.

¹⁷⁴ Departamento de Infraestructura (INE). *Guía de desarrollo de productos digitales*. [Diapositivas de PowerPoint]. Banco Interamericano de Desarrollo (BID).

el punto de vista de tiempo y recursos sino también en la motivación del equipo de trabajo. Al respecto, implementar un programa de transferencia de conocimiento es clave para que el proyecto continue iterando, para que se siga ajustando el modelo en sus diferentes etapas y para que las diferentes áreas relacionadas con el problema se apropien de la solución. La capacitación del equipo favorecerá el mayor aprovechamiento del proyecto y su uso continuo, así como sus respectivas actualizaciones.

Etapa3, Fase 3

Auditoría ética y de seguridad:

Este componente se centra en la evaluación *ex post* de la solución para identificar posibles vulnerabilidades en la seguridad de la información, y asegurar que los resultados no perpetúen estereotipos sociales que puedan ser discriminatorios con ciertos grupos poblacionales. Tener sistemas automatizados de toma de decisiones genera desafíos éticos y morales en la definición de las reglas que dicho sistema sigue; en consecuencia, resulta necesario contar con mecanismos de control adecuados como por ejemplo la auditoría algorítmica (Villagrán, 2022). Aunque la mayoría de los modelos utilizados en el sector de infraestructura no suelen ser entrenados con datos sensibles,

representa una buena práctica realizar auditorías éticas y de seguridad, principalmente en casos en los que se identifiquen posibles alertas en cuanto a sesgos o tratamiento de información sensible.

Uno de los mecanismos de seguimiento y cumplimiento de los estándares éticos planteados desde el diseño mismo del modelo tiene que ver con la “equidad de grupo”, que hace referencia a la identificación de los grupos poblacionales que podrían estar siendo perjudicados con los resultados del modelo¹⁷⁵. Este concepto, de acuerdo con las mejores prácticas, se cuantifica mediante métricas de disparidad que buscan examinar y comparar el comportamiento de los grupos a través de diferentes indicadores de rendimiento mediante proporciones o diferencias¹⁷⁶. De igual manera, existen métricas de sesgo generales de carácter grupal¹⁷⁷, como por ejemplo

la Paridad Demográfica (PD)¹⁷⁸, la Igualdad de Oportunidades (EO)¹⁷⁹ o la Paridad Estadística (SP)¹⁸⁰; y de carácter individual¹⁸¹, como es el caso de los indicadores de Igualdad de probabilidades (EOdds)¹⁸² y Calibración¹⁸³, entre otros.

Finalmente, en los procesos de auditoría algorítmica es recomendable, además de documentar los procedimientos y registrar las personas que hacen parte de estos, adoptar protocolos de intervención en el modelo cuando no se superen las evaluaciones de equidad algorítmica (Pombo *et al.* 2020; Torres *et al.*, 2021; Villagrán, 2022).

178 La cual comprueba “si la probabilidad de una predicción positiva es igual en todos los grupos demográficos” (Gomedé, 2023).

179 Esta determina si en todos los grupos la tasa de verdaderos positivos es equivalente, por lo cual busca una reducción en la cantidad de falsos negativos (Gomedé, 2023).

180 Garantiza que entre los grupos exista una distribución equitativa de los resultados positivos previstos (Gomedé, 2023).

181 Fairness Metrics in Machine Learning. Op.cit.

182 Se asegura que en todos los grupos las tasas de verdaderos positivos sea equivalente a la de falsos positivos (Gomedé, 2023).

183 Este indicador evalúa si las probabilidades previstas reflejan con exactitud la probabilidad de que se produzca un suceso. Dado que un modelo mal calibrado tiende a reproducir decisiones sesgadas, la calibración es un elemento a considerar (Gomedé, 2023).

175 Microsoft. Rendimiento y equidad del modelo. (febrero, 2024). Recuperado de <<https://learn.microsoft.com/es-es/azure/machine-learning/concept-fairness-ml?view=azureml-api-2>>

176 Ibidem.

177 Gomedé, E. Fairness Metrics in Machine Learning. (septiembre, 2023). Recuperado de <<https://medium.com/the-modern-scientist/fairness-metrics-in-machine-learning-8c3777b48a9c>>

Etapa 3, Fase 4

Mantenimiento, actualización y escalamiento de la solución:

Esta fase hace referencia a las actividades asociadas a los desarrollos adicionales, actualizaciones y mantenimiento del modelo, de acuerdo con las necesidades existentes. El escalamiento del modelo puede potenciar su impacto en la organización. Por su parte, los cambios en el entorno, en los usuarios y en los datos alimentan el modelo, generan la necesidad de que este sea revisado, requiera ajustes de sus parámetros, o que sea reentrenado con nueva información.

El modelo desarrollado e implementado con el tiempo puede ir perdiendo su precisión debido a cambios estructurales en el mercado o en la sociedad. También se pueden presentar cambios más leves en el comportamiento de las variables que lo alimentan y en sus propiedades estadísticas e incluso en los canales de captura de información, por lo que es necesario reentrenarlo con nueva información¹⁸⁴.

A lo anterior se le conoce como *model drift*, pues se podrá experimentar una degradación en el rendimiento del modelo de *machine learning* desplegado¹⁸⁵. Para poder estar al tanto de este fenómeno, resulta relevante contar con un proceso continuo de control de calidad y de monitoreo del rendimiento del modelo que permita detectar desviaciones con respecto a los indicadores que se obtenían en la etapa temprana de producción¹⁸⁶, así como habilitar la incorporación de nuevos datos de entrada para anticipar los cambios del entorno.

De igual manera, resulta importante mantener documentados los cambios que se realicen tanto del modelo como de la interfaz con la que interactúa el usuario, si se tiene. En este sentido, el control de versiones permite la colaboración entre los diferentes desarrolladores, facilita la trazabilidad de las modificaciones, permite navegar con relativa agilidad entre

184 Understanding Data Drift and Model Drift: Drift Detection in python. Recuperado de <<https://www.datacamp.com/tutorial/understanding-data-drift-model-drift>>

185 Nicomanesh A. (2024). Model drift: Identifying and Monitoring for Model Drift in Machine Learning Engineering and Production Recuperado de <<https://medium.com/@anicomanesh/model-drift-identifying-and-monitoring-for-model-drift-in-machine-learning-engineering-and-0f74b2aa2fb0>>

186 Ibidem.

las versiones para recuperar parte de alguna solución del pasado, contribuye a la solución de conflictos entre cambios simultáneos al código y favorece la auditoría algorítmica, entre otros.

Finalmente, en los proyectos que involucran *machine learning* se entiende escalabilidad como la capacidad del sistema para incorporar aumentos significativos de volúmenes de datos, aumentar su eficiencia y eficacia, así como también soportar mayores cargas de trabajo sin que se vea afectado su rendimiento¹⁸⁷. En ese sentido, la escalabilidad de una solución de IA involucra distintas dimensiones entre las que se encuentran, los datos, el modelo y la infraestructura¹⁸⁸. Así entonces, en lo que respecta a la dimensión de información, en medida en que la aplicación evoluciona, la cantidad de información aumenta, por lo que se involucran al proceso más datos para reentrenar, validar y testear las nuevas versiones

187 Censius. ML Scalability. Recuperado de <<https://censius.ai/wiki/ml-scalability#:~:text=Machine%20learning%20scalability%20refers%20to,users%20residing%20at%20global%20locations.>> & OpenTeams. Scalable Infrastructure for MLOps: Ensuring High Performance and Efficiency. (2023, junio). Recuperado de <<https://www.openteams.com/scalable-infrastructure-for-mlops-ensuring-high-performance-and-efficiency/>>

188 Ibidem.

del modelo¹⁸⁹. Por su parte, el modelo también puede variar en su tamaño y complejidad, y con esto demandar mayor capacidad de cómputo. Esto deriva en la necesidad de contar con infraestructura escalable para atender las nuevas necesidades de almacenamiento -cada vez más información- y de procesamiento -modelos más complejos y con más parámetros¹⁹⁰ que se puedan presentar. La escalabilidad de la solución se podrá lograr mediante acciones como la implementación de un sistema de monitoreo de rendimiento que alerte cuando el modelo se esté desactualizando, el aprovechamiento de la computación en la nube para poder escalar oportunamente las plataformas tecnológicas, el uso de procesamiento paralelo¹⁹¹ o mediante la ejecución de tareas en contenedores tipo Docker¹⁹² para hacer más eficiente la operación de los modelos¹⁹³.

189 Ibidem.

190 Ibidem.

191 Para más información consultar: Parallel processing. Recuperado de <<https://www.techtarget.com/searchdatacenter/definition/parallel-processing#:~:text=Parallel%20processing%20is%20a%20method,time%20to%20run%20a%20program.>>

192 ¿Qué es Docker? Recuperado de <<https://aws.amazon.com/es/docker/>>

193 Census. ML Scalability. Recuperado de <<https://census.ai/wiki/ml-scalability#:~:text=Machine%20learning%20scalability%20refers%20to,users%20residing%20at%20global%20locations.>> & OpenTeams. Scalable Infrastructure for

4.2

Principios recomendados para el desarrollo de soluciones de IA

Finalmente, y de acuerdo con las consideraciones presentadas en la sección anterior, teniendo en cuenta las ventajas del enfoque de desarrollo e innovación ágil para la implementación de soluciones de IA en sectores de infraestructura, se recomienda considerar a lo largo del proceso de desarrollo e implementación de las soluciones un conjunto de nueve (9) principios, que se describen a continuación.

● **Entendimiento de la problemática y de la pertinencia de la IA para su solución:** Este principio se fundamenta en que es deseable primero entender la problemática antes de pensar en cómo resolverla. En este sentido, resalta la relevancia de definir y acotar el problema o necesidad a solucionar, de manera que el problema definido sea claro, conciso, basado en evidencia, y que haga referencia a una situación solucionable. Una vez identificado y entendido el problema, en la identificación de las alternativas, será

MLOps: Ensuring High Performance and Efficiency. (2023, junio). Recuperado de <<https://www.openteams.com/scalable-infrastructure-for-mlops-ensuring-high-performance-and-efficiency/>>

de vital importancia evaluar la pertinencia de utilizar IA en la solución, con base en los beneficios, costos e implicaciones para la organización del uso de esta tecnología. En este sentido, el foco de los proyectos de IA deberá ser la solución del problema específico a resolver, antes que la tecnología en sí misma.

● **Diseño y desarrollo centrado en el usuario:** Este principio se basa en ubicar al usuario como fuerza convergente del desarrollo de la solución. Esto implica conocer qué características tienen las personas o entidades que van a usar el modelo, cuáles van a ser los principales usos, qué motivaciones tienen, en qué procesos interactuarán los resultados del modelo, entre otras. Para esto, se requiere interactuar con el usuario en el marco de la creación del producto, con el objetivo de identificar sus necesidades, motivaciones y expectativas en el uso.

● **Desarrollo ágil:** Hace referencia a la habilidad para crear productos de manera dinámica e iterativa, y adaptar los productos en respuesta al cambio. Este principio comprende una serie de marcos de trabajo¹⁹⁴ y

194 Algunos ejemplos son: Scrum, Kanban y Extreme Programming (Agile Alliance).

metodologías¹⁹⁵ que permite que el desarrollo de producto a través de la iteración, la experiencia y la colaboración, pueda adaptarse con relativa facilidad a los cambios del usuario, del mercado e incluso de la propia empresa que está a cargo del producto o servicio¹⁹⁶.

● **Aprovechamiento de los datos:** Este principio va más allá de utilizar información en los procesos, requiere una transformación de la organización¹⁹⁷ para pensar, gestionar y comunicar sus procesos productivos a través de la maximización de la información disponible. Para esto es fundamental contar con información de calidad¹⁹⁸, es decir, que esta esté completa, sea consistente y veraz,

de otra forma los resultados del modelo carecerán de fiabilidad y robustez.

● **Uso de estándares e innovación abiertos:** Este principio se fundamenta en la creación de conocimiento en comunidad. Parte de la base que un enfoque abierto de desarrollo e innovación maximiza los recursos y el impacto de las soluciones que se implementen¹⁹⁹.

● **Uso de modelos fundacionales de uso libre:** Como se señaló, los modelos fundacionales (FM) también conocidos como modelos pre-entrenados o de propósito general, son redes neuronales que realizan aprendizaje profundo entrenados con grandes cantidades de datos y compuestos por un número significativo de parámetros, que realizan distintas tareas generales como puede ser, generar texto e imágenes, comprender diferentes lenguajes humanos y mantener conversaciones en lenguaje natural, entre otros²⁰⁰. Algunas de las ventajas

195 Algunos ejemplos son: pair programming, test-driven development y sprint planning (Agile Alliance).

196 Agile Alliance.What is Agile? Recuperado de <<https://www.agilealliance.org/agile101/#:~:text=Agile%20is%20the%20ability%20to,an%20uncertain%20and%20turbulent%20environment.>> & Microsoft. ¿Qué es el desarrollo de Agile? (octubre, 2023). Recuperado de <<https://learn.microsoft.com/es-es/devops/plan/what-is-agile-development>>

197 Para esto es importante como primera medida identificar qué nivel de madurez tiene la organización en términos de análisis de datos dado que la implementación del proyecto debe ser paulatina.

198 Los problemas de calidad en la información pueden deberse a múltiples factores como, por ejemplo, errores humanos, técnicos o de recolección de los datos.

que se obtienen de utilizar este tipo de modelos²⁰¹ dentro del desarrollo del sistema propio tienen que ver con la reducción del tiempo de desarrollo, optimización de recursos, adaptabilidad a través del *fine-tuning*, escalabilidad horizontal y vertical, y crecimiento en comunidad, entre otros²⁰².

● **Relevancia de la ética, privacidad y seguridad:** Este principio hace referencia a tres conceptos principales. El primero tiene que ver con la aplicación de principios éticos en el diseño y estructuración de modelos de IA. El segundo concepto se refiere a la privacidad de los datos. Al respecto, un buen diseño del modelo debe garantizar que los datos de los usuarios se manejen de forma segura y se respete su privacidad, evitando el uso indebido o el acceso no autorizado. Finalmente, el tercer concepto consiste en

201 Algunos ejemplos son: BERT-Bidirectional Encoder Representations from Transformers- (<https://github.com/google-research/bert>); GPT-Generative Pre-trained Transformer- (<https://github.com/openai/gpt-2>); RoBERTa-A Robustly Optimized BERT Pertaining Approach- (<https://github.com/facebookresearch/fairseq/tree/main/examples/roberta>); T5-Text to Text Transfer Transformer- (<https://github.com/google-research/text-to-text-transfer-transformer>); XLNet (<https://github.com/zihangdai/xlnet>); y YOLO-You Only Look Once- (<https://github.com/ultralytics/yolov5>)

202 3 Ways to adapt a Foundation Model to fit your specific needs. Recuperado de <<https://kili-technology.com/large-language-models-llms/three-ways-to-adapt-an-llm-model-to-suit-your-ml-needs>>

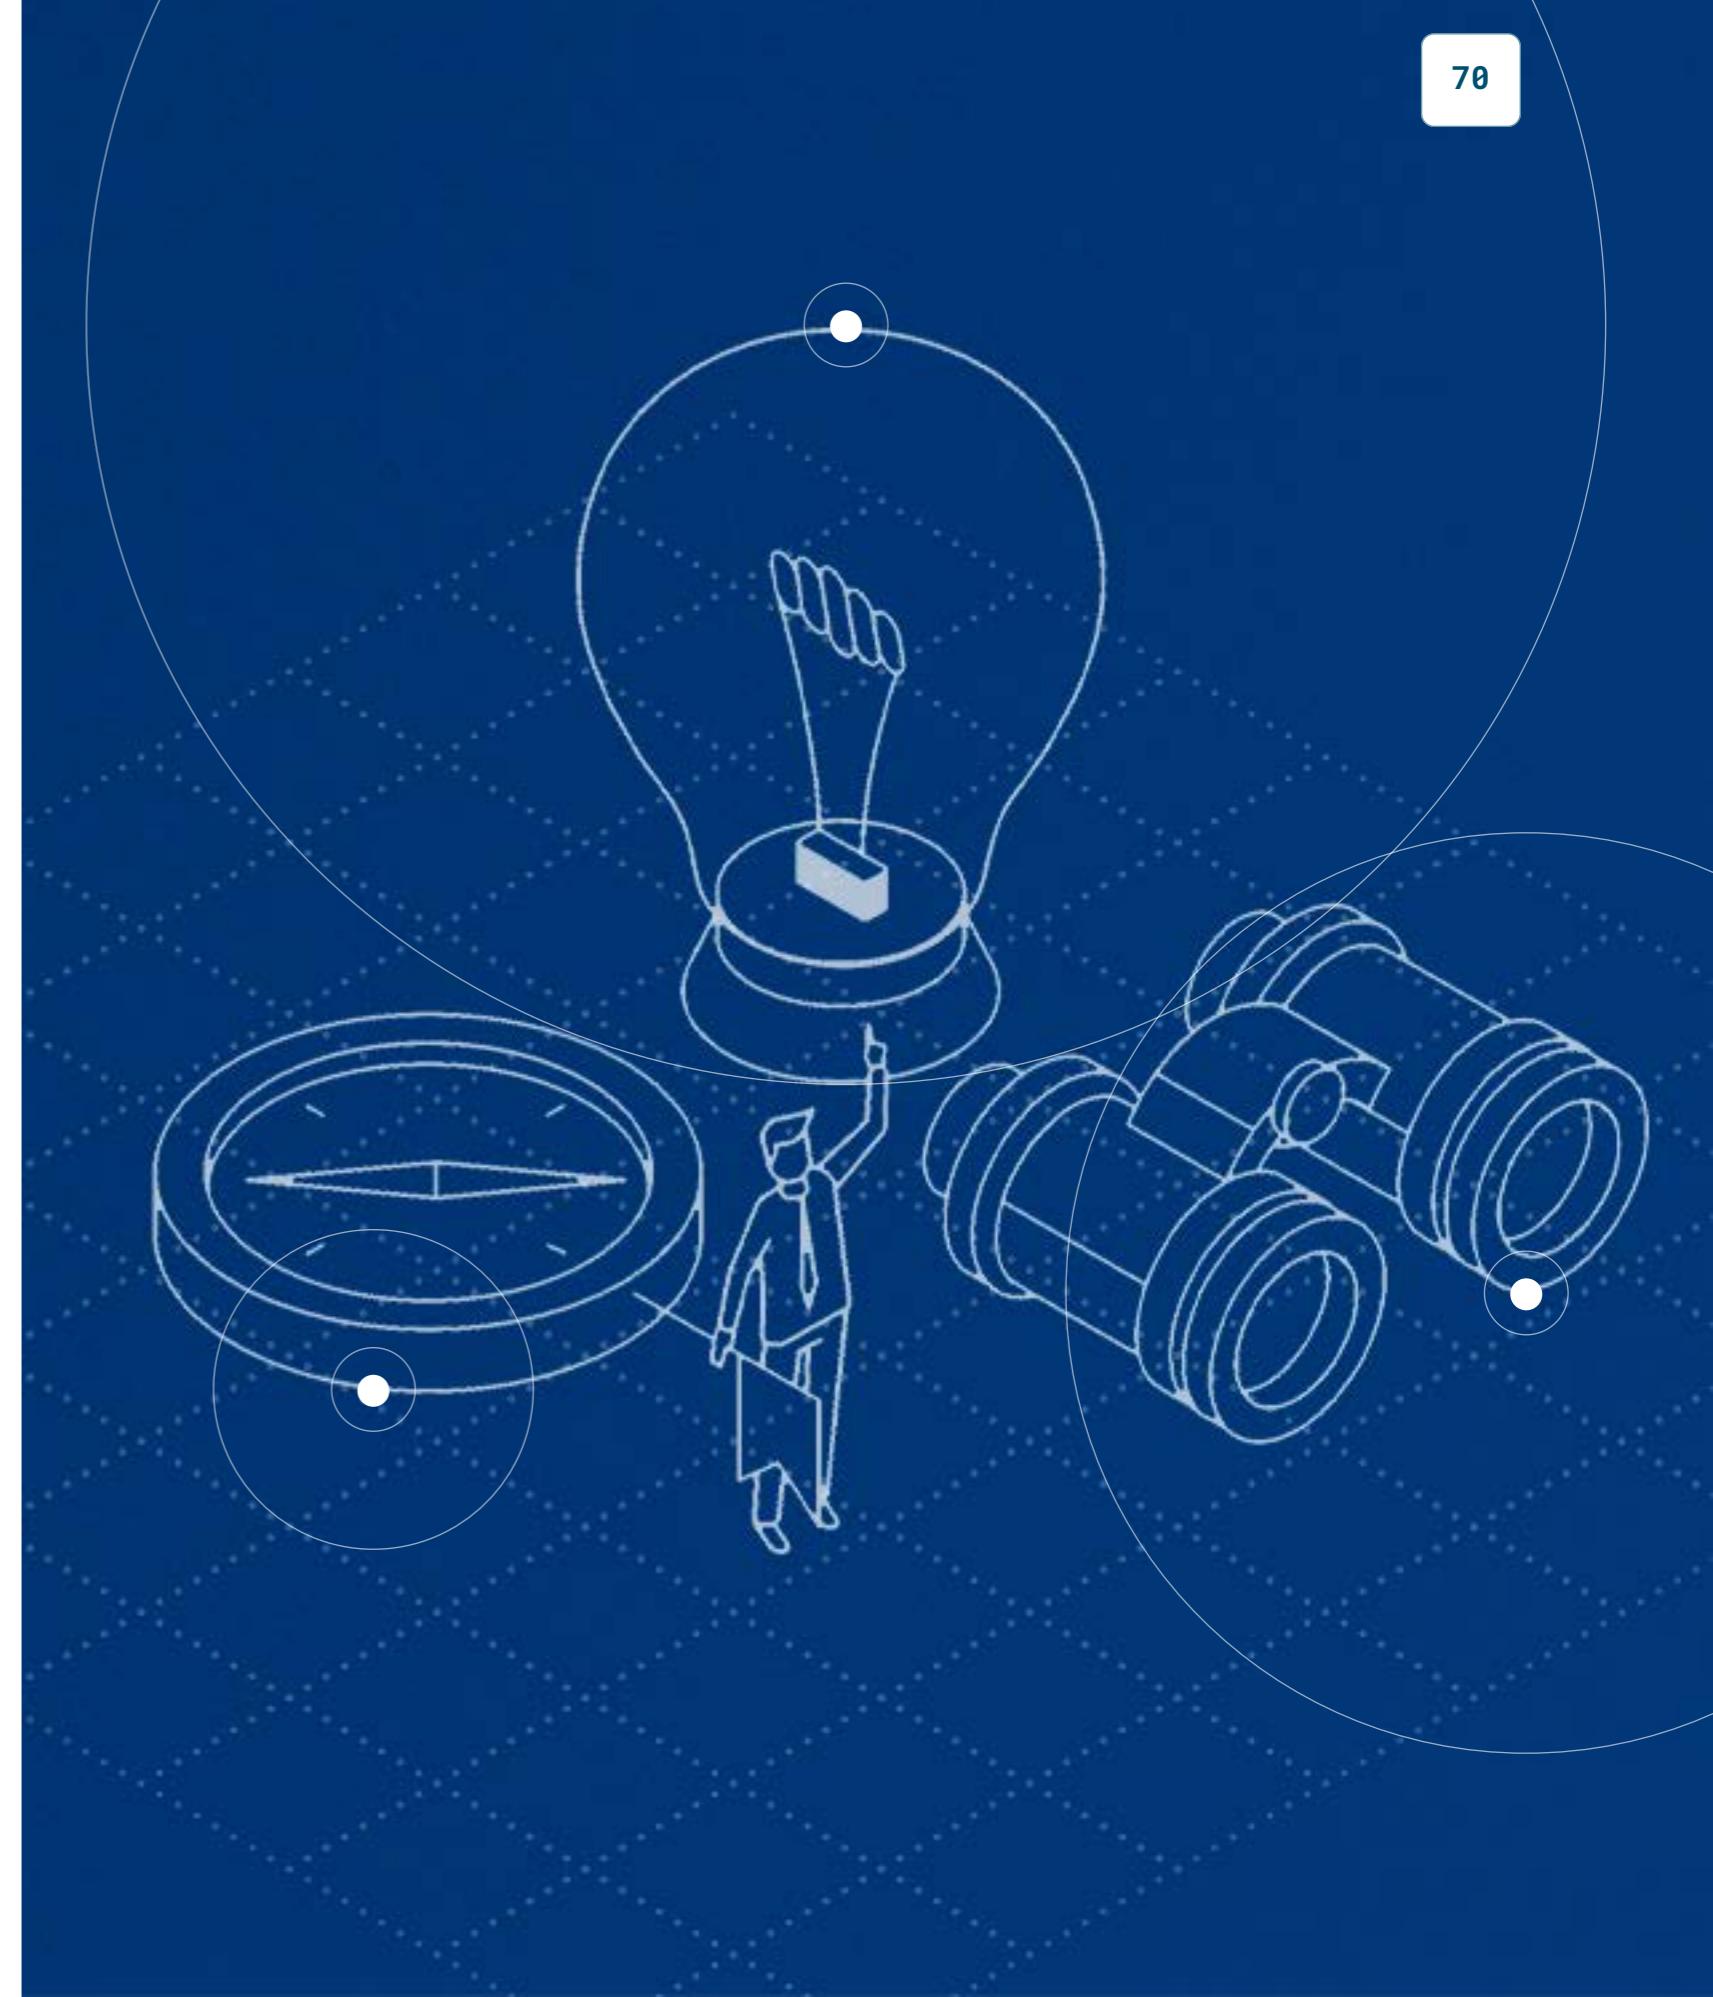
la seguridad del sistema. Esto implica mitigar los riesgos ciberneticos que surgen cuando los modelos de IA se aplican a infraestructura critica como es el caso de los sectores de energía eléctrica, transporte, y agua y saneamiento básico.

- **Escalabilidad:** Este principio es prospectivo y consiste en el diseño e implementación de un sistema que esté en capacidad de crecer según esto se requiera. La escalabilidad del sistema debe estar en función de aspectos como la cantidad de datos que requiere el modelo, la capacidad de procesamiento y almacenamiento, y el tipo y frecuencia de interacciones que tendrá con los usuarios.
- **Sostenibilidad:** Finalmente, este principio señala la relevancia de que las soluciones de IA implementadas sean adoptadas efectivamente en las organizaciones, que generen impactos relevantes en las mismas, y que se garanticen los recursos para que puedan continuar siendo utilizadas en el mediano y largo plazo.



CONCLUSIONES Y RECOMENDACIONES

La Inteligencia Artificial se perfila como una tecnología de propósito general, comparable a hitos históricos como la máquina de vapor, la electricidad, la informática e Internet, gracias a su capacidad de transformar profundamente múltiples sectores y dimensiones de la sociedad. Su desarrollo y adopción brindan oportunidades significativas para la transformación digital en sectores clave de infraestructura, como energía, transporte, agua y saneamiento, y residuos sólidos. Estos sectores, al ser sistemas complejos organizados en redes, con múltiples actores y alta intensidad en capital físico y datos, presentan un gran potencial para beneficiarse del impacto transformador de esta tecnología. Considerando las oportunidades que ofrece la IA en los sectores de infraestructura, resulta entonces relevante para las organizaciones implementar metodologías de desarrollo e innovación robustas, que sean consistentes con sus objetivos, y acordes con las mejores prácticas.



El BID ha apoyado a gobiernos y organizaciones en áreas de infraestructura en el diseño, prototipado, desarrollo y despliegue de soluciones de IA que han contribuido a mejorar el desempeño de procesos, la integración regional, y la calidad de los servicios a los ciudadanos. El Departamento de Infraestructura y Energía del BID ha liderado el uso de la IA, acompañando a sus clientes en el pilotaje y adopción de soluciones desarrolladas tanto por las mismas entidades públicas como por el sector privado. A su vez, en conjunto con el BID Lab, ha fomentado la creación de soluciones innovadoras desde el sector emprendedor de la región, con el objetivo de mejorar la prestación de servicios públicos y la creación de oportunidades de desarrollo.

Teniendo en cuenta la revisión de prácticas internacionales y las consideraciones presentadas a lo largo del documento, a continuación, se presenta un conjunto de recomendaciones para el desarrollo e implementación exitosos de soluciones basadas en IA en los sectores de infraestructura en ALC. Estas recomendaciones están dirigidas a quienes diseñan e implementan estas soluciones, a los formuladores de política pública en la región, y a emprendedores o equipo que innovan en este campo.

Recomendaciones generales

- En la implementación de soluciones digitales en sectores de infraestructura, centrarse en el problema a solucionar antes que en la tecnología en sí misma. Para esto, definir y acotar el problema o necesidad, de forma que este sea claro, conciso, basado en evidencia, y que haga referencia a una situación solucionable. Una vez identificado y entendido el problema, evaluar la pertinencia de utilizar IA en la solución, con base en los beneficios, costos e implicaciones para la organización del uso de esta tecnología. De esta manera, se recomienda orientar la aplicación de la IA en estas soluciones a los casos o componentes en que su uso resulte pertinente, útil y viable desde punto de vista operativo, financiero y jurídico.
- Implementar metodologías ágiles de desarrollo e innovación de IA para permitir iteraciones rápidas, ajustes continuos y una adaptación flexible a cambios y mejoras en los modelos y en los requerimientos de los procesos y usuarios.
- Incorporar dentro de la metodología de desarrollo la realización de pruebas de concepto, prototipos y proyectos piloto para probar y ajustar la solución antes de su implementación a gran escala. Esto permitirá identificar e incorporar tecnologías específicas y funcionalidades de acuerdo con las necesidades y requerimientos concretos.
- Desarrollar esquemas organizacionales que habiliten la adopción de soluciones tecnológicas basadas en IA. El éxito en su desarrollo e implementación dependerá en gran medida del compromiso y apoyo de la alta dirección, la existencia de responsables o “campeones” internos que impulsen el proceso, y la consolidación de una cultura abierta a la innovación, el cambio, la experimentación, y el trabajo en equipo. Así mismo, resulta fundamental la participación y el compromiso de todo el equipo operativo, para garantizar el uso sostenido y aprovechamiento continuo de la herramienta a lo largo del tiempo.
- Diagnosticar el estado de las capacidades de los funcionarios para el entendimiento de las oportunidades y riesgos de la IA, para la gestión de los datos, y para la participación en el desarrollo e implementación de soluciones basadas en esta tecnología. En función de estos diagnósticos, diseñar e implementar los programas de capacitación y de transferencia de conocimientos pertinentes.

- Examinar la viabilidad financiera de adoptar soluciones basadas en IA, teniendo en cuenta los costos asociados, especialmente en términos de entrenamiento de modelos y procesamiento de datos, así como la posible evolución de dichos costos dependiendo de la fase del proyecto. Considerar también los costos asociados con la implementación de proyectos de IA, incluyendo aquellos relacionados con la gestión del cambio, el desarrollo de habilidades y la sostenibilidad de los modelos a largo plazo.
- Identificar y definir el retorno de la inversión (ROI) de la adopción de soluciones basadas en IA para justificar su implementación. Esto implica evaluar los beneficios tangibles e intangibles, como la reducción de costos operativos, el aumento de la eficiencia, la mejora en la toma de decisiones y la optimización de procesos. Al establecer indicadores de éxito medibles y vinculados a los objetivos estratégicos, se asegura que las soluciones tecnológicas aporten valor real y sostenido a largo plazo, facilitando su escalabilidad y aceptación.
- Prestar especial atención a los aspectos éticos, de privacidad y seguridad desde las etapas iniciales del diseño de soluciones basadas en IA. Esto implica incorporar principios éticos como la transparencia, la

equidad y la responsabilidad en el desarrollo de los modelos, para asegurar que las soluciones no perpetúen sesgos ni discriminen a ciertos grupos. Además, será necesario garantizar la protección de los datos personales, cumplir con las normativas de privacidad vigentes y establecer mecanismos de seguridad robustos que minimicen riesgos de filtraciones o accesos no autorizados. La implementación de estas medidas desde el inicio no solo refuerza la confianza en la tecnología, sino que también protege a la organización de posibles riesgos legales y reputacionales a largo plazo.

- Documentar y disseminar las lecciones aprendidas y estudios de caso exitosos que permitan promover en el sector público el entendimiento de la IA, así como convencer a más responsables de políticas sobre las oportunidades que ofrece esta tecnología.
- Considerar las experiencias de otras regiones en la implementación de soluciones de IA en sectores de infraestructura, con el objetivo de contar con conocimiento e insumos para fortalecer la planeación y ejecución de políticas y proyectos de promoción de la adopción de IA.

Recomendaciones en la etapa de identificación de la oportunidad y planteamiento de la solución

- Definir los datos necesarios si estos no están definidos, identificar las fuentes disponibles -sensores, medidores inteligentes, cámaras de video, sistemas SCADA, redes de transporte o distribución, entre otros-, y establecer una arquitectura de datos y esquemas de gobernanza óptimos. Estos elementos aseguran la recolección y gestión adecuada de los datos críticos, como flujos de tráfico, consumo de agua o energía, y estado de la infraestructura. Prestar especial atención a la calidad, seguridad y disponibilidad de los datos durante el desarrollo e implementación resulta clave para lograr una operación eficiente y sostenible, optimizar la toma de decisiones y cumplir con normativas sectoriales. Así mismo, diferenciar desde el inicio la utilización de datos de los sistemas y redes sin implicaciones de privacidad, de los datos de usuarios y otros individuos, donde la protección de datos y la ciberseguridad resultan críticas.
- Identificar y evaluar desde el diseño los requerimientos de herramientas tecnológicas e infraestructura de datos para el desarrollo de soluciones de IA, en especial en relación

con las capacidades de almacenamiento y procesamiento. Al respecto, evitar dependencias exclusivas con proveedores específicos y considerar el valor ofrecido por los servicios de computación en la nube debido a su eficiencia, flexibilidad, agilidad y escalabilidad.

- Evaluar e identificar el esquema operativo óptimo para el desarrollo de la solución de IA. El desarrollo “*in-house*” implica menores costos y los aprendizajes quedan en la organización. Por su parte, los esquemas de contratación de equipos externos incorporan de manera oportuna el conocimiento técnico y la experiencia requerida para el desarrollo de la solución, así como disponer de menores tiempos de desarrollo. Trabajar con consultores internos permite una colaboración estrecha y personalizada, mientras que vincular firmas especializadas puede traer el beneficio de acceder a un equipo diverso con múltiples habilidades.
- Analizar la posibilidad de colaborar con *startups* tecnológicas representa una opción valiosa para el desarrollo de soluciones basadas en IA para los sectores de infraestructura. En ALC, existe un ecosistema creciente de *startups* especializadas en agua, residuos sólidos, transporte y energía que ofrecen soluciones innovadoras y adaptadas a los retos locales. Trabajar con estas empresas emergentes

puede aportar agilidad, nuevas perspectivas y tecnologías de vanguardia, además de facilitar la implementación de soluciones más personalizadas y flexibles. Esta colaboración reduce tiempos de desarrollo, al mismo tiempo que fomenta el crecimiento del ecosistema emprendedor regional.

- Considerar, para la conformación de los equipos, profesionales con capacidades necesarias para el desarrollo e implementación exitosa de la solución. Como parte de esto, evaluar la existencia de habilidades en ciencia de datos, *machine learning* y diseño y gestión de arquitectura tecnológica. Así mismo, incorporar profesionales con conocimiento del negocio, quienes podrán validar, desde el diseño, que el modelo responde a las necesidades de la organización, y suministrar retroalimentación valiosa sobre las funcionalidades y resultados en el contexto específico del sector.
- Identificar los grupos de interés que serán relevantes para la adopción exitosa de la solución. Como parte de esto, resulta conveniente vincular potenciales aliados o patrocinadores que puedan contribuir a garantizar la viabilidad de dicha adopción. Así mismo, los gobiernos locales y reguladores son actores importantes para promover la adopción y alcanzar un mayor impacto con el uso de estas soluciones.

- Examinar desde el inicio los riesgos éticos, reputacionales y normativos, entre otros, asociados al desarrollo y adopción de la solución, evaluar su posible impacto y establecer un plan para su mitigación. En el caso de utilizar información sensible, evaluar la implementación de las metodologías de tratamiento especial de este tipo de variables y los indicadores de equidad algorítmica señalados en el Capítulo 4.

Recomendaciones en la etapa de prototipado y desarrollo de la solución

- Analizar el flujo de datos del proyecto para garantizar que los datos sean adecuados, limpios y estén preparados para su uso en el entrenamiento y puesta en producción de un modelo de IA o *machine learning*. Este proceso identifica posibles problemas con las fuentes de información, asegurando que se integren de manera eficiente, y optimiza las etapas de procesamiento y transformación de los datos. Además, al estructurar correctamente el flujo de datos, se mejora la calidad del modelo, se minimizan errores, y se reducen tiempos y costos asociados a correcciones posteriores, lo que incrementa las probabilidades de éxito en la implementación de la solución.

- Valorar la representatividad de la población en los conjuntos de datos, y evaluar si se requiere contar con consentimiento para su procesamiento. En casos donde no existan suficientes datos, evaluar la adopción de técnicas como el aumento de datos para entrenar modelos de IA de manera efectiva.
- Estudiar los criterios propuestos para la selección de los modelos –la naturaleza del problema, el tipo y calidad de la información, la capacidad computacional, los indicadores de rendimiento y la explicabilidad, entre otros-. Comenzar con modelos simples y aumentar su complejidad según sea necesario. Esto facilitará el diseño, desarrollo y experimentación, hará posible incorporar ajustes en la medida en que se obtenga información de desempeño y retroalimentación de los usuarios, y evitará el desperdicio de recursos computacionales.
- Entender la importancia del desarrollo de la prueba de concepto, de los prototipos y del producto mínimo viable, como espacios de experimentación, aprendizaje y retroalimentación para la mejora continua de la solución.
- Otorgar relevancia al desarrollo de interfaces de usuarios amigables, que faciliten el uso de las aplicaciones por

parte de los miembros de la organización, incluido, si es el caso, del personal no especializado.

- Implementar procesos permanentes de vigilancia ética y de seguridad de la información desde el diseño. Esto implica monitorear de manera continua el uso de los datos, asegurar la privacidad de los usuarios y prevenir posibles sesgos en los modelos. Adicionalmente, establecer medidas de seguridad robustas para proteger la información sensible frente a ciberataques o accesos no autorizados.

Recomendaciones en la etapa de implementación, mantenimiento y escalamiento de la solución

- Definir e implementar indicadores de rendimiento como los señalados en el Capítulo 4 para evaluar el desempeño de la solución, así como la eficacia del modelo en la ejecución de su tarea específica y en el logro de los resultados esperados.
- Adelantar auditorías algorítmicas que proporcionen información relevante para asegurar que los modelos tengan el desempeño esperado, y que no generen resultados con implicaciones éticas no deseadas. En este

sentido, conviene que la validación de los modelos incluya mecanismos de respuesta para los casos en que los resultados no sean los esperados.

- Otorgar importancia a la explicabilidad y transparencia de los modelos. La capacidad de explicar cómo funcionan los modelos y sobre qué bases toman decisiones resulta esencial para la rendición de cuentas y la confianza en las soluciones de IA. Esto es especialmente crítico en el sector público, por la utilización de recursos del estado, por los requerimientos de rendición de cuentas, y por las implicaciones de las soluciones implementadas en el bienestar de la población
- Implementar estrategias de comunicación sobre la existencia de la herramienta, su funcionamiento y los resultados que esta genera para la organización.
- Evaluar y comunicar el retorno de la inversión relacionada con la adopción de las soluciones, con el fin de retroalimentar el proceso de desarrollo e implementación, y promover la adopción y continuidad de estas. En el mismo sentido, conviene que las áreas de la compañía logren interiorizar que la IA es de gran ayuda para evaluar hipótesis de mercado y reducir costos de inversión

u operación. Esto podrá asegurar flujos futuros que permitan contar con un presupuesto adecuado para su mantenimiento y mejora continua.

- Consolidar una cultura de experimentación y aprendizaje continuo, que habilite la innovación en cualquier área de la organización, y que contribuya a garantizar la sostenibilidad en la adopción de la solución. Al respecto, implementar un programa de transferencia de conocimiento es clave para que el proyecto continue iterando, para que se siga ajustando el modelo en sus diferentes etapas y para que las diferentes áreas relacionadas con el problema se apropien de la solución.
- Contar con un proceso continuo de control de calidad y de monitoreo del rendimiento del modelo que detecte desviaciones en los resultados, así como habilitar la incorporación de nuevos datos de entrada para anticipar los cambios del entorno.
- Mantener documentados los cambios que se realicen tanto del modelo como de la interfaz de usuario. Esto asegura un seguimiento claro de las modificaciones, facilita la colaboración entre equipos y permite identificar rápidamente el impacto de los ajustes en el rendimiento

del sistema y la experiencia del usuario. Para asegurar una documentación eficaz, se recomienda utilizar herramientas de control de versiones, que registre y rastree cada cambio realizado en el código. Además, se pueden emplear plataformas colaborativas para crear una base de conocimientos centralizada donde los equipos puedan describir en detalle las actualizaciones, mejoras y justificaciones de los cambios. Al respecto, es importante estructurar la documentación en secciones claras, que incluyan fechas, versiones y descripciones técnicas, de manera que cualquier miembro del equipo pueda consultar y entender el historial de modificaciones fácilmente.

- Asegurar la flexibilidad técnica y organizacional que permita la adaptación de las soluciones a los cambios en el entorno, así como a las nuevas regulaciones aplicables.
- Implementar acciones que habiliten la escalabilidad de la solución como la implementación de un sistema de monitoreo de rendimiento que alerte cuando el modelo se esté desactualizando, el aprovechamiento de la computación en la nube para poder escalar oportunamente las plataformas, y el uso de opciones tecnológicas para hacer más eficiente la operación de los modelos.

Las organizaciones en los sectores de infraestructura crítica en ALC tienen una oportunidad única de avanzar en la adopción de la inteligencia artificial como un medio para acelerar su transformación digital, y alcanzar mejores resultados en eficiencia operativa, productividad, satisfacción de los usuarios, sostenibilidad y contribución al desarrollo económico y social de los países. Para lograr estos beneficios es vital que los tomadores de decisiones comprendan plenamente el potencial e implicaciones de la IA, así como las oportunidades que ofrecen los casos de uso reales y las soluciones a problemas existentes. Además, resulta conveniente que estos líderes se familiaricen con las metodologías recomendadas para el desarrollo e innovación en IA, y que consideren los aspectos clave señalados para el desarrollo y adopción de este tipo de soluciones.

6

ANEXOS

Anexo 1. Revisión marcos regulatorios de IA en ALC

Un elemento relevante por considerar para la implementación exitosa de soluciones basadas en IA en sectores de infraestructura es el marco regulatorio aplicable. Este anexo presenta una revisión de los marcos regulatorios en ALC relacionados con el desarrollo y adopción de estas tecnologías. Específicamente, se realiza un análisis comparativo de los principales elementos de la normativa en materia de protección de datos en la región, así como de los desarrollos específicos que han implementado los países en términos de normatividad y lineamientos para el desarrollo y adopción de la IA.



Mediante la adopción de normativas y regulaciones sobre IA, cada país puede influir en el nivel de desarrollo de estas tecnologías a nivel nacional (TMG, 2020). De hecho, los marcos regulatorios determinan las posibles oportunidades que puede traer la adopción temprana y oportuna de IA para los individuos, las empresas y la sociedad, así como los riesgos asociados a la privacidad y a posibles prácticas discriminatorias, entre otras. Además, los marcos regulatorios pueden priorizar la puesta en práctica de algunos de los principios considerados fundamentales para la IA como lo son la imparcialidad, la privacidad, la responsabilidad y la transparencia.

El objetivo de este anexo es presentar una revisión de los marcos regulatorios sobre IA y protección de datos en once países de la región, en aspectos que pueden tener implicaciones para el desarrollo de soluciones basadas en esta tecnología en los sectores de infraestructura. El conjunto de países analizado está compuesto por: Argentina, Brasil, Chile, Colombia, Costa Rica, Ecuador, México, Panamá, Perú, República Dominicana, y Uruguay. Como se menciona en esta sección, la mayoría de los desarrollos regulatorios relacionados con IA en los países de la región se han implementado principalmente en el componente de privacidad y protección de datos. Así mismo, algunos gobiernos han

abordado las implicaciones éticas del uso de esta tecnología a partir de la formulación de principios, lineamientos o recomendaciones, antes que mediante la expedición de normas específicas. Adicionalmente, una práctica común de política pública en la región es la formulación de planes o estrategias nacionales orientadas a desarrollar los factores habilitantes para la adopción de esta tecnología en los gobiernos y diferentes sectores económicos.

Marcos regulatorios de protección de datos en IA

Un área de regulación que resulta determinante para el desarrollo e implementación de soluciones basadas en IA corresponde a los regímenes de protección de datos de los países. Estos regímenes definen las normas sobre la generación, el acceso, la recopilación, la gestión, el almacenamiento y procesamiento de los datos (TMG, 2020), que son el insumo fundamental para los desarrollos basados en IA. La **Tabla 1** presenta un resumen de los principales elementos de los marcos regulatorios existentes en materia de protección de datos en los once países de la región analizados. Algunos de los elementos considerados, que pueden resultar determinantes para el desarrollo de soluciones basadas en IA, son la existencia de requisitos con respecto al consentimiento de los titulares de los datos, el

registro en bases de datos, el procesamiento de datos por cuenta de terceros, la evaluación de impacto en privacidad, las restricciones a la transferencia internacional de datos, y los requerimientos de localización de datos.

Tabla 1. Marcos regulatorios de protección de datos en Latinoamérica

País	Principal Ley de Protección de Datos	Consentimiento del titular de los datos	Registro de bases de datos	Procesamiento de datos por cuenta de terceros	Obligaciones de evaluación de impacto en la privacidad	Restricciones a transferencia internacional de datos	Requerimiento de localización de datos
Argentina	Ley 25.326 de 2000	Si	Si	Si	No	Lista países	Sector financiero, contable, y laboral
Brasil	Ley 13.709 de 2018	Si	No	Si	Si	Lista países	Información estatal, pública, y financiera
Chile	Ley 19.628 de 1999	Si	Si	Si	No	NE	Sector bancario
	Ley 20.575 de 2012	Si	Si	Si	No	Lista países	Sector defensa
Colombia	Ley 1.581 de 2012	Si	Si	Si	Si	NE	NE
Costa Rica	Ley 8.968 de 2011	Si	Si	Si	Si	No	NE
	Reglamento 37.554-JP de 2013 a la Ley	Si	Si	Si	Si	NE	NE

País	Principal Ley de Protección de Datos	Consentimiento del titular de los datos	Registro de bases de datos	Procesamiento de datos por cuenta de terceros	Obligaciones de evaluación de impacto en la privacidad	Restricciones a transferencia internacional de datos	Requerimiento de localización de datos
Ecuador	Ley Orgánica de 2021	Si	Si	Si	Si	Lista países	Datos reservados del Estado y por seguridad nacional (Ley Fintech)
México	Nueva Ley Federal DOF 05-07-2010	Si	No	Si	Si	NE	En casos de seguridad nacional e información pública
Panamá	Ley 81 de 2019	Si	No	Si	Si	Lista países	NE
Perú	Ley 29.733 de 2011	Si	Si	Si	No	Lista países	No
República Dominicana	Ley 172 de 2013	Si	No	Si	No	Lista países	NE
Uruguay	Ley 18.331 de 2008	Si	Si	Si	Si	Lista países	Para riesgos en administración central y regulación sectorial como la bancaria

Fuente: EY (2023), IAPP Research and Insights (2024), & Centro LATAM Digital (2022), Baker McKenzie - actualizado entre diciembre 2023 y enero 2024, Asamblea Nacional República del Ecuador (2022).

NE: No especificado

Como se observa, los once países examinados cuentan con regímenes de protección de datos expedidos mediante leyes nacionales. Los primeros países en implementar este tipo de regímenes fueron Chile y Argentina en 1999 y 2000, mientras que Ecuador es el país que implementó este régimen de manera más recientemente, en 2021. En todos estos países los regímenes exigen contar con el consentimiento del titular de los datos como medida de protección de estos. Sin embargo, hay circunstancias bajo las cuales no es necesario el consentimiento en estos países. Algunas de estas están asociadas a que los datos sean de acceso público, estén anonimizados, o a que su procesamiento obedezca a requerimientos legales, entre otros (EY, 2023).

De otra parte, en siete de los once países analizados se requiere el registro de las bases de datos ante la autoridad respectiva, así como entregar informes relacionados de manera periódica (EY, 2023). Los países con este requerimiento son Argentina, Chile, Colombia, Costa Rica, Ecuador, Perú y Uruguay. En el caso de Chile, dicho registro es requerido para la información recopilada por entidades públicas.

Otro de los aspectos analizados en el marco regulatorio de protección de datos es la habilitación para el procesamiento

de datos por cuenta de terceros. En todos los once países analizados dicho procesamiento es permitido. En algunos países como Argentina y Costa Rica aspectos como la finalidad y el cumplimiento de ciertas condiciones son fundamentales, mientras que en otros como Ecuador el alcance del procesamiento debe estar determinado contractualmente (EY, 2023).

Adicionalmente, los marcos regulatorios en protección de datos consideran la exigencia de implementar ejercicios de evaluación de impacto en privacidad o *Privacy Impact Assessment* en inglés. Esta obligación exige que el agente a cargo del tratamiento de los datos o su responsable realice una evaluación con respecto a la protección de estos en virtud de los riesgos asociados a aspectos como los derechos y libertades (Comisión Europea, 2012). Este requerimiento existe en seis de los once países de la región analizados: Brasil, Costa Rica, Ecuador, México, Panamá, y Uruguay.

Finalmente, los marcos regulatorios de la región en protección de datos incluyen consideraciones sobre la transferencia internacional de datos, y en algunos casos existen ciertos requerimientos de localización de datos en los territorios nacionales. Al menos ocho países de la región han incorporado restricciones a la transferencia internacional

de datos, consistentes en que dichas transferencias pueden realizarse solo a aquellos con niveles de protección de los datos similares o superiores (EY, 2023), y en este sentido han definido listas de países a los que los datos pueden ser transferidos. Otros países como Costa Rica no cuentan con estas restricciones, mientras que Chile y México no las especifican. De otra parte, en países como Argentina, Brasil, Chile, Colombia, Ecuador, México, y Uruguay existen requerimientos de localización de datos en sectores específicos como el financiero el de defensa, o en relación con los datos estatales. En Perú no existen este tipo de restricciones, mientras que en Costa Rica, Panamá y República Dominicana las leyes no especifican este tipo de restricciones.

Marcos regulatorios sobre IA

El segundo de los marcos regulatorios considerado es el de IA en la región²⁰³. En particular, se presenta una revisión de los desarrollos que han implementado los países en normas o guías para la IA en aspectos éticos, protección de datos, transparencia, así como políticas o normas específicas de IA. La **Tabla 2** presenta los resultados de la revisión para

203 Revisión propia con base en Accessnow (2024), OECD-CAF (2022) y TMG (2020).

los nueve países en los que se identificaron desarrollos específicos de normas o lineamientos en esta materia. La existencia de estas normas o guías evidencia el nivel de esfuerzo en la búsqueda por equilibrar la innovación que trae IA y los posibles riesgos asociados (IAPP Research and Insights, 2024).

Como se observa, en seis países de los nueve seleccionados se identificaron normas o guías relacionadas con aspectos éticos de IA. Este es el caso de Argentina, Chile, Colombia, Costa Rica, México y Perú. En cada uno de estos países existen guías o normas enfocadas en los aspectos éticos. Existen también documentos dedicados a los aspectos éticos como la *Formulación ética de proyectos en ciencia de datos* en Chile y el *Marco ético para la IA* en Colombia, así como un documento elaborado por agencias públicas, INTEL y el BID sobre la importancia de contar con unos lineamientos éticos en IA en Costa Rica, y un decreto con una sección sobre el uso ético de la IA en Perú. Otras guías cuentan con secciones sobre elementos éticos a considerar, con propuestas éticas o con las exigencias éticas para licitaciones en países como Argentina, Chile, Colombia, y México.

Así mismo, en seis países se identificaron normas o guías específicas de protección de datos para las soluciones de

IA, que son adicionales a las mencionadas en los marcos regulatorios de protección de datos en IA (**Tabla 1**). Los países que cuentan con este tipo de documentos son: Argentina, Brasil, Chile, Colombia, México y Uruguay. En el caso de Argentina, Brasil, Chile y México, estos documentos son anexos de una norma, secciones específicas con lineamientos y sugerencias dentro de documentos oficiales, o publicaciones de las entidades encargadas. Otro tipo de documentos expedidos por países como Brasil, Colombia, México y Uruguay incluyen procesos participativos, documentos realizados por la sociedad civil, y sandboxes asociados con protección de datos.

De otra parte, en tres países de la región se identificó la existencia de normas o guías de transparencia para las soluciones de IA: Argentina, Chile y Colombia. En estos casos, solo en Argentina se encontró un documento específico para el programa de transparencia, mientras que en Chile estas guías hacen parte de los lineamientos generales, y en Colombia la referencia a aspectos de transparencia es parte de una sección de una hoja de ruta de IA.

Por último, se identificó la existencia de políticas o normas específicas de IA en ocho países de la región. Específicamente, en Brasil, Chile y en Perú las estrategias de IA se han elevado al nivel de norma -Ordenanza en Brasil, decreto en Chile, Ley en Perú-, mientras que en los demás países estas estrategias y hojas de rutas están consignadas en documentos de política.

Tabla 2. Marcos regulatorios de IA en Latinoamérica

País	Normas o guías sobre soluciones de IA en los siguientes aspectos			
	Aspectos éticos	Protección de datos	Transparencia	Políticas o normas específicas de IA
Argentina	<i>Recomendaciones para una IA Fiable</i> (Jefatura Gabinete y Secretaría de Innovación Pública, 2023)	<i>Programa de transparencia y protección datos personales en uso IA – anexo de Resolución</i> (Agencia de Acceso a la Información Pública, 2023)		<i>Plan Nacional de Inteligencia Artificial</i> (Presidencia de la Nación, 2019)
Brasil	ND	<i>Análisis Preliminar Proyecto de Ley 2338</i> (ANDP ¹ , 2023)	ND	<i>Estrategia Nacional IA</i> (Ordenanza, 2021)
Chile	<i>Formulación ética proyectos ciencias de datos</i> (División Gobierno Digital Chile, Universidad Adolfo Ibáñez y BID Lab, 2022)	<i>Lineamientos para uso de herramientas de IA en sector público</i> (Ministerio Secretaría General de la Presidencia y Ministerio de Ciencia, Tecnología, Conocimiento e Innovación, 2023)		<i>Política Nacional de IA</i> (Decreto, 2021)
	<i>Bases Tipo licitar proyectos de IA con requisitos éticos</i> (Dirección de Compras y Contratación Pública – ChileCompra, 2023)			

País	Normas o guías sobre soluciones de IA en los siguientes aspectos			
	Aspectos éticos	Protección de datos	Transparencia	Políticas o normas específicas de IA
Colombia	<i>Marco Ético para IA</i> (Gobierno de Colombia, CAF y BID, 2021)	<i>Sandbox privacidad en proyectos de IA</i> (SIC ² , Gobierno de Colombia y Consejería Presidencial para asuntos económicos y transformación digital, 2020)	<i>Hoja de Ruta Desarrollo y aplicación de la IA</i> (Minciencias, 2024)	<i>Política nacional para la transformación digital e inteligencia artificial – Documento CONPES</i> (DNP, 2019)
	Hoja de Ruta Desarrollo y aplicación de la IA (Minciencias, 2024)			
Costa Rica	<i>Apoyo para el uso responsable y ético de IA</i> (MICITT, CINDE, BID e INTEL, 2021)	ND	ND	ND
	<i>Iniciativa para regulación ética IA PAN – en proceso</i> (Ignacio Loyola, 2023)	<i>Recomendaciones tratamiento datos personales uso IA (INAI³, 2022)</i>	ND	<i>Estrategia IA-MX</i> (Coordinación de Estrategia Digital Nacional, 2018)
México	<i>Agenda Nacional Mexicana de Inteligencia Artificial</i> (Coalición IA2030MX, 2020)			

País	Normas o guías sobre soluciones de IA en los siguientes aspectos			
	Aspectos éticos	Protección de datos	Transparencia	Políticas o normas específicas de IA
Perú	<i>Estrategia Nacional de IA</i> (Secretaría de Gobierno y Transformación Digital y Presidencia de Consejo de Ministros, 2021)	ND	ND	<i>Ley que promueve uso de IA en favor desarrollo</i> (Ley, 2023)
	<i>Marco confianza digital - Uso</i> ético tecnologías y datos (Decreto, 2020)			
República Dominicana	ND	ND	ND	<i>Estrategia Nacional de IA</i> (OGTIC, Dirección Ejecutiva Gabinete de innovación y Desarrollo Digital, 2023)
Uruguay	ND	<i>Estrategias de IA y Datos – en</i> proceso la participación pública (AGESIC, CAF y UNESCO, 2023-2024)	ND	<i>Estrategia de IA para el Gobierno Digital</i> (AGESIC, Presidencia, 2019)

Fuente: Accessnow (2024), OECD-CAF (2022), & TMG (2020).

Nota: No incluye proyectos de ley.

¹ ANDP: Autoridad Nacional de Protección de Datos de Brasil.

² SIC: Superintendencia de Industria y Comercio de Colombia.

³ INAI: Instituto Nacional de Transparencia, Acceso a la Información y Protección de Datos Personales de México

Recomendaciones de política

Los formuladores de política de ALC tienen un rol significativo en la consolidación de marcos de política y regulación que habiliten y promuevan la adopción de la IA en los sectores de infraestructura. A continuación, se presentan cinco líneas de acción principales en las que los gobiernos de la región pueden avanzar en la consolidación de estos marcos habilitadores. Estas líneas se plantean con base en la revisión de las experiencias internacionales, en las entrevistas realizadas a expertos en el desarrollo e implementación de este tipo de soluciones, y en la revisión comparativa de marcos regulatorios de IA en ALC, cuyos principales resultados se presentan en el Anexo.

Marcos regulatorios en datos e IA modernos, eficientes y estables

Los marcos regulatorios de los países en materia de protección de datos y en IA configuran entornos normativos que pueden habilitar o inhibir el desarrollo y adopción de esta tecnología en sectores económicos, incluidos los de infraestructura. En términos generales, estos marcos se configuran como habilitadores cuando logran promover simultáneamente el logro de objetivos de política diferentes, y

aparentemente contradictorios, como la privacidad y seguridad de la información sensible y el avance de la innovación tecnológica como factor de competitividad, productividad y transformación digital. Los marcos regulatorios robustos permiten alcanzar balances en los que se pueden cumplir simultáneamente estos dos objetivos, y por esta vía, inducen a las sociedades a avanzar hacia mejores estados de bienestar.

En el caso de los regímenes de protección de datos, existentes en la mayoría de países de la región, resulta relevante que los países avancen en la modernización de dichos regímenes sin incorporar restricciones adicionales al procesamiento de datos que no estén soportadas en la evidencia, así como requisitos de localización de datos más allá de casos sensibles o de seguridad nacional, que puedan crear barreras a la adopción de servicios de nube para el desarrollo e implementación de soluciones de IA en sectores económicos, incluidos los de infraestructura.

Así mismo, en la medida en que la adopción generalizada de la IA en sectores económicos es un fenómeno relativamente reciente, conviene que los gobiernos desarrollen espacios de aprendizaje y experimentación sobre las implicaciones regulatorias de esta adopción, antes de definir marcos legislativos o regulatorios específicos y rígidos que puedan

incorporar barreras a dicha adopción. En este sentido, resulta una buena práctica, como lo han implementado la mayoría de los países de la región, el enfoque inicial de derecho blando (*Soft Law*) basado en la formulación de lineamientos y guías para la implementación responsable de esta tecnología. Otra práctica a considerar es la implementación de espacios de experimentación regulatoria (*sand boxes regulatorios*) para la adopción de IA -como se ha realizado en múltiples casos a nivel internacional para el sector financiero-, en sectores altamente regulados, entre los que podrían considerarse algunos pertenecientes a sectores de infraestructura.

Marcos regulatorios sectoriales habilitadores de la innovación

En el mismo sentido, para avanzar en la adopción de la IA en los sectores de infraestructura, resulta conveniente que los marcos regulatorios sectoriales de estos sectores no incorporen elementos que puedan restringir o desincentivar la innovación orientada a objetivos como el avance en eficiencia y productividad, o la incorporación de nuevos modelos de negocio. Por ejemplo, en los sectores con presencia de empresas de servicios públicos (energía, y agua y saneamiento) las regulaciones tarifarias rígidas pueden generar desincentivos a la implementación de iniciativas orientadas a la reducción de costos. Por su parte, en el sector

transporte, las regulaciones tradicionales pueden crear barreras a la incorporación de nuevas modalidades de servicio, como aquellas basadas en plataformas tecnológicas. En este sentido, se recomienda a los formuladores de política en estos sectores consolidar marcos de política flexibles que reconozcan la innovación tecnológica como factor de desarrollo sectorial.

Políticas efectivas en desarrollo de capital humano y capacidades sectoriales

Como se ha señalado a lo largo del documento, el desarrollo de capacidades es un factor fundamental para la adopción de la IA en los sectores de infraestructura de la región. De una parte, algunas organizaciones en sectores tradicionales como el de transporte o el de agua y saneamiento tradicionalmente han sido adoptantes tardíos de innovaciones tecnológicas, por lo que la implementación de soluciones basadas en IA les plantea retos culturales y de capacidades técnicas para el desarrollo e implementación de este tipo de soluciones. De otra parte, en general, las organizaciones de los sectores de infraestructura requerirán contar con nuevas capacidades, conjuntos de habilidades y cambios culturales para poder adoptar y aprovechar las oportunidades que ofrece una tecnología emergente de uso generalizado reciente, como

lo es la IA. En este sentido, cobra vital importancia que los gobiernos implementen políticas efectivas de capital humano y desarrollo de capacidades que contribuyan al cierre de brechas en los países para la adopción de esta tecnología. Para esto, el apoyo a la educación superior, la colaboración público-privada en desarrollo de capacidades, y los programas nacionales de preparación de la fuerza de trabajo para la adopción de IA podrán tener un impacto relevante en estos sectores.

Promoción de ecosistemas de innovación tecnológica

La adopción de IA en sectores económicos como los de infraestructura también es impulsada por los ecosistemas locales de innovación tecnológica, compuestos por diferentes actores como emprendedores, empresas tecnológicas, sector privado, academia y gobierno, y sus interrelaciones, los cuales aceleran dinámicas de innovación que impulsen el desarrollo de soluciones tecnológicas basadas en IA para estos sectores. Los gobiernos tienen un rol relevante en la promoción de estos ecosistemas, mediante la definición e implementación de políticas públicas que aborden los determinantes del desarrollo de estos ecosistemas, en aspectos como la regulación, el financiamiento, el capital humano, la infraestructura tecnológica y el comercio, entre otros.

Adicionalmente, el Estado tiene un papel dinamizador de la innovación tecnológica como comprador de tecnología, mediante la implementación de nuevas modalidades de compra pública, como los programas de compra pública innovadora; estos programas pueden hacerse igualmente extensivos a las empresas de servicios públicos (*utilities*) con participación de capital estatal.

Comunicación de oportunidades, mejores prácticas y casos de éxito

Finalmente, los gobiernos de la región impulsan la adopción de la IA en sectores, incluidos los de infraestructura, mediante políticas e iniciativas que comuniquen e informen a los actores económicos sobre las oportunidades existentes para el avance en productividad, competitividad y bienestar a partir de la adopción de la IA, así como sobre las mejores prácticas y casos de éxito existentes en los países y a nivel internacional. De igual manera, la existencia de marcos regulatorios modernos en seguridad digital y de lineamientos en uso responsable de la IA y aspectos éticos relacionados, podrá contribuir en la consolidación de la confianza de estos actores y de los ciudadanos en el uso y adopción de esta tecnología.

Anexo 2.

Metodología de las entrevistas

Tipo de entrevistas	Objetivo y alcance	Duración	Medio	Perfil de los entrevistados	Número de entrevistas	Fecha de las entrevistas
Semiestructuradas ²⁰⁴ . Se dado siguió la Guía de Entrevistas presentada a continuación. Igualmente, se realizaron preguntas adicionales según las particularidades de cada entrevista y del perfil de cada entrevistado.	Conocer la perspectiva de entrevistados sobre el potencial de la IA para los sectores de infraestructura, y las principales consideraciones y recomendaciones para la adopción exitosa de esta tecnología en dichos sectores en ALC. Así mismo, conocer las lecciones aprendidas de la experiencia de los entrevistados en casos específicos de desarrollo de estas soluciones.	30 – 60 minutos	Virtual con la presencia de funcionarios del BID.	Miembros de los equipos técnicos del BID, clientes y actores externos con experiencia en el desarrollo y la implementación de soluciones de tecnologías emergentes e IA.	17	Marzo y abril, 2024

204 Longhurst, R. (2003). "Semi-structured Interviews and Focus Groups". *Key Methods in Geography*.

Guía de entrevistas

Información sobre el caso analizado

- ¿Cuál es el problema/necesidad que busca resolver la solución, y cómo fue el proceso de entendimiento y diagnóstico de dicho problema/necesidad?
- ¿En qué consiste la solución implementada y cuáles son sus principales objetivos y características?
- ¿Qué tipo de modelo(s) de IA se implementó (implementaron) en el desarrollo de la solución y con qué tipo de datos?
¿Cómo se tomaron las decisiones sobre la escogencia del (de los) modelos y los datos a utilizar?
- ¿Qué ventajas/desventajas quisiera resaltar del modelo de IA utilizado en términos de sus atributos? (ej Usabilidad, escalabilidad, testeabilidad, interpretabilidad, adaptabilidad, precisión/rendimiento, seguridad?)
- Describa brevemente como fue el proceso de desarrollo e implementación de la solución.
- ¿Qué actores internos y externos al BID han intervenido en el desarrollo e implementación de la solución, y cómo ha sido la interacción con/entre ellos?
- ¿Qué avances o resultados se han tenido a la fecha en la implementación de esta solución? ¿qué nivel de apropiación ha tenido por parte de los beneficiarios?
- ¿Qué desafíos o dificultades encontró el equipo en el desarrollo e implementación de la solución y cómo los enfrentó/solucionó?
- ¿Cuáles son las principales lecciones aprendidas a partir del desarrollo e implementación de esta solución, que podrán ser útiles para fortalecer los procesos de desarrollo e implementación de soluciones de IA en este sector a futuro?

Entendimiento del potencial de IA en infraestructura

- En su opinión, ¿cuáles son las principales oportunidades y ventajas que puede traer la adopción de IA a los sectores de infraestructura en ALC?
- Además de la solución discutida previamente, ¿tiene conocimiento de otros desarrollos²⁸ o soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) a nivel global o en ALC que tengan un alto potencial? ¿cuáles son?

Guía de entrevistas

Consideraciones para la adopción de IA en infraestructura
Recomendaciones para los formuladores de políticas

- Desde su experiencia, ¿Cuáles son los principales factores de éxito de los procesos de desarrollo y adopción de soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) en ALC?
- Desde su experiencia, ¿Cuáles son los principales grupos de interés que deben ser considerados en el desarrollo y adopción de soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) en ALC, y cómo deben ser vinculados efectivamente en estos procesos?

Preguntas adicionales opcionales:

- Desde su experiencia, ¿cuáles son las principales consideraciones en aspectos éticos que deben tenerse en cuenta para el desarrollo y adopción de soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) en ALC?
- Desde su experiencia, ¿cuáles son las principales consideraciones en aspectos legales, regulatorios o institucionales que deben tenerse en cuenta para el desarrollo y adopción de soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) en ALC?
- Desde su experiencia, ¿cuáles son las principales consideraciones en aspectos técnicos, de procesamiento de datos, y de seguridad que deben tenerse en cuenta para el desarrollo y adopción de soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) en ALC?
- Desde su experiencia, ¿cuáles son las principales consideraciones en desarrollo de capacidades que deben tenerse en cuenta para el desarrollo y adopción de soluciones de IA en el sector de (Transporte, Energía, Agua o Saneamiento) en ALC?

- ¿Cuáles considera que son los principales cuellos de botella que deben abordar los países de ALC para el desarrollo e implementación exitosos de proyectos de IA en sectores de infraestructura?
- ¿Cuáles son las principales recomendaciones que haría a los formuladores de política de la región para impulsar el desarrollo e implementación exitosos de proyectos de IA en sectores de infraestructura?

Referencias

1. Abdalla, A. N., Nazir, M. S., Tao, H., Cao, S., Ji, R., Jiang, M., & Yao, L. (2021). Integration of energy storage system and renewable energy sources based on artificial intelligence: An overview. *Journal of Energy Storage*, 40, 102811. <https://doi.org/10.1016/j.est.2021.102811>
2. Accessnow (2024). Radiografía normativa: ¿dónde, qué y cómo se está regulando la inteligencia artificial en América Latina.
3. Ahmad, T., Zhu, H., Zhang, D., Tariq, R., Bassam, A., Ullah, F., AlGhamdi, A. S., & Alshamrani, S. S. (2022). Energetics Systems and artificial intelligence: Applications of industry 4.0. *Energy Reports*, 8, 334–361. <https://doi.org/10.1016/j.egyr.2021.11.256>
4. Alarcón, A. (2018). Pérdidas eléctricas: tres tendencias tecnológicas que pueden ayudar a resolver el problema. Blogs IADB. Disponible en: <https://blogs.iadb.org/energia/es/perdidas-electricas-tres-tendencias-tecnologicas-que-pueden-ayudar-a-resolver-el-problema/>
5. Alvarez, O., Díaz Echeverría, A., Pérez, N.A., Sánchez Campos, A., & Bordiu García-Ovies, C. Hoja de ruta para la transformación digital del sector energético en América Latina y el Caribe. Nota técnica IDB-TN-02833. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0005215>
6. Arch, A., Cortijo, R., Romero, E., Canga, E., Furrer, P., Woodhouse, S., Dulle, H., & Koller, T. (2020). La revolución digital de la energía hidroeléctrica en los países latinoamericanos. Nota técnica No. IDB-TN-01761. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0001989>
7. Asamblea Nacional República del Ecuador (2022). Ley orgánica para el desarrollo, regulación y control de los servicios financieros tecnológicos (Ley fintech).
8. Ávalos, R. S., González, F., & Ortiz, T. (2021). Uso responsable de la IA para las políticas públicas: Manual de ciencia de datos. *IDB Publications*. <https://doi.org/10.18235/0002876>
9. Banco Mundial. (2020). *Artificial Intelligence in the Public Sector*. <https://documents1.worldbank.org/curated/en/74672161604533426/pdf/Artificial-Intelligence-in-the-Public-Sector-Summary-Note.pdf>
10. Baker McKenzie (2024). Global Data Privacy and Cybersecurity Handbook. (Actualizado entre diciembre 2023 y enero 2024). <https://resourcehub.bakermckenzie.com/en/resources/global-data-privacy-and-cybersecurity-handbook/comparison?j=1dd6a01b-0da5-46a1-b9a1-59a294a80f85&n=Global+Data+Privacy+and+Cybersecurity+Handbook>
11. Banerjee, S., Kabir, Md. M., Khadem, N. K., & Chavis, C. (2020). Optimal locations for bikeshare stations: A new GIS based spatial approach. *Transportation Research Interdisciplinary Perspectives*, 4, 100101. <https://doi.org/10.1016/j.trip.2020.100101>
12. Barrero, V., & Bou, O. (2020). Estado de preparación en ciberseguridad del sector eléctrico en América Latina: Diagnóstico, recomendaciones y guía de buenas prácticas. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0002344>
13. Basani, M. (2023). El poder de ChatGPT para elaborar políticas públicas innovadoras. Blogs IADB. Disponible en: <https://blogs.iadb.org/agua/es/ aprovechar-el-poder-de-chatgpt-para-elaborar-politicas-publicas-innovadoras/>
14. Basani, M. (2023). Tecnologías inteligentes de residuos sólidos: ¿Dónde estamos y hacia dónde vamos? Blogs IADB. Disponible en: <https://blogs.iadb.org/agua/es/tecnologias-inteligentes-de-residuos-solidos-donde-estamos-y-hacia-donde-vamos/>
15. Bedi, J., & Toshniwal, D. (2019). Deep learning framework to forecast electricity demand. *Applied Energy*, 238, 1312–1326. <https://doi.org/10.1016/j.apenergy.2019.01.113>
16. Bengio, Y., LeCun, Y., & Hinton G. (2021). Deep Learning for AI. *Communications of the ACM*, 64(7), 58-65. <http://dx.doi.org/10.1145/3448250>
17. BID – Código para el Desarrollo. (s.f). Trampas Barceló. <https://code.iadb.org/es/herramientas/trampas-barcelo>
18. BID (2021). Robot Laura Auditoría Algorítmica: Estudio sobre el sistema Laura de predicción de riesgo de deterioro clínico. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0003919>
19. BID (2024). Digital Transformation of Solid Waste Management: Waste collection innovation, Business intelligence, and Digital technologies to transition waste management towards circularity in Latin America and the Caribbean.
20. BID fAIr LAC. Acuadata. Recuperado de: <<https://fairlac.iadb.org/piloto/acuadata>>. Entrevistas al equipo de trabajo de EPMAPS y del BID.
21. BID fAIr LAC. Pavimenta2. Recuperado de: <<https://fairlac.iadb.org/piloto/pavimenta2>>
22. BID fAIr LAC. Víasegura <<https://fairlac.iadb.org/piloto/viasegura>>
23. BID. (2022, marzo 17). VíaSegura: soluciones digitales para la seguridad vial. [Video]. YouTube. <https://www.youtube.com/watch?v=zTKE1yqwrl>.
24. BID. (2023, abril 28). VíaSegura: Technology to save lives.[Video]. YouTube. <https://www.youtube.com/watch?v=pUnPVxPqhY4>,
25. BID. (2023, agosto 18). Pavimenta2: la tecnología definitiva para las carreteras de América Latina y el Caribe [Video]. YouTube. <https://www.youtube.com/watch?v=cuOw4OPIKgl>.
26. BID. (2023, febrero 24). Webinar Inteligencia Artificial para crear y disseminar Políticas Públicas [Video]. YouTube. <https://www.youtube.com/watch?v=zB1P9p9pR00> (40:21, 46:17, y 50:28).
27. BID. Energizados, una herramienta para automatizar la detección de fraudes eléctricos. <https://blogs.iadb.org/energia/es/energizados-la-deteccion-de-fraudes-electricos/>

28. BID. Energizados. <<https://fairlac.iadb.org/piloto/energizados>>

29. BID. Pavimenta2: Acelerando la transformación digital del sector Transporte en América Latina y El Caribe. (2022, septiembre). Recuperado de: <<https://blogs.iadb.org/transporte/es/pavimentados-acelerando-la-transformacion-digital-del-sector-transporte-en-america-latina-y-el-caribe/>>

30. BID. Pavimenta2: infraestructura digital al servicio de los activos viales. (2023, agosto). Recuperado de: <<https://blogs.iadb.org/transporte/es/pavimenta2-infraestructura-digital-al-servicio-de-los-activos-viales/>>

31. BID. Pavimentados. Recuperado de: <<https://code.iadb.org/es/herramientas/pavimentados>>

32. BID. ViaSegura - Resumen ejecutivo. <https://resources.irap.org/Key-documents/Resumen_ejecutivo_VíaSegura.pdf?_gl=1*19gnjtl*_ga*MTA2Njc3NDI5MC4xNzEwODY3Mjc1*_ga_K6PSM29PR*MTcxMDg2NzI3NC4xLjEuMTcxMDg2NzMzNS4wLjAuMA..>

33. BID. Víasegura <<https://code.iadb.org/es/herramientas/viasegura>>

34. BID. ViaSegura: Inteligencia Artificial aplicada a la mejora de la seguridad vial - Folleto <https://resources.irap.org/Key-documents/VíaSegura_iRAP.pdf?_gl=1*19gnjtl*_ga*MTA2Njc3NDI5MC4xNzEwODY3Mjc1*_ga_HK6PSM29PR*MTcxMDg2NzI3NC4xLjEuMTcxMDg2NzMzNS4wLjAuMA..>

35. Boukerche, A., Tao, Y., & Sun, P. (2020). Artificial intelligence-based vehicular traffic flow prediction methods for supporting intelligent transportation systems. *Computer Networks*, 182, 107484. <https://doi.org/10.1016/j.comnet.2020.107484>

36. Bowles, C., Chen, L., Guerrero, R., Bentley, P., Gunn, R., Hammers, A., Dickie, D. A., Hernández, M. V., Wardlaw, J., & Rueckert, D. (2018). GAN Augmentation: Augmenting Training Data using Generative Adversarial Networks. <https://doi.org/10.48550/arXiv.1810.10863>

37. Brynjolfsson, E., Li, D., & Raymond, L. R. (2023). *Generative AI at Work* (Working Paper 31161). National Bureau of Economic Research. <https://doi.org/10.3386/w31161>

38. Brzezinski, I. A. (2023). Integración de soluciones innovadoras en los servicios de agua y saneamiento: Lecciones de proyectos piloto de innovación en América Latina y el Caribe. *IDB Publications*. <https://doi.org/10.18235/0005236>

39. Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249–259. <https://doi.org/10.1016/j.neunet.2018.07.011>

40. Calatayud, A., Benítez, C., Leaño, J.M., Agosta, R., Blas, F., Goytia, C., Guilera, S., Riobó Patino, A., Navas Duk, C., Freytes, C., & Rodríguez Tourón, F. (2020). Vehículos Autónomos: Una revisión bibliográfica sobre su impacto en la movilidad de las ciudades en la región. Nota técnica IDB-TN-1929. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0002491>

41. Calatayud, A., Benítez, C., Leaño, J.M., Agosta, R., Blas, F., Goytia, C., Guilera, S., Riobó Patino A., Navas Duk, C., Freytes, C., & Rodríguez Tourón, F. (2020). Vehículos Autónomos: Resultados de la encuesta Delphi sobre su impacto y adopción en ciudades de América Latina y el Caribe. Nota técnica IDB-TN-1930. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0002486>

42. Calatayud, A., Katz, R. (2019). Cadena de suministro 4.0: Mejores Prácticas Internacionales y Hoja de Ruta para América Latina. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0001956>

43. Calatayud, A., Katz, R., & Riobó, A. (2022). Impulsando la transformación digital del transporte en América Latina y el Caribe. *IDB Publications*. <https://doi.org/10.18235/0004233>

44. Calatayud A., Riobó A., Irigoyen J., Basani M., Unzueta A., Katz R. (2022). *Estrategia de Transformación Digital para el Sector de Infraestructura y Energía 2021-2025*. Documento para Discusión No. IDB-DP-00935. Banco Interamericano de Desarrollo (BID).

45. Calatayud A., Rivas M., Camacho J., Beltrán C., Ansaldo M., Café E. (2023). Transporte 2050: El camino hacia la descarbonización y la resiliencia climática en América Latina y el Caribe. Banco Interamericano de Desarrollo.

46. Calatayud, A., Sánchez González, S., Bedoya Maya, F., Giraldez Zúñiga, F., & Márquez, J. M. (2021). *Congestión urbana en América Latina y el Caribe: Características, costos y mitigación*. Inter-American Development Bank. <https://doi.org/10.18235/0003149>

47. Castelli, M., Groznik, A., & Popović, A. (2020). Forecasting Electricity Prices: A Machine Learning Approach. *Algorithms*, 13(5), 119. <https://doi.org/10.3390/a13050119>

48. Centro LATAM Digital (2022). Políticas de Competencia y Protección de Datos Personales Perspectivas para América Latina.

49. Cevallos, A., Latorre, L., Alicandro, G., Wanner, Z., Cerrato, I., Zarate, J. D., Alvarez, J., Villacreses, K., Pfeifer, M., Gutierrez, M., Villanueva, V., Rivera-Fournier, A., Riobó, A., Pombo, C., Puerto, F., & Rodríguez Breuning, J. (2023). Tech Report: IA generativa. *IDB Publications*. <https://doi.org/10.18235/0005105>

50. Chan, W. C., Wan Ibrahim, W. H., Lo, M. C., Suaidi, M. K., & Ha, S. T. (2020). Sustainability of Public Transportation: An Examination of User Behavior to Real-Time GPS Tracking Application. *Sustainability*, 12(22), 9541. <https://doi.org/10.3390/su12229541>

51. Chen, H., Chen, A., Xu, L., Xie, H., Qiao, H., Lin, Q., & Cai, K. (2020). A deep learning CNN architecture applied in smart near-infrared analysis of water pollution for agricultural irrigation resources. *Agricultural Water Management*, 240, 106303. <https://doi.org/10.1016/j.agwat.2020.106303>

52. Chen, P., Wang, B., Wu, Y., Wang, Q., Huang, Z., & Wang, C. (2023). Urban river water quality monitoring based on self-optimizing machine learning method using multi-source remote sensing data. *Ecological Indicators*, 146, 109750. <https://doi.org/10.1016/j.ecolind.2022.109750>

53. Chung S., Zhang Y. (2023). Artificial Intelligence Applications in Electric Distribution Systems: Post-Pandemic Progress and Prospect. *Appl. Sci.* 2023, 13(12), 6937.

54. Comisión Económica para América Latina y el Caribe - CEPAL. (2011). Caracterización de la brecha de infraestructura económica en América Latina y el Caribe.

55. Comisión Europea (2012). Propuesta de Reglamento del Parlamento Europeo y del Consejo relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos (Reglamento general de protección de datos). <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2012:0011:FIN:ES:PDF>

56. Consejería Presidencial para asuntos económicos y transformación digital. (2020). *Proyectos de Transformación Digital, Trámites y Servicios para el ciudadano*.

57. Daigger G.T., Voutchkov, N., Lall U., & Sarni, W. (2019). The Future of Water: A collection of essays on "disruptive" technologies that may transform the water sector in the next 10 years. Discussion Paper No. IDB-DP-657. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0001666>

58. Del Real, A. J., Dorado, F., & Durán, J. (2020). Energy Demand Forecasting Using Deep Learning: Applications for the French Grid. *Energies*, 13(9), 2242. <https://doi.org/10.3390/en13092242>

59. Deloitte (2023). AI around the world - Case Study: Digital twin gives San Diego options in tackling traffic congestion. [https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/#digital-twin-gives-san-diego](https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/%20-%20digital-twin-gives-san-diego.html/#digital-twin-gives-san-diego)

60. Deloitte (2023). AI around the world - Case Study: Dubai Electricity and Water Authority chatbot answers customer queries on many platforms. <https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/#dubai-electricity-and-water-authority>

61. Deloitte (2023). AI around the world - Case Study: Transport Canada uses AI to identify risky cargo. <https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/#transport-canada-uses-ai-to>

62. Deloitte (2023). AI around the world - Case Study: US cities use analytics to deploy snowplows and garbage trucks efficiently. <https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/#us-cities-use-analytics-to>

63. Deloitte AI Institute (2023). The AI Dossier. <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/deloitte-analytics/us-ai-institute-ai-dossier-full-report.pdf>

64. Deloitte - AI Institute. (2021). The AI Dossier.

65. Desai, R., Jadhav, A., Sawant, S., & Thakur, N. (2021). *Accident Detection Using ML and AI Techniques*.

66. Dyba T., Dingsoyr. (2009). What do we know about agile software development? *IEEE Software*.

67. Engelhardt, S., McClelland, J. & Collet, S. (s.f.). What Generative AI Can Do for Utilities. <https://www.sap.com/insights/viewpoints/what-generative-ai-can-do-for-utilities.html>

68. Eno Center for Transportation. (2023). Understanding AI & Transportation. <https://enotrans.org/wp-content/uploads/2023/08/AI-and-Transportation.pdf>

69. EY (2023). Protección de Datos Personales en LATAM - Guía de Consulta Rápida.

70. Fan, M., Hu, J., Cao, R., Ruan, W., & Wei, X. (2018). A review on experimental design for pollutants removal in water treatment with the aid of artificial intelligence. *Chemosphere*, 200, 330–343. <https://doi.org/10.1016/j.chemosphere.2018.02.111>

71. Féry, G. (2022). *The Digital Journey of Water and Sanitation Utilities in Latin America and The Caribbean: What is at Stake and How to Begin*. Documento de discusión No. IDB-DP-00972. Banco Interamericano de Desarrollo (BID).

72. Foro Económico Mundial – FEM. (2012). *Strategic Infrastructure: Steps to Prioritize and Deliver Infrastructure Effectively and Efficiently*. Prepared in collaboration with PwC

73. Fuller, A., Fan, Z., Day, C., & Barlow, C. (2020). Digital Twin: Enabling Technologies, Challenges and Open Research. *IEEE Access*, 8, 108952–108971. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2020.2998358>

74. Fundación Bunge y Born (2021). Detección automatizada de basurales a cielo abierto: Inteligencia artificial, satélites y políticas pública. https://www.fundacionbyb.org/_files/ugd/2aae47_03757f467e384554b8d88ffd26c60af3.pdf

75. Fundación Bunge y Born (s.f.). Detección De Basurales Y Microbasurales A Cielo Abierto. <https://www.fundacionbyb.org/basurales>

76. Galo, J., Di Martino, E., Velásquez Bermúdez, J. M., & Delgadillo Gomez, A. (2023). *Tecnologías de Inteligencia Artificial (AI) en el mantenimiento de activos del sector eléctrico*. Banco Interamericano de Desarrollo. <https://doi.org/10.18235/000490>

77. Gámiz E., Argelicj A. El futuro de la analítica en las redes eléctricas: digital twins. eSmarcity.es. Disponible en: <https://www.esmarcity.es/comunicaciones/comunicacion-futuro-analitica-redes-electricas-digital-twins>

78. García A., Iglesias E. (2018). *Cloud computing: opportunities and challenges for sustainable economic development in Latin America and the Caribbean*. Inter-American Development Bank.

79. García De Soto, B., Bumbacher, A., Deublein, M., & Adey, B. T. (2018). Predicting road traffic accidents using artificial neural network models. *Infrastructure Asset Management*, 5(4), 132–144. <https://doi.org/10.1680/jinam.17.00028>

80. Ghenai, C., Husein, L. A., Al Nahlawi, M., Hamid, A. K., & Bettayeb, M. (2022). Recent trends of digital twin technologies in the energy sector: A comprehensive review. *Sustainable Energy Technologies and Assessments*, 54, 102837. <https://doi.org/10.1016/j.seta.2022.102837>

81. Giraldo, M.C., Ríos, C., Alarcón, A., Snyder, V., Echevarría, C., Riobo, A., Hallack, M. & Irigoyen, J.L. (2022). Energizados: los beneficios de una herramienta basada en las metodologías de machine learning para facilitar la detección de robo eléctrico. Nota técnica IDB-TN-2444. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0004178>

82. Gomedé, E. Fairness Metrics in Machine Learning. (2023). Recuperado de <<https://medium.com/the-modern-scientist/fairness-metrics-in-machine-learning-8c3777b48a9c>>

83. Grady, S. A., Hussaini, M. Y., & Abdullah, M. M. (2005). Placement of wind turbines using genetic algorithms. *Renewable Energy*, 30(2), 259–270. <https://doi.org/10.1016/j.renene.2004.05.007>

84. Granada, I., Pinto, A.M., & Castro, B. (2018). ¿Pilotos de innovación en el transporte público sin costo alguno para los países? Sí, es posible. Blogs IADB. Disponible en: <https://blogs.iadb.org/transporte/es/innovacion-en-el-transporte-publico-sin-costo alguno-para-los-paises-si-es-posible/>

85. Granata, F., Papirio, S., Esposito, G., Gargano, R., & De Marinis, G. (2017). Machine Learning Algorithms for the Forecasting of Wastewater Quality Indicators. *Water*, 9(2), 105. <https://doi.org/10.3390/w9020105>

86. Greyparrot AI (2024). Recuperado de: <https://www.greyparrot.ai/how-it-works>

87. Greyparrot AI (2024b). Recuperado de: <https://www.greyparrot.ai>

88. Greyparrot AI & CIMVI (Consórcio Intermunicipal do Médio Vale do Itajaí). Inteligência de resíduos Garantir que a embalagem nunca se torne desperdício.

89. Gschwendter, A., Munizaga, M., & Simonetti, C. (2016). Using smart card and GPS data for policy and planning: The case of Transantiago. *Research in Transportation Economics*, 59, 242–249. <https://doi.org/10.1016/j.retrec.2016.05.004>

90. Guerra, P. (2023). Inteligencia Artificial: Hacia una economía circular y la eficiencia en la gestión de residuos. Blogs IADB. Disponible en: <https://blogs.iadb.org/agua/es/inteligencia-artificial-hacia-una-economia-circular-y-la-eficiencia-en-la-gestion-de-residuos/>

91. Guerra, P. (2023). La revolución digital ha llegado para transformar el modo en que vemos y manejamos nuestros residuos. Blogs IADB. Disponible en: <https://blogs.iadb.org/agua/es/innovacion-tecnologica-en-la-gestion-de-residuos-solidos-la-revolucion-digital-que-ha-llegado-para-transformar-el-modo-en-que-vemos-y-manejamos-nuestros-residuos/>

92. Guresen, E., & Kayakutlu, G. (2011). Definition of artificial neural networks with comparison to other networks. *Procedia Computer Science*, 3, 426–433. <https://doi.org/10.1016/j.procs.2010.12.071>

93. Gutiérrez Puebla, J., Benítez, C., García Palomares, J. C., Romanillos Arroyo, G., Rubinstein, E., Leaño, J. M., Ribeiro, K. M., Scholl, L., Moya Gómez, B., & Condeço Melhorado, A. (2020). *Cómo aplicar Big Data en la planificación del transporte: El uso de datos de GPS en el análisis de la movilidad urbana*. Inter-American Development Bank. <https://doi.org/10.18235/0002487>

94. Gutiérrez Puebla, J., Benítez, C., Leaño, J. M., García Palomares, J.C., Melhorado, A., Mojica, C., Schnoll, L., Adler, V., Vera, F., Moya Gómez, B., Romanillos, G. (2019). *Cómo aplicar Big Data en la planificación del transporte urbano: El uso de datos de telefonía móvil en el análisis de la movilidad*. Documento para Discusión No. IDB-TN-1773. Banco Interamericano de Desarrollo (BID).

95. Gutiérrez, M.C., Pérez Jaramillo, D., & Riobó, A. (2019). Vehículos autónomos: Potencial y riesgos para América Latina y el Caribe. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0001686>

96. Halder, N. Decoding Machine Learning Success: Evaluating Performance Metrics with Python. (2024). Recuperado de <<https://medium.com/gitconnected/>>

97. Hammid, A. T., Sulaiman, M. H. B., & Abdalla, A. N. (2018). Prediction of small hydropower plant power production in Himreen Lake dam (HLD) using artificial neural network. *Alexandria Engineering Journal*, 57(1), 211–221. <https://doi.org/10.1016/j.aej.2016.12.011>

98. Heidarpahah, M., Hooshyaripor, F., & Fazeli, M. (2023). Daily electricity price forecasting using artificial intelligence models in the Iranian electricity market. *Energy*, 263, 126011. <https://doi.org/10.1016/j.energy.2022.126011>

99. Heymann F., Quest H., Lopez García T., Ballif C., Galus M. (2024). Reviewing 40 years of artificial intelligence applied to power systems – A taxonomic perspective. *Energy and AI* 15 (2024) 101322

100. Hermosilla, M., Alarcón, N. G., Pombo, C., Ávalos, R. S., Denis, G., & Aracena, C. (2021). Uso responsable de IA para política pública: Manual de formulación de proyectos. IDB Publications. <https://doi.org/10.18235/0003631>

101. Hong J., Chu Z., & Wang Q. (2011). Transport infrastructure and regional economic growth: evidence from China. *Transportation* 38, 737-752.

102. Hsu, J.-Y., Wang, Y.-F., Lin, K.-C., Chen, M.-Y., & Hsu, J. H.-Y. (2020). Wind Turbine Fault Diagnosis and Predictive Maintenance Through Statistical Process Control and Machine Learning. *IEEE Access*, 8, 23427–23439. <https://doi.org/10.1109/ACCESS.2020.2968615>

103. IAPP Research and Insights (2024). Global AI Law and Policy Tracker.

104. IEEE-USA. (2017). Artificial Intelligence Research, Development and Regulation. IEEE-USA Position Statement.

105. Índice latinoamericano de inteligencia artificial (s.f.). Índice Latinoamericano de Inteligencia Artificial. <https://indicelatam.cl>

106. Infosys BPM. (2024). AI-powered use cases for the energy and utilities sector. <https://www.infosysbpmp.com/blogs/energy-utilities/ai-powered-use-cases-energy-utilities-sector.html>

107. International Monetary Fund (IMF). (2016). Regional Economic Outlook. Western Hemisphere. Managing Transitions and Risks. Chapter 5: Infrastructure in Latin America and the Caribbean.

108. iRAP. ViaSegura. <<https://irap.org/es/rap-tools/light-ratings/viasegura/>>

109. Irigoyen J., Mayorga N. (2024). Infraestructura crítica en América Latina y el Caribe: tecnologías que están cambiando el juego. Blogs IADB. Disponible en: <https://blogs.iadb.org/energia/es/infraestructura-critica-en-america-latina-y-el-caribe-tecnologias-que-estan-cambiando-el-juego>

110. Irigoyen J., Tulande, N., & Daza, E. (2023). Inteligencia artificial, habilitador para un sector competitivo. Blogs IADB. Disponible en: <https://blogs.iadb.org/energia/es/inteligencia-artificial-habilitador-para-un-sector-competitivo/>

111. IWA (2020). Digital Water: Artificial Intelligence Solutions for the Water Sector. https://iwa-network.org/wp-content/uploads/2020/08/IWA_2020_Artificial_Intelligence_SCREEN.pdf

112. Jevinger, Å., Zhao, C., Persson, J. A., & Davidsson, P. (2024). Artificial intelligence for improving public transport: A mapping study. *Public Transport*, 16(1), 99–158. <https://doi.org/10.1007/s12469-023-00334-7>

113. Jiwattanakulpaisarn P., Noland R., & Graham D. (2012). Marginal productivity of expanding highway capacity. *Journal of Transport Economics and Policy*. 46 (3), 33-347.

114. Johannesen, N. J., Kolhe, M., & Goodwin, M. (2019). Relative evaluation of regression tools for urban area electrical energy demand forecasting. *Journal of Cleaner Production*, 218, 555–564. <https://doi.org/10.1016/j.jclepro.2019.01.108>

115. Jordon, J., Szpruch, L., Houssiau, F., Bottarelli, M., Cherubin, G., Maple, C., Cohen, S. N., & Weller, A. (2022). Synthetic Data—What, why and how? (arXiv:2205.03257). arXiv. <http://arxiv.org/abs/2205.03257>

116. Kuhlmann, A., Mehlum, E., & Moore, J. (2021). Harnessing artificial intelligence to accelerate the energy transition. World Economic Forum. https://www3.weforum.org/docs/WEF_Harnessing_AI_to_accelerate_the_Energy_Transition_2021.pdf

117. Kumar, K., & Saini, R. (2021). Application of Artificial Intelligence for the Optimization of Hydropower Energy Generation. *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*, 8(28), 170560. <https://doi.org/10.4108/eai.6-8-2021.170560>

118. Laplante, P., & Amaba, B. (2021). Artificial Intelligence in Critical Infrastructure Systems. *Computer*, 54(10). <https://doi.org/10.1109/MC.2021.3055892>

119. Latorre, L., Rego, E., Leo, L. D., & Gutiérrez, M. (2024). Reporte de tecnología: Gemelos digitales. IDB Publications. <https://doi.org/10.18235/0013166>

120. Laubshtein, Y. (2023). Protegiendo las infraestructuras de agua y saneamiento de amenazas ciberneticas: Un estudio de ciberseguridad para América Latina y el Caribe. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0004876>

121. Lehe, L. (2019). Downtown congestion pricing in practice. *Transportation Research Part C: Emerging Technologies*, 100, 200–223. <https://doi.org/10.1016/j.trc.2019.01.020>

122. Lekidis, A., Anastasiadis, A. G., & Vokas, G. A. (2022). Electricity infrastructure inspection using AI and edge platform-based UAVs. *Energy Reports*, 8, 1394–1411. <https://doi.org/10.1016/j.egyr.2022.07.115>

123. Levy, A., Yépez-García, A., Hallack, M., Snyder, V. and Ji, Y. (2018). Documento marco sectorial de energía. IDB

124. Li, F. (2023). The worlds I see: Curiosity, Explorations, and Discovery at the Dawn of AI.

125. Li, Y. (2023). The State of Art in transformer fault diagnosis with artificial intelligence and dissolved gas analysis: A review of literature.

126. Li T., Li L., Wang S., Dehghanian P. (2020). Artificial Intelligence for real-time topology identification in power distribution systems. George Washington University.

127. Liu, X., Miao, X., Jiang, H., & Chen, J. (2020). Review of data analysis in vision inspection of power lines with an in-depth discussion of deep learning technology. *Annual Reviews in Control*, 50, 253–277. <https://doi.org/10.1016/j.arcontrol.2020.09.002>

128. Lopez Conde, M., & Twinn, I. (2019). How artificial intelligence is making transport safer, cleaner, more reliable and efficient in emerging markets. EMCompass. <https://www.ifc.org/content/dam/ifc/doc/mgrt/emcompass-note-75-ai-making-transport-safer-in-emerging-markets.pdf>

129. Lu, Y., Shen, M., Wang, H., Wang, X., Van Rechem, C., & Wei, W. (2024). *Machine Learning for Synthetic Data Generation: A Review*. <https://arxiv.org/html/2302.04062v6>

130. Luu, T.T., Le, H., Vu, M., Nguyen, B. (2023). AI application for solid waste sorting in Global South. <https://sdgs.un.org/sites/default/files/2023-05/A41%20-%20Thien-An%20Tran%20Luu%20-%20AI%20Application%20for%20Solid%20Waste%20in%20the%20global%20south.pdf>

131. Manners-Bell, J. (2019). Future of Logistics. Nota técnica IDB-TN-1658. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0001729>

132. Maroju, R. G., Choudhari, S. G., Shaikh, M. K., Borkar, S. K., & Mendhe, H. (2023). Application of Artificial Intelligence in the Management of Drinking Water: A Narrative Review. *Cureus*, 15(11), e49344. <https://doi.org/10.7759/cureus.49344> <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10749683/>

133. McKinsey Analytics. (2018). *An executive's guide to AI*.

134. McKinsey & Company (2023). The AI-enabled utility: Rewiring to win in the energy transition.

135. McMillan, L., Varga, L. (2022). A review of the use of artificial intelligence methods in infrastructure systems. *Engineering Applications of Artificial Intelligence*, Volume 116. <https://www.sciencedirect.com/science/article/pii/S0952197622004626>

136. Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2022). *A Survey on Bias and Fairness in Machine Learning*. *ACM Computing Surveys*, 54(6), 1-35 <https://doi.org/10.1145/3457607>

137. Microsoft – Streebo Inc. (2024). Utility Chatbot - Energy and Utilities Company AI Chatbot Solution Powered by Microsoft Copilot and GPT. <https://appsource.microsoft.com/en-us/product/web-apps/streeboinc1674035040438.utility-chatbot?tab=overview>

138. Minatta A., Basani, M. (2022). Ecosistema de innovación en el sector Agua, saneamiento y residuos sólidos de América Latina y el Caribe: Relevamiento y modelo de vinculación. Nota técnica No. IDB-TN-2565. Banco Interamericano de Desarrollo (BID).

139. Minatta A., & Basani, M. (2023). *¿Cómo puede la regulación impulsar la innovación? Regulación habilitadora para la innovación en el sector agua, saneamiento y residuos sólidos de América Latina y el Caribe*. Nota técnica No. IDB-TN-2689. Banco Interamericano de Desarrollo (BID).

140. Minatta A., Basani, M., & Shaki G. (2022). *Gestión de innovación del prestador de servicios de agua, saneamiento y residuos sólidos en América Latina y el Caribe: Laboratorio de innovación*. Nota técnica No. IDB-TN-02513. Banco Interamericano de Desarrollo (BID).

141. Minatta, A., & Basani, M. (2020). Innovación en agua, saneamiento y residuos sólidos: Diagnóstico, perspectivas y oportunidades para América Latina y el Caribe. Nota técnica No. IDB-TN-01974. Banco Interamericano de Desarrollo (BID). <http://dx.doi.org/10.18235/0002514>

142. MODESHIFT (2023). What Is the Future of Artificial Intelligence AI in Transportation? <https://www.modeshift.com/what-is-the-future-of-artificial-intelligence-ai-in-transportation/>

143. Mohammad, A., & Mahjabeen, F. (2023). Revolutionizing Solar Energy: The Impact of Artificial Intelligence on Photovoltaic Systems. 2(1).

144. Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of Machine Learning*, second edition. MIT Press.

145. Molero G., Poveda Reyes S., Kumar A., García-Jimenez E., Chiara M., Santarremigia F. (2021). *Computational solutions based on bayesian networks to hierarchize and to predict factors influencing gender fairness in the transport system: four use cases*. *Sustainability* 2021 13 (20)

146. Moszoro M. (2021). *The Direct Employment Impact of Public Investment*. IMF Working Paper, WP/21/131.

147. Mounce, S. R., Boxall, J. B., & Machell, J. (2010). Development and Verification of an Online Artificial Intelligence System for Detection of Bursts and Other Abnormal Flows. *Journal of Water Resources Planning and Management*, 136(3), 309–318. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000030](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000030)

148. Navia Díaz, M. d. R., Bohórquez, J. F., Aguilera, J. C., Orejarena, S. S., Manosalva Castaneda, O. L., Corzo, C. M., Rodríguez, S., Romero Burgos, M. F. (2024). La gestión del cambio en el sector de agua potable y saneamiento de Colombia. <https://publications.iadb.org/es/la-gestion-del-cambio-en-el-sector-de-agua-potable-y-saneamiento-de-colombia>

149. Nestor, S. (2023). AI in the infrastructure sector: what does the future hold? *Infrastructure magazine*. <https://infrastructuremagazine.com.au/2023/09/05/ai-in-the-infrastructure-sector-what-does-the-future-hold/>

150. Nevala K. (2017). *The Machine Learning Primer*. SAS Best Practices.

151. Nolan, B. (2023). AI is doing the work of 250 people at an energy company and satisfying customers better than trained workers, CEO says. <https://www.businessinsider.com/ai-work-automation-octopus-energy-greg-jackson-2023-5>

152. Nova, K. (2023). AI-Enabled Water Management Systems: An Analysis of System Components and Interdependencies for Water Conservation.

153. NVIDIA. (2022). Top AI use cases for utilities companies. <https://resources.nvidia.com/en-us-energy-utilities/top-ai-usecases?xs=327369>

154. OECD. (2019). *Artificial Intelligence in Society*. OECD. <https://doi.org/10.1787/eedfee77-en>

155. OECD. (2019). OECD AI Principles Overview. <https://oecd.ai/en/ai-principles>

156. OECD. (2023). *AI language models: Technological, socio-economic and policy considerations* (OECD Digital Economy Papers 352; OECD Digital Economy Papers, Vol. 352). <https://doi.org/10.1787/13d38f92-en>

157. OECD. (2023). Perspectivas económicas para América Latina 2023. Invirtiendo para un desarrollo sostenible. Resumen.

158. OECD-CAF (2022). The Strategic and Responsible Use of Artificial Intelligence in the Public Sector of Latin America and the Caribbean. OECD Public Governance Reviews, OECD Publishing, Paris, <https://doi.org/10.1787/1f334543-en>.

159. Patterson, J., & Gibson, A. (2017). *Deep Learning: A Practitioner's Approach*. O'Reilly Media, Inc.

160. Pietersen, W., Baptista, D., Rosas-Shady, D., & Franco, A. (2023). La transformación digital de los servicios públicos de empleo en América Latina y el Caribe. IDB Publications. <https://doi.org/10.18235/0005084>

161. Pirika (s.f). Takanome: Litter Distribution Research. <https://corp.pirika.org/en/service/takanome/>

162. Pombo, C., Cabrol, M., Alarcón, N. G., & Ávalos, R. S. (2020). fAIr LAC: Adopción ética y responsable de la inteligencia artificial en América Latina y el Caribe. IDB Publications. <https://doi.org/10.18235/0002169>

163. Pombo C., Gupta R., Stankovich M. (2018). Servicios sociales para ciudadanos digitales: Oportunidades para América Latina y el Caribe. Banco Interamericano de Desarrollo – BID.

164. Ponomareva N., Hazimeth H., Kurakin A., Xu Z., Denison C., McMahan H., Vassilvitskii S., Chien S., Thakurta A. (2023). *How to DP-fy ML: A practical guide to machine learning with differential privacy*. Journal of Artificial Intelligence Research 77 (2023).

165. Pourdaryaei, A., Mohammadi, M., Mubarak, H., Abdellatif, A., Karimi, M., Gryazina, E., & Terzija, V. (2024). A new framework for electricity price forecasting via multi-head self-attention and CNN-based techniques in the competitive electricity market. *Expert Systems with Applications*, 235, 121207. <https://doi.org/10.1016/j.eswa.2023.121207>

166. Pourdaryaei, A., Mokhlis, H., Illias, H. A., Kaboli, S. Hr. A., Ahmad, S., & Ang, S. P. (2019). Hybrid ANN and Artificial Cooperative Search Algorithm to Forecast Short-Term Electricity Price in De-Regulated Electricity Market. *IEEE Access*, 7, 125369–125386. <https://doi.org/10.1109/ACCESS.2019.2938842>

167. Rebala, G., Ravi, A., & Churiwala, S. (2019). *An Introduction to Machine Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-15729-6>

168. Rennie, G., Hartnett, K., Reyes, V., Siegert, D. and Sandoval, D. (2020). *Análisis de brechas y oportunidades de innovación en el sector energético en América Latina y el Caribe*. IDB

169. Rendón Rodríguez, J. R., Hernández, E., & Del Río, H. (2020). Nueva generación de modelos de transporte a través del uso de big data: Caso San Salvador. Inter-American Development Bank. <https://doi.org/10.18235/0002130>

170. Rodrigues, F., Markou, I., & Pereira, F. C. (2019). Combining time-series and textual data for taxi demand prediction in event areas: A deep learning approach. *Information Fusion*, 49, 120–129. <https://doi.org/10.1016/j.inffus.2018.07.007>

171. Romanillos, G., Moya-Gómez, B., Zaltz-Austwick, M., & Lamíquiz-Daudén, P. J. (2018). The pulse of the cycling city: Visualising Madrid bike share system GPS routes and cycling flow. *Journal of Maps*, 14(1), 34–43. <https://doi.org/10.1080/17445647.2018.1438932>

172. Runge, J., & Zmeureanu, R. (2021). A Review of Deep Learning Techniques for Forecasting Energy Use in Buildings. *Energies*, 14(3), 608. <https://doi.org/10.3390/en14030608>

173. Sameen, M., & Pradhan, B. (2017). Severity Prediction of Traffic Accidents with Recurrent Neural Networks. *Applied Sciences*, 7(6), 476. <https://doi.org/10.3390/app7060476>

174. Santos, D., Saias, J., Quaresma, P., & Nogueira, V. B. (2021). Machine Learning Approaches to Traffic Accident Analysis and Hotspot Prediction. *Computers*, 10(12), 157. <https://doi.org/10.3390/computers10120157>

175. Sarni, W., Sheehan, J., & Cox, T. (2023). *The Digital Journey of Water and Sanitation Utilities in the Caribbean: Current State and Opportunities*. Discussion Paper No. IDB-DP-01046. Inter-American Development Bank.

176. Schwartz J., Andres L, Dragoiu G. Crisis in Latin America: infrastructure investment, employment and the expectations of stimulus. *Policy Research Working Paper Series 5009*. The World Bank.

177. Sergienko, B. (2024). Generative AI in the Energy Industry and Utilities: Next-Gen Solutions for a Greener Future. <https://masterofcode.com/blog/generative-ai-in-energy-and-utilities>

178. Senthil kumar, A. R., Goyal, M. K., Ojha, C. S. P., Singh, R. D., & Swamee, P. K. (2013). Application of artificial neural network, fuzzy logic and decision tree algorithms for modelling of streamflow at Kasol in India. *Water Science and Technology*, 68(12), 2521–2526. <https://doi.org/10.2166/wst.2013.491>

179. Sharma, A., Kosasih, E., Zhang, J., Brintrup, A., & Calinescu, A. (2022). Digital Twins: State of the art theory and practice, challenges, and open research questions. *Journal of Industrial Information Integration*, 30, 100383. <https://doi.org/10.1016/j.jii.2022.100383>

180. Smola A., Vishwanathan S.V.N. *Introduction to Machine Learning*. Cambridge University Press.

181. Stankovich, M., Hasanbeigi, A., & Neftenov, N. (2020). Uso de tecnologías de la 4RI en agua y saneamiento en América Latina y el Caribe. IDB Publications. <https://doi.org/10.18235/0002343>

182. Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning*, second edition: An Introduction. MIT Press.

183. Taylor, L., & Nitschke, G. (2017). Improving Deep Learning using Generic Data Augmentation (arXiv:1708.06020). arXiv. <https://doi.org/10.48550/arXiv.1708.06020>

184. Talbott, S. (2024). How AI Is Lighting Up the Energy Industry. <https://www.salesforce.com/blog/ai-in-energy/>

185. Tempest, O. (2023). Harnessing AI for Optimization and Sustainability in Water and Wastewater Industry. Interview with Adam Cartwright Global Head of Industry Strategy for Water Industry at Siemens AG. <https://smartwatermagazine.com/news/siemens/exploring-potential-ai-offers-water-utilities-achieving-their-sustainability-goals>

186. TMG (2020). Repaso de las políticas y desarrollos latinoamericanos sobre Inteligencia Artificial. <https://www.tmgtelecom.com/wp-content/uploads/2020/07/TMG-Informe-de-Desarrollo-de-Políticas-de-IA.pdf>

187. Torres, C. S. R., Sánchez, C. B., & Narita, T. (2021). Autoevaluación ética de IA para actores del ecosistema emprendedor: Guía de aplicación. IDB Publications. <https://doi.org/10.18235/0003269>

188. Turing, A. (1950). Machinery and Intelligence. *Mind: A Quarterly Review of Psychology and Philosophy*, 59(236), 433–460.

189. UNESCO. (2019). Preliminary study on the Ethics of Artificial Intelligence—UNESCO Digital Library. <https://unesdoc.unesco.org/ark:/48223/pf0000367823>

190. UNESCO (2022). Recomendación sobre la ética de la inteligencia artificial. Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO).

191. Vanijjirattikhan, R., Khomsay, S., Kitbutrawat, N., Khomsay, K., Supakchukul, U., Udomsuk, S., Suwatthikul, J., Oumtrakul, N., & Anusart, K. (2022). AI-based acoustic leak detection in water distribution systems. *Results in Engineering*, 15, 100557. <https://doi.org/10.1016/j.rineng.2022.100557>

192. Valenciaport, F. (2020). Manual de puertos inteligentes: Estrategia y hoja de ruta. IDB Publications. <https://doi.org/10.18235/0002384>

193. Vasudevan, M., Townsend, H., Dang, Nhi, T., O'Hara, A., Burnier, C., & Ozbay, K. (2020). Identifying Real-World Transportation Applications Using Artificial Intelligence (AI): Summary of Potential Application of AI in Transportation. <https://rosap.ntl.bts.gov/view/dot/50651>

194. Vélez, M. I., Gómez Santamaría, C., & Osorio Sanabria, M. A. (2022). *Conceptos fundamentales y uso responsable de la inteligencia artificial en el sector público*. Informe 2 [workingPaper]. CAF. <https://scioteca.caf.com/handle/123456789/1921>

195. Villagrán, M. A. (2022). Auditoría algorítmica para sistemas de toma o soporte de decisiones. IDB Publications. <https://doi.org/10.18235/0004154>

196. Visor AI. (2021). AI Bots in the Utilities Sector: The Solution You Need. <https://www.visor.ai/blog/ai-bots-in-the-utilities-sector/>

197. Wang, P. (2019). On Defining Artificial Intelligence. *Journal of Artificial General Intelligence*, 10(2), 1–37. <https://doi.org/10.2478/jagi-2019-0002>

198. Wang, J., Mall, S., & Perez, L. (2017). The Effectiveness of Data Augmentation in Image Classification using Deep Learning.

199. Wipro. (2019). 3 Ways AI Will Improve Utility Customers' Experiences. <https://www.wipro.com/blogs/anjan-lahiri/3-ways-ai-will-improve-utility-customers-experiences/>

200. World Bank. (2022). *Government Migration to Cloud Ecosystems: Multiple Options, Significant Benefits, Manageable Risks*. World Bank, Washington, DC.

201. Yang, Z., Franz, M. L., Zhu, S., Mahmoudi, J., Nasri, A., & Zhang, L. (2018). Analysis of Washington, DC taxi demand using GPS and land-use data. *Journal of Transport Geography*, 66, 35–44. <https://doi.org/10.1016/j.jtrangeo.2017.10.021>

202. Zhang, H., Davigny, A., Colas, F., Poste, Y., & Robyns, B. (2012). Fuzzy logic based energy management strategy for commercial buildings integrating photovoltaic and storage systems. *Energy and Buildings*, 54, 196–206. <https://doi.org/10.1016/j.enbuild.2012.07.022>

203. Zhang, Y. & Cheng L. (2023). The role of transport infrastructure in economic growth: empirical evidence in the UK. *Transport Policy* 133 (2023) 2023–233.

204. Zhang, Q., Li, Z., Snowling, S., Siam, A., & El-Dakhakhni, W. (2019). Predictive models for wastewater flow forecasting based on time series analysis and artificial neural network. *Water Science and Technology*, 80(2), 243–253. <https://doi.org/10.2166/wst.2019.263>

205. Zhou, M., Zhang, Y., Wang, J., Xue, T., Dong, Z., & Zhai, W. (2023). Fault Detection of Wastewater Treatment Plants Based on an Improved Kernel Extreme Learning Machine Method. *Water*, 15(11), 2079. <https://doi.org/10.3390/w15112079>

