

**USO DE LAS MATEMÁTICAS EN MODELOS DE INTELIGENCIA ARTIFICIAL**  
**USE OF MATHEMATICS IN ARTIFICIAL INTELLIGENCE MODELS**

**Autores: <sup>1</sup>Mario Alberto Ibarra Martínez, <sup>2</sup>Carla Guillermina Mendoza Arce y <sup>3</sup>Manuel Eduardo López Delgado.**

<sup>1</sup>ORCID ID: <https://orcid.org/0009-0004-5500-871X>

<sup>2</sup>ORCID ID: <https://orcid.org/0009-0004-2110-6047>

<sup>3</sup>ORCID ID: <https://orcid.org/0000-0003-1452-3382>

<sup>1</sup>E-mail de contacto: [mibarra@uagraria.edu.ec](mailto:mibarra@uagraria.edu.ec)

<sup>2</sup>E-mail de contacto: [cmendozaf5@unemi.edu.ec](mailto:cmendozaf5@unemi.edu.ec)

<sup>3</sup>E-mail de contacto: [mlopez@uagraria.edu.ec](mailto:mlopez@uagraria.edu.ec)

Afiliación: <sup>1</sup><sup>3</sup>\*Universidad Agraria del Ecuador, (Ecuador). <sup>2</sup>\*Universidad Estatal de Milagro, (Ecuador).

Artículo recibido: 7 de Julio del 2025

Artículo revisado: 8 de Julio del 2025

Artículo aprobado: 18 de Julio del 2025

<sup>1</sup>Ingeniero Industrial, graduado de la Escuela Superior Politécnica del Litoral, (Ecuador). Maestrante en Ingeniería de Software y Sistemas Informáticos de la Universidad Internacional de la Rioja, (España). Docente de la Universidad Agraria del Ecuador, (Ecuador), con años de experiencia laboral.

<sup>2</sup>Ingeniera en Negocios Internacionales, graduada de la Escuela Superior Politécnica del Litoral, (Ecuador). Máster en Dirección Comercial de la Universidad de la Rioja, (España). Docente de la Universidad Estatal de Milagro, (Ecuador), con años de experiencia laboral.

<sup>3</sup>Doctorante en Planificación Pública y Privada, Universidad de Tumbes, (Perú). Docente de la Universidad Agraria del Ecuador, (Ecuador), con años de experiencia laboral.

### **Resumen**

El avance de la inteligencia artificial ha evidenciado una profunda dependencia de estructuras matemáticas para lograr sistemas adaptativos, precisos y explicables. La creciente complejidad de los entornos digitales y educativos exige comprender puede integrarse de manera efectiva el uso de modelos matemáticos en los sistemas de inteligencia artificial. El objetivo del estudio fue analizar la relación entre los modelos matemáticos y la inteligencia artificial (IA). Se realizó una investigación cualitativa, de tipo bibliográfica, con enfoque descriptivo-exploratorio, aplicando análisis documental y métodos teórico, inductivo-deductivo y analítico-sintético. Los resultados indicaron que los modelos matemáticos no solo estructuran los algoritmos de IA, sino que permiten su operatividad en contextos de manera personalizada, el análisis neurocognitivo, y el diagnóstico automatizado. Las estructuras identificadas incluyeron álgebra lineal, lógica difusa, series temporales, teoría de grafos y análisis multivariado. Las conclusiones del estudio subrayan que esta integración no es simplemente técnica, sino epistémica, y que la efectividad de los modelos IA depende de la

solidez matemática subyacente, con implicaciones éticas, funcionales y sociales relevantes para el diseño de soluciones computacionales avanzadas.

**Palabras clave: Matemáticas, Inteligencia artificial, Predicción, Modelado, Automatización.**

### **Abstract**

The advancement of artificial intelligence has evidenced a deep dependence on mathematical structures to achieve adaptive, accurate and explainable systems. The increasing complexity of digital and educational environments requires an understanding of how the use of mathematical models can be effectively integrated into artificial intelligence systems. The aim of the study was to analyze the relationship between mathematical models and artificial intelligence (AI). A qualitative, bibliographic research was conducted, with a descriptive-exploratory approach, applying documentary analysis and theoretical, inductive-deductive and analytical-synthetic methods. The results indicated that mathematical models not only structure AI algorithms, but also allow their operability in contexts in a personalized manner, neurocognitive analysis, and automated

diagnosis. The structures identified included linear algebra, fuzzy logic, time series, graph theory, and multivariate analysis. The conclusions of the study underline that this integration is not simply technical, but epistemic, and that the effectiveness of AI models depends on the underlying mathematical soundness, with ethical, functional, and social implications relevant to the design of advanced computational solutions.

**Keywords:** **Mathematics, Artificial intelligence, Prediction, Modeling, Automation.**

### **Sumário**

O avanço da inteligência artificial revelou uma profunda dependência de estruturas matemáticas para sistemas adaptativos, exactos e explicáveis. A complexidade crescente dos ambientes digitais e educativos exige a compreensão do modo como a utilização de modelos matemáticos pode ser efetivamente integrada nos sistemas de inteligência artificial. O objetivo do estudo é analisar a relação entre os modelos matemáticos e a inteligência artificial (IA). Foi realizada uma investigação qualitativa, bibliográfica, descritivo-exploratória, com recurso à análise documental e aos métodos teórico, indutivo-dedutivo e analítico-sintético. Os resultados indicaram que os modelos matemáticos não só estruturam os algoritmos de IA, como também permitem a sua operacionalização em contextos de análise personalizada, neurocognitiva e de diagnóstico automatizado. As estruturas identificadas incluem a álgebra linear, a lógica difusa, as séries temporais, a teoria dos grafos e a análise multivariada. As conclusões do estudo sublinham que esta integração não é simplesmente técnica, mas epistémica, e que a eficácia dos modelos de IA depende da solidez matemática subjacente, com implicações éticas, funcionais e sociais relevantes para a conceção de soluções computacionais avançadas.

**Palavras-chave:** **Matemática, Inteligência artificial, Previsão, Modelação, Automatização.**

### **Introducción**

La combinación entre modelos matemáticos y sistemas de Inteligencia Artificial (IA) representa una de las mayores transformaciones en los campos científicos, tecnológicos y educativos de la sociedad contemporánea (Rivas et al., 2024). Actualmente, diferentes instituciones a nivel mundial emplea algoritmos de IA sustentados en estructuras matemáticas avanzadas para la toma de decisiones automatizadas, esta integración ha derivado en modelos predictivos de alto rendimiento, con aplicaciones que van desde el diagnóstico médico asistido por redes neuronales hasta la personalización de entornos de aprendizaje inteligente (Morandini et al., 2023). La convergencia entre las matemáticas y los modelos de inteligencia artificial ha marcado un hito en la transformación de los procesos educativos, industriales y científicos, este fenómeno responde al auge de técnicas computacionales avanzadas, como las redes neuronales artificiales (RNA), el aprendizaje automático y el aprendizaje profundo las cuales encuentran en las matemáticas su fundamento operativo (Guishca et al., 2024).

Según una revisión sistemática realizada por Pacha et al. (2024), los estudios incorporan directamente conceptos matemáticos a través de la inteligencia artificial para optimizar la personalización del aprendizaje y la evaluación automatizada. Asimismo, Morandini (2021), destaca que el uso de modelos matemáticos para la resolución de problemas reales mediante IA ha incrementado la precisión de los algoritmos de clasificación, especialmente en contextos con alta vulnerabilidad social. Estas informaciones no solo reflejan la aplicabilidad práctica de dicha intersección, sino que subrayan su creciente relevancia como campo de estudio multidisciplinario con profundo impacto pedagógico y tecnológico, en

consecuencia, explorar esta articulación resulta imprescindible para comprender cómo los principios matemáticos estructuran el razonamiento lógico que permite a la IA generar soluciones eficientes en entornos cada vez más dinámicos. Por su parte, los modelos matemáticos constituyen representaciones abstractas de fenómenos reales, formuladas mediante expresiones matemáticas que permiten describir, analizar y predecir comportamientos de sistemas complejos (Rivas et al., 2024).

De acuerdo con Guishca et al. (2024), estos modelos no solo cumplen una función descriptiva, sino también normativa, al ofrecer marcos formales para la toma de decisiones basada en datos cuantificables, su aplicabilidad abarca áreas como la física, la biología, la economía y, más recientemente, la inteligencia artificial, donde operan como soporte lógico de algoritmos de aprendizaje y reconocimiento. Existen diversos tipos de modelos matemáticos, como los modelos deterministas, que son aquellos en los que no interviene la aleatoriedad; su estructura permite que, dadas ciertas condiciones iniciales, se obtenga siempre el mismo resultado. Por otro lado, los modelos estocásticos incorporan elementos de incertidumbre, empleando teoría de probabilidades para estimar comportamientos variables (García, 2015). También se reconocen los modelos lineales, cuya función se expresa mediante ecuaciones de primer grado, y los no lineales, que involucran ecuaciones polinómicas o diferenciales más complejas (Ñaupás et al., 2018).

Además, los modelos dinámicos consideran la evolución de un sistema en el tiempo, siendo fundamentales en la simulación de procesos que varían de forma continua. Un ejemplo representativo son las ecuaciones diferenciales

empleadas en el entrenamiento de redes neuronales artificiales. En contraste, los modelos estáticos describen fenómenos en un instante particular, sin considerar su evolución temporal. Ambos enfoques han sido aplicados con éxito en inteligencia artificial, particularmente en el modelado de trayectorias de aprendizaje y patrones de conducta (Forteza, 2019). En la práctica educativa, el uso de modelos matemáticos ha permitido interpretar fenómenos didácticos como la adquisición del pensamiento algebraico, la resolución de problemas o la adaptación del currículo en función de parámetros contextuales. Según Morandini (2021), el uso de modelos predictivos basados en ecuaciones logísticas y análisis multivariado permitió mejorar la identificación de estudiantes con bajo rendimiento en matemáticas. Por tanto, los modelos matemáticos no solo son herramientas de representación, sino que actúan como mediadores epistemológicos entre el mundo real y los sistemas de procesamiento computacional, ofreciendo una estructura formal para el diseño de algoritmos de IA con alta capacidad de generalización, optimización y adaptación contextual.

Mientras que la inteligencia artificial se define como el conjunto de sistemas tecnológicos capaces de realizar tareas que normalmente requieren inteligencia humana, tales como el razonamiento, el aprendizaje, la resolución de problemas y la toma de decisiones (Lombeida et al., 2025). La IA representa una revolución técnica y ética que transforma los modelos productivos, educativos y sociales mediante el procesamiento automatizado de grandes volúmenes de datos y patrones de comportamiento. El funcionamiento de la IA se basa en algoritmos complejos que simulan estructuras cognitivas humanas mediante modelos computacionales. El aprendizaje

automático machine learning (ML) permite que los sistemas “aprendan” a partir de los datos, ajustando sus parámetros internos para mejorar su rendimiento progresivamente. Una subcategoría de este enfoque es el aprendizaje profundo deep learning (DL), basado en redes neuronales artificiales que replican las conexiones sinápticas del cerebro humano (Cinar y Natarajan, 2022). Los beneficios de la IA son amplios y abarcan múltiples sectores, en educación, permite la personalización del aprendizaje, la detección temprana de dificultades cognitivas, la retroalimentación automática y el diseño de entornos adaptativos. En el ámbito económico, la IA mejora la eficiencia operativa, reduce costos y optimiza la toma de decisiones. Según Pacha et al. (2024), la implementación de soluciones basadas en IA ha incrementado la eficiencia en la gestión de recursos educativos en sistemas automatizados.

En contextos de vulnerabilidad social, la IA ha demostrado un impacto relevante al ampliar el acceso a recursos de aprendizaje y facilitar el seguimiento individualizado del progreso académico, sin embargo, su uso también plantea desafíos éticos, como la protección de datos, la transparencia de los algoritmos y el riesgo de sesgos en los modelos de predicción. Por tal motivo, diversas instituciones académicas y organismos internacionales han propuesto marcos normativos para garantizar una IA ética, confiable y centrada en el ser humano (Lescano et al., 2024). En este sentido, las matemáticas constituyen la base estructural de la inteligencia artificial, proporcionando el lenguaje formal y las herramientas necesarias para la formulación, validación y optimización de algoritmos. En particular, ramas como el álgebra lineal, el cálculo diferencial, la teoría de probabilidades y la estadística inferencial permiten representar operaciones complejas de clasificación, predicción y agrupamiento de datos (Bolaño y

Duarte, 2024). En el aprendizaje automático, los algoritmos utilizan funciones matemáticas de coste y gradientes descendientes para ajustar los parámetros del modelo a los datos de entrada. Según León (2024), aproximadamente nueve de cada diez algoritmos de IA aplicados en contextos educativos emplean estructuras algebraicas y funciones de activación no lineales derivadas del análisis matemático para optimizar su precisión.

Las redes neuronales artificiales (RNA), como parte del aprendizaje profundo, dependen de operaciones matriciales y del cálculo vectorial para representar la activación de nodos y la propagación del error durante el entrenamiento del modelo (Núñez et al., 2023). En términos de interacción, las matemáticas permiten modelar datos mediante funciones que transforman entradas, por ejemplo, respuestas de un estudiante en salidas categorizadas como niveles de competencia, estos modelos operan en ciclos iterativos donde las operaciones diferenciales ajustan el rendimiento del sistema con base en retroalimentación empírica. Así, IA y matemáticas no funcionan como componentes aislados, sino como un sistema simbiótico donde la capacidad de predicción y generalización depende de la robustez del modelado matemático. Entre los beneficios se encuentra la precisión de los modelos; por otro, se fortalece su interpretabilidad, permitiendo representar relaciones causa-efecto mediante ecuaciones paramétricas. Los sistemas de predicción del rendimiento escolar basados en IA incrementan su fiabilidad de forma notable al incorporar modelos matemáticos probabilísticos y bayesianos. De igual forma, el análisis de series temporales permitió anticipar patrones de deserción escolar con alta exactitud al combinar redes recurrentes y modelado estadístico.

Desde un enfoque pedagógico, esta fusión posibilita la evaluación continua de los procesos de aprendizaje, generando retroalimentación personalizada y en tiempo real, esto se traduce en una enseñanza adaptativa, guiada por modelos dinámicos que interpretan el progreso de cada estudiante como una función dependiente de múltiples variables contextuales y cognitivas. En consecuencia, este trabajo adopta un enfoque de investigación cualitativa mediante el método de revisión bibliográfica, para lo cual se recopilaron, analizaron y sintetizaron fuentes científicas indexadas en bases como Scopus, Web of Science y ScienceDirect, publicadas entre 2020 y 2025, con énfasis en estudios empíricos y teóricos que abordan la integración entre modelos matemáticos e inteligencia artificial en entornos educativos. La estrategia metodológica permite identificar patrones, vacíos teóricos y tendencias emergentes, constituyendo una base sólida para formular propuestas que optimicen el uso conjunto de matemáticas e IA en procesos pedagógicos y formativos de alta precisión contextual. Finalmente se plantea como formulación del problema la interrogante ¿Cómo puede integrarse de manera efectiva el uso de modelos matemáticos en los sistemas de inteligencia artificial? Estableciendo como objetivo general analizar la relación entre los modelos matemáticos y la inteligencia artificial (IA), con el fin de identificar las principales estructuras teóricas, aplicaciones prácticas y beneficios derivados de su implementación conjunta.

Al respecto, se define como inteligencia artificial a la capacidad de los sistemas computacionales para emular procesos cognitivos humanos mediante algoritmos capaces de aprender, razonar y tomar decisiones. Esta disciplina se clasifica en IA débil, centrada en tareas específicas; IA fuerte,

que simula razonamientos complejos; y IA general, cuyo propósito es replicar integralmente la inteligencia humana (Bolaño y Duarte, 2024). Los pilares funcionales de esta evolución son el machine learning (aprendizaje automático) y el deep learning (aprendizaje profundo), los cuales estructuran el proceso de entrenamiento de modelos mediante el análisis de patrones y la retroalimentación de errores.

En entornos educativos, la IA ha transformado las prácticas pedagógicas mediante el diseño de sistemas de tutoría inteligente, algoritmos de predicción de desempeño académico, y plataformas de aprendizaje adaptativo. Estas tecnologías permiten personalizar trayectorias formativas, automatizar la retroalimentación, y detectar tempranamente el riesgo de abandono escolar. Rivas et al. (2024), destacan la utilidad de la IA para analizar grandes volúmenes de datos educativos y generar soluciones inmediatas ante problemas de aprendizaje matemático, reforzando la comprensión conceptual en tiempo real. El impacto de la IA en la educación, sin embargo, trasciende lo técnico. Se articula como un dispositivo epistemológico que redefine la noción de enseñanza mediante la automatización de procesos metacognitivos, tal como lo señalan Bolaño y Duarte (2023), la IA no solo aporta eficiencia operativa, sino que transforma los modelos de mediación educativa al favorecer dinámicas de aprendizaje autónomo, continuo y centrado en el estudiante. Este proceso implica una revisión crítica del rol del docente, quien asume la función de mediador cognitivo y evaluador ético del uso de las tecnologías inteligentes.

Por otro lado, los modelos matemáticos constituyen representaciones formales de fenómenos observables, a través de ecuaciones que codifican las relaciones entre variables y

permiten comprender, predecir o controlar sistemas complejos. En el ámbito de la inteligencia artificial, estos modelos se estructuran como herramientas fundamentales para el procesamiento algorítmico de datos, permitiendo identificar patrones, inferencias y proyecciones con altos niveles de precisión (Tóala et al., 2024). Existen dos grandes enfoques en la modelación matemática utilizada en IA: los modelos deterministas y los estocásticos. Los primeros se caracterizan por su estructura rígida, en la que las relaciones entre variables se mantienen constantes, generando resultados predecibles bajo condiciones controladas. Por el contrario, los modelos estocásticos incorporan incertidumbre y aleatoriedad, utilizando distribuciones de probabilidad para representar fenómenos dinámicos como el comportamiento del usuario o la variabilidad del aprendizaje (Villena et al., 2024).

Desde una perspectiva estructural, los modelos pueden ser lineales, no lineales, estáticos o dinámicos. Los lineales suponen proporcionalidad entre variables, mientras que los no lineales permiten representar interacciones más complejas, como las que se encuentran en redes neuronales profundas. Por su parte, los modelos estáticos trabajan con estados fijos del sistema, y los dinámicos incorporan el tiempo como variable, permitiendo simulaciones de evolución temporal, especialmente útiles en la predicción de trayectorias educativas o análisis longitudinal de datos (Sachini et al., 2022). La función de los modelos matemáticos en inteligencia artificial puede clasificarse en tres dimensiones: descriptiva, explicativa y normativa. La función descriptiva se limita a representar lo observado, como en el caso de los algoritmos de agrupamiento o clustering. La función explicativa busca interpretar las causas

de los patrones detectados, como los modelos de regresión. Finalmente, la función normativa implica el uso del modelo como guía para la toma de decisiones, tal como sucede en los sistemas de recomendación educativa basados en redes bayesianas o lógica difusa (Rivas et al., 2024). La articulación de estos modelos dentro de los sistemas de IA contribuye a transformar datos brutos en información relevante para la mejora de los procesos formativos, su eficacia radica en la combinación de abstracción matemática con métodos computacionales, configurando una sinergia epistemológica entre la lógica simbólica, el análisis estadístico y la inferencia algorítmica.

La conexión estructural entre matemáticas e inteligencia artificial en la estructura de los modelos de inteligencia artificial se fundamenta en una base matemática rigurosa que permite su formalización, interpretación y optimización. Álgebra lineal, cálculo diferencial, estadística y teoría de probabilidades son disciplinas clave en esta arquitectura formal, proporciona los marcos operacionales necesarios para el manejo de vectores, matrices y tensores, esenciales para el funcionamiento de redes neuronales profundas. El cálculo diferencial, por su parte, sustenta el proceso de optimización de funciones a través del uso de gradientes y derivadas parciales, facilitando el aprendizaje iterativo en algoritmos supervisados (Pantsar, 2023). La estadística permite inferir patrones y construir modelos robustos a partir de datos incompletos o ruidosos, mientras que la teoría de probabilidades sustenta modelos generativos y redes bayesianas. Ecuaciones diferenciales se utilizan en el modelado de sistemas dinámicos, y los vectores activan capas neuronales según funciones no lineales como ReLU o sigmoide, las cuales definen los límites de decisión y capacidad de generalización de los modelos. Esta convergencia matemática constituye el

núcleo teórico que permite a la IA operar como una tecnología predictiva, adaptativa y escalable (Sachini et al., 2022; Tóala et al., 2024).

Asimismo, las redes neuronales artificiales (RNA) son sistemas inspirados en el funcionamiento del cerebro humano que utilizan estructuras matemáticas para simular procesos de aprendizaje, su arquitectura básica se compone de capas (de entrada, ocultas y de salida), nodos o neuronas artificiales, y funciones de activación que definen cómo se transmiten y transforman las señales entre capas (Rivas et al., 2024). El entrenamiento de una RNA se basa en la retro - propagación del error, un algoritmo que utiliza cálculo diferencial para ajustar los pesos sinápticos mediante el descenso del gradiente. Esta técnica calcula la derivada parcial de una función de costo con respecto a cada parámetro, minimizando iterativamente la discrepancia entre las predicciones del modelo y los datos reales. Las funciones de costo, como el error cuadrático medio, cuantifican la pérdida del modelo en cada iteración, mientras que los algoritmos de descenso de gradiente permiten la actualización de parámetros hacia un óptimo local o global (Pantsar, 2023). Las RNA permiten el modelado de relaciones no lineales complejas, siendo capaces de aproximar funciones arbitrarias gracias al teorema de aproximación universal. Este carácter matemático les otorga flexibilidad y adaptabilidad en tareas como clasificación, regresión, reconocimiento de imágenes y procesamiento de lenguaje natural.

En el ámbito educativo, la inteligencia artificial basada en modelos matemáticos permite desarrollar sistemas que predicen el rendimiento académico, personalizan contenidos y promueven una retroalimentación adaptativa, la implementación de algoritmos de

regresión logística, redes neuronales y árboles de decisión ha permitido modelar trayectorias de aprendizaje y predecir la probabilidad de deserción estudiantil, identificando factores de riesgo y diseñando intervenciones tempranas (Villena et al., 2024). La personalización se logra mediante sistemas de recomendación que analizan el historial de interacción del estudiante con la plataforma educativa, generando secuencias de contenidos ajustadas a su estilo de aprendizaje y ritmo cognitivo, estas estrategias matemáticamente formuladas optimizan el tiempo de instrucción y mejoran la retención conceptual. La retroalimentación automática, fundamentada en modelos supervisados, permite corregir errores en tiempo real, guiando al estudiante hacia soluciones más eficientes. Así, la IA no reemplaza al docente, sino que amplía su capacidad de monitoreo y acompañamiento, actuando como un asistente pedagógico que promueve la autonomía del educando (Rivas et al., 2024; Bolaño y Duarte, 2023).

### **Materiales y Métodos**

El presente estudio se enmarcó en el paradigma cualitativo, sustentado en una epistemología interpretativa que privilegió la comprensión profunda de las variables examinadas (Hadi et al., 2023). Este tipo de investigación no buscó establecer generalizaciones estadísticas, sino interpretar el significado de los conceptos, procesos y estructuras que emergen en la articulación entre matemáticas e inteligencia artificial. La orientación cualitativa permitió acceder a dimensiones cognitivas y lógicas que subyacen en el diseño y la implementación de modelos de IA, en función de su estructura matemática. La investigación adoptó un enfoque descriptivo y exploratorio. El componente descriptivo permitió identificar, organizar y caracterizar las estructuras, funciones y aplicaciones de las matemáticas en

modelos de inteligencia artificial, sistematizando las relaciones entre teoría matemática y desempeño algorítmico (Cohen y Gómez, 2019).

A su vez, el componente exploratorio resultó fundamental para abordar un campo interdisciplinario aún en consolidación, permitiendo examinar vacíos conceptuales y tendencias emergentes no suficientemente documentadas en la literatura académica (Silador, 2023). La articulación de ambos enfoques favoreció el análisis de fenómenos complejos, posibilitando la identificación de categorías teóricas iniciales, útiles tanto para la comprensión del estado actual del conocimiento como para orientar futuras investigaciones que profundicen en la relación entre matemáticas y sistemas inteligentes. Se desarrolló una investigación de tipo bibliográfica, basada en la revisión sistemática y crítica de fuentes secundarias, esta modalidad se sustentó en la recopilación, selección y análisis de artículos científicos, libros especializados, tesis indexadas y documentos técnicos publicados entre 2020 y 2025. La revisión bibliográfica permitió construir una base teórica consistente e identificar antecedentes relevantes en la aplicación de las matemáticas a la inteligencia artificial y contrastar enfoques conceptuales procedentes de la matemática aplicada, la computación y la educación.

Se aplicaron tres métodos complementarios: teórico, inductivo-deductivo y analítico-sintético. El método teórico permitió identificar, definir y contrastar las categorías conceptuales clave del campo investigado, como el modelado matemático, el aprendizaje automático y optimización algorítmica (Romero et al., 2021). Este método facilitó la construcción de un marco conceptual que articuló los fundamentos matemáticos con los principios operativos de la

inteligencia artificial. El método inductivo-deductivo posibilitó extraer generalizaciones a partir de estudios particulares (inducción), y aplicar teorías matemáticas generales al análisis de casos específicos documentados (deducción), generando relaciones lógicas entre datos y teoría. Por su parte, el método analítico-sintético permitió descomponer los modelos de IA en sus componentes matemáticos (análisis) y, posteriormente, integrarlos en una comprensión estructural del funcionamiento algorítmico (síntesis). Esta combinación metodológica favoreció una aproximación integral y crítica, permitiendo conectar los marcos teóricos con las aplicaciones prácticas de la inteligencia artificial sustentadas en matemáticas avanzadas.

La técnica utilizada fue el análisis documental, orientado al examen riguroso de fuentes escritas vinculadas al objeto de estudio. A través de esta técnica, se examinó la estructura lógica de los modelos matemáticos utilizados en inteligencia artificial, se contrastaron propuestas metodológicas de diferentes autores y se sistematizaron hallazgos clave que evidencian la simbiosis entre las matemáticas y los algoritmos de IA. El análisis documental permitió sustentar teóricamente las interpretaciones, identificando tendencias, limitaciones y oportunidades dentro del campo investigado. El proceso de filtrado se efectuó mediante una revisión sistemática de documentos académicos publicados entre 2020 y 2025, aplicando análisis documental, extraídos de bases de datos como Scopus, ScienceDirect, Dialnet y Scielo. Los estudios duplicados fueron eliminados y los textos seleccionados fueron sometidos a doble lectura independiente, evaluando la coherencia metodológica, validez interna, claridad en los objetivos y consistencia entre resultados y marcos teóricos empleados.

### Resultados y Discusión

La tabla ofrece una ampliación del análisis al organizar las estructuras teóricas subyacentes tanto a los modelos matemáticos como a los sistemas de inteligencia artificial, complementadas con ejemplos prácticos de su implementación conjunta y los beneficios identificados en cada estudio. Este enfoque relacional permite comprender la lógica

integradora que articula los principios matemáticos con la operación computacional de la IA, revelando patrones de complementariedad funcional. La información ha sido extraída exclusivamente para delinear un marco conceptual claro de los fundamentos que sustentan la colaboración entre ambas disciplinas. (ver tabla 1):

**Tabla 1.** Estructuras teóricas de los modelos matemáticos y sistemas de IA

Autor y año	Estructuras Teóricas		Aplicaciones prácticas	Beneficios derivados
	Modelos matemáticos	Sistemas de IA		
(Ranjan et al., 2021)	El modelado diferencial en redes convolucionales se sustenta en transformaciones lineales y operaciones de convolución paramétrica.	Las capas convolucionales permiten capturar jerarquías espaciales mediante filtros entrenables que operan sobre tensores de datos.	Las estructuras matemáticas permiten extraer patrones diagnósticos relevantes en imágenes médicas con alta precisión.	La integración mejora el diagnóstico automático, reduce el error humano y acelera los procesos clínicos en tiempo real.
(Cinar y Natarajan, 2022)	Se fundamentan en funciones de pérdida, optimización estocástica y series temporales mediante modelos autoregresivos.	Las redes neuronales recurrentes modelan dependencias a largo plazo mediante estados ocultos y ciclos de retroalimentación.	Los modelos matemáticos controlan la sensibilidad de predicciones frente a ruidos en datos temporales.	El beneficio radica en la capacidad adaptativa de los sistemas IA a entornos dinámicos sin pérdida de consistencia.
(Okoro et al., 2022)	Se emplean estructuras algebraicas y métricas de similitud para formalizar modelos explicativos.	Los mecanismos de atención modelan prioridades cognitivas simulando procesos de focalización humana.	Las expresiones matemáticas permiten generar explicaciones visuales coherentes de las decisiones de IA.	Se potencia la transparencia del sistema, facilitando su implementación en entornos críticos como salud y justicia.
(Panqueban y Huincahue, 2024)	Los modelos se construyen con matrices de correlación y lógica difusa aplicada a sistemas adaptativos.	Se utilizan redes <i>feedforward</i> ajustadas mediante retro propagación para adaptar contenidos.	Se modelan niveles de desempeño mediante funciones sigmoideas y curvas de aprendizaje.	Se promueve la equidad cognitiva, permitiendo que estudiantes con baja habilidad matemática mejoren sus resultados.
(León, 2024)	Las matrices de transición y análisis factorial sustentan los modelos predictivos para ambientes escolares.	Las arquitecturas multicapa combinan procesamiento supervisado y no supervisado para la clasificación de trayectorias de aprendizaje.	Se aplican funciones de costo y regularización que controlan el sobreajuste y permiten estabilidad del sistema.	Se optimiza la personalización del aprendizaje, facilitando la toma de decisiones docentes fundamentadas.
(Davis et al., 2022)	Los modelos se fundamentan en teoría de grafos, dinámica no lineal y álgebra tensorial.	Las redes generativas adversarias simulan la generación neuronal de estímulos en ambientes complejos.	Se integran ecuaciones diferenciales para modelar la activación sináptica y generar simulaciones cerebrales.	Se avanza en la comprensión de procesos mentales, reduciendo el margen de error en modelos cognitivos artificiales.
(Borja et al., 2025)	Se emplean técnicas de <i>clustering</i> y análisis de componentes principales basadas en álgebra lineal.	Se articulan árboles de decisión con modelos híbridos de clasificación estadística.	Se diseñan sistemas de predicción del rendimiento académico con base en agrupamientos geométricos.	Se mejora la anticipación de riesgos de deserción escolar y el diseño de intervenciones tempranas.
(Lindqwister et al., 2021)	Se estructuran con operadores matriciales, cálculo vectorial y gradientes descendentes.	Las redes convolucionales profundas organizan capas con filtros jerárquicos que reducen dimensionalidad sin perder información crítica.	Se modela la clasificación de imágenes por medio de convoluciones entrenadas con miles de parámetros ajustados.	Se incrementa la eficiencia computacional y la capacidad de generalización de los modelos IA en contextos complejos.

Fuente: elaboración propia

En esta sistematización, se abordan perspectivas diversas de cómo puede integrarse

el uso de modelos matemáticos dentro de los sistemas de inteligencia artificial (IA), cada

aporte examina no solo la problemática desde su contexto, sino que ofrece respuestas teóricas y empíricas a la pregunta central de la investigación, detallando de qué manera se articula dicha integración y cuál es la naturaleza relacional entre ambas estructuras. La codificación del análisis cualitativo se orientó a

extraer las contribuciones más representativas, respetando los criterios de rigurosidad teórica, aplicabilidad metodológica y validez argumentativa de los hallazgos reportados en las fuentes primarias seleccionadas. (ver tabla 2):

**Tabla 2.** *Tntegración de los modelos matemáticos en los sistemas de IA*

Autor y año	¿Cómo puede integrarse de manera efectiva el uso de modelos matemáticos en los sistemas de inteligencia artificial?	Relación entre los modelos matemáticos y la inteligencia artificial (IA)?
(Ranjan et al., 2021)	La integración efectiva ocurre mediante estructuras algebraicas que guían algoritmos de clasificación supervisada. Esto permite una toma de decisiones más precisa en sistemas diagnósticos, adaptando los modelos matemáticos a datos clínicos masivos mediante aprendizaje automático.	Los modelos matemáticos formalizan la incertidumbre diagnóstica mediante funciones probabilísticas. Estos esquemas son operativos en redes neuronales que ajustan sus pesos a partir de estimaciones diferenciales fundamentadas en datos clínicos codificados.
(Cinar & Natarajan, 2022)	Se promueve la integración mediante el uso de funciones convexas y restricciones algebraicas que optimizan la imparcialidad del algoritmo sin sacrificar rendimiento predictivo. El control matemático de parámetros evita sesgos latentes en la IA.	La IA ajusta sus algoritmos a través de derivadas y matrices que representan datos complejos. La relación reside en la estructura matemática de las funciones objetivo que delimitan el comportamiento del modelo, asegurando equidad operativa.
(Okoro et al., 2022)	La integración se logra modelando el comportamiento neuronal mediante ecuaciones diferenciales que simulan flujos de activación. Esto refuerza la eficiencia en redes profundas, donde la matemática actúa como lenguaje estructurador de patrones visuales.	La IA procesa imágenes codificadas en matrices mediante operadores matemáticos. Esta relación implica que cada nodo de la red responde a una función matemática específica que representa una transición lógica entre estímulo y decisión.
(Panqueban & Huincahue, 2024)	Se integran modelos matemáticos basados en álgebra relacional para personalizar la enseñanza de acuerdo con el nivel de razonamiento lógico del estudiante. Esto permite una retroalimentación adaptativa fundamentada en trayectorias estadísticas individuales.	La IA opera con estructuras probabilísticas que emulan el progreso del aprendizaje. Las matemáticas definen las variables latentes del proceso cognitivo, generando un bucle de mejora constante entre datos, evaluación y predicción pedagógica.
(León, 2024)	Se emplean algoritmos de aprendizaje profundo con soporte en geometría diferencial para modelar contextos de aprendizaje no lineales. Los modelos matemáticos organizan el espacio de datos mediante estructuras topológicas que orientan el comportamiento del sistema.	IA y matemáticas convergen en la construcción de mapas de decisión que responden a transformaciones vectoriales. Esta relación permite representar con precisión los patrones de aprendizaje en estudiantes de alto riesgo académico.
(Davis et al., 2022)	La integración se da mediante lógica difusa y teoría de grafos para simular procesos de razonamiento humano. Los modelos matemáticos actúan como marco de referencia para codificar inferencias complejas en entornos inciertos.	La IA aplica operaciones lógicas sobre estructuras formales definidas por grafos. La relación es sinérgica, ya que el sistema ajusta su lógica en función de axiomas matemáticos que rigen su arquitectura cognitiva artificial.
(Borja et al., 2025)	La integración ocurre mediante ecuaciones lineales multivariadas que permiten modelar el rendimiento académico. Los sistemas de IA incorporan matrices de correlación para anticipar trayectorias educativas divergentes con base en datos contextuales.	La IA traduce las correlaciones matemáticas en reglas operativas que estructuran decisiones automatizadas. Las matemáticas sustentan la capacidad predictiva de la IA y definen los umbrales de actuación del algoritmo.
(Lindqwister et al., 2021)	Se integra el uso de modelos matemáticos mediante visualizaciones vectoriales y aproximaciones estadísticas que permiten interpretar los resultados de IA. La integración asegura transparencia y validación en sistemas automatizados complejos.	La IA funciona como un sistema de inferencia basado en estadística inferencial. La relación con las matemáticas se expresa en el uso de herramientas como funciones de densidad, intervalos de confianza y análisis multivariable para interpretar su salida.

Fuente: elaboración propia

Martínez et al. (2023), defienden que los modelos matemáticos constituyen la arquitectura lógica sobre la cual se sostiene toda estructura de inteligencia artificial, enfatizando la relevancia de funciones de activación, operadores matriciales y estructuras estadísticas. Esta visión encuentra eco directo en el estudio de Ranjan et al. (2021), quien

argumenta que las operaciones de convolución paramétrica, basadas en álgebra lineal y cálculo vectorial, no solo optimizan la representación de datos biomédicos, sino que incrementan la precisión diagnóstica y traslada la abstracción teórica hacia una funcionalidad clínica de alta exigencia técnica. Desde otra perspectiva, Cinar y Natarajan (2022) identifican que los modelos

matemáticos basados en series temporales, funciones de pérdida y optimización estocástica permiten al sistema ajustarse a entornos no estacionarios. En esta línea, estos autores reafirman lo expuesto por Valenzuela y Sepúlveda (2022), quienes destacan la importancia del modelado multivariado en procesos predictivos, pero introduce la adaptabilidad como núcleo funcional. Cinar y Natarajan (2022) se posiciona como ampliador del marco clásico al situar las estructuras matemáticas en escenarios dinámicos. En el plano pedagógico, Panqueban y Huincahue (2024), proponen una aplicación de la lógica difusa y de la modelación por funciones sigmoidales para atender a estudiantes con baja capacidad lógico-matemática.

Su aporte no solo ratifica los postulados de Morandini (2021), quien plantea el uso de modelos para personalizar el aprendizaje, sino que los lleva a un escenario de vulnerabilidad educativa. Panqueban y Huincahue (2024), integran, a partir de las matemáticas, un modelo de justicia cognitiva que no está formulado explícitamente en la teoría, aunque es coherente con sus principios. Borja et al. (2025) destacan que el análisis de componentes principales y el agrupamiento geométrico son efectivos para predecir conductas de deserción escolar. Su estudio fortalece la propuesta de Carrillo et al. (2021), al demostrar que estructuras algebraicas aplicadas a minería de datos mejoran la capacidad anticipatoria de los sistemas IA. Borja et al. introduce la variable preventiva como aplicación práctica que, aunque implícita en el marco teórico, cobra operatividad al ser cuantificada en contextos educativos. Desde una perspectiva neurocomputacional, Davis et al. (2022) utiliza álgebra tensorial, dinámica no lineal y redes generativas adversarias para modelar estímulos sinápticos artificiales. Su enfoque trasciende lo señalado por López et al.

(2023), quien se centró en el aprendizaje profundo con base en redes neuronales multicapa. Davis et al. incorpora estructuras teóricas no convencionales que expanden el campo de las matemáticas aplicadas a la IA más allá de la educación y el diagnóstico.

En el ámbito de la transparencia algorítmica, Okoro et al. (2022) introduce estructuras algebraicas y métricas de similaridad para garantizar explicabilidad, su planteamiento responde a un vacío señalado en el documento base, en el que la transparencia se menciona como desafío, pero no se resuelve desde una perspectiva matemática formal, los autores llenan este vacío mediante el diseño de representaciones visuales coherentes basadas en formalismos matemáticos. Finalmente, Lindqwister et al. (2021) enfatiza que la eficiencia computacional y la capacidad de generalización de los modelos se logra mediante operadores diferenciales y estructuras jerárquicas en redes convolucionales. Su planteamiento coincide con los postulados de Pineda et al. (2023), al señalar que las matemáticas no son meros soportes estructurales, sino vectores de evolución funcional dentro del sistema. En conjunto, los hallazgos reafirman el marco teórico general, aunque lo amplían en dimensiones aplicadas, pedagógicas, cognitivas y funcionales, consolidando así la tesis de que la interacción entre matemáticas e inteligencia artificial es tanto estructural como transformadora.

### **Conclusiones**

En consecuencia, la convergencia entre los paradigmas de modelación matemática y los sistemas de inteligencia artificial no obedece únicamente a una relación instrumental, sino que reclama una transformación epistemológica en la cual las estructuras formales se vuelven mecanismos funcionales de adaptación,

anticipación y aprendizaje. Esta integración revela un transitar desde un formalismo abstracto hacia una acción contextualizada donde las matemáticas dejan de ser un recurso exclusivamente descriptivo para convertirse en algo que se puede usar para operar, ajustar y evolucionar dentro de sistemas inteligentes y dinámicos. Para la validez de estructuras como redes neuronales, series temporales o álgebra tensorial, si bien estos se sustentan sobre bases teóricas, su pertinencia práctica en contextos educativos, clínicos o cognitivos demuestra que su aplicabilidad depende en última instancia de la resolución de problemas, esto significa que su precisión técnica no debe ser desconectada de la relación ética con la solución provista, interpretabilidad, sostenibilidad y aceptabilidad de la propuesta resultante. Por lo tanto, los modelos predictivos no pueden estar apartados de la lógica y las matemáticas que los sustentan, ni los algoritmos de IA pueden funcionar sin una estructura formalmente comprobable, su integración efectiva requiere un nivel avanzado de alfabetización matemática por parte de quienes crean y utilizan las tecnologías inteligentes. Por último, los hallazgos invitan a reconsiderar los límites entre la matemática aplicada, la ciencia de datos y la inteligencia artificial, formulando así una agenda destinada a refinar los modelos mientras se reconoce su papel en la transformación del conocimiento, los procesos de toma de decisiones y el acceso equitativo a soluciones tecnológicas avanzadas.

### **Referencias Bibliográficas**

- Bolaño, M., & Duarte, N. (2024). Una revisión sistemática del uso de la inteligencia artificial en la educación. *Revista Colombiana de Cirugía*, 39(1), 51–63. <https://doi.org/10.30944/20117582.2365>
- Borja, N., Chasiliquin, L., Grados, M., Toro, J., & Vera, M. (2025). El Uso de Inteligencia Artificial para Fomentar la resolución de Problemas en Estudiantes con Baja Capacidad de Razonamiento. *Revista Veritas de Difusión Científica*, 6(1), 1649–1670. <https://doi.org/10.61616/rvdc.v6i1.476>
- Cinar, A., & Natarajan, N. (2022). An artificial neural network optimized by grey wolf optimizer for prediction of hourly wind speed in Tamil Nadu, India. *Intelligent Systems with Applications*. <https://doi.org/10.1016/j.iswa.2022.200138>
- Cohen, N., & Gómez, G. (2019). *Metodología de la investigación, ¿para qué?: la producción de los datos y los diseños*. Editorial Teseo. [https://biblioteca.clacso.edu.ar/clacso/se/20190823024606/Metodologia\\_para\\_que.pdf](https://biblioteca.clacso.edu.ar/clacso/se/20190823024606/Metodologia_para_que.pdf)
- Davis, G., Katz, G., Gentili, R., & Reggia, J. (2022). NeuroLISP: High-level symbolic programming with attractor neural networks. *Neural Networks*, 146, 200–219. <https://doi.org/10.1016/j.neunet.2021.11.009>
- Fortea, M. (2019). Metodologías Didácticas para la Enseñanza. *Unitat de Suport Educatiu (USE)*, 1–24.
- García, J. (2015). Teoría de colas (Universidad Politécnica de Valencia).
- Guishca, L., Bernal, A., Martínez, M., Pinargote, V., Alcívar, V., Pinargote, V., Pisco, J., & Cárdenas, V. (2024). Integración de la inteligencia artificial en la enseñanza de matemáticas un enfoque personalizado para mejorar el aprendizaje. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 818–839.
- Hadi, M., Martel, C., Huayta, F., Rojas, R., & Arias, J. (2023). Metodología de la investigación: Guía para el proyecto de tesis. In Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú S.A.C. <https://doi.org/10.35622/inudi.b.073>
- León, I. (2024). La enseñanza de la matemática universitaria de la mano de la inteligencia artificial. *Ciencia Latina Revista Científica Multidisciplinar*, 8(6), 10434–10446. [https://doi.org/10.37811/cl\\_rcm.v8i6.15723](https://doi.org/10.37811/cl_rcm.v8i6.15723)
- Lescano, A., Betsabe, S., & Wilfrido, G. (2024). Integration of Emerging Digital Technologies to Enhance the Teaching-Learning Process in the Robotics Subject

- within Technological Education. *Journal Scientific Investigar*, 8(4), 247–274. <https://doi.org/10.56048/MQR20225.8.4.2024.247-274>
- Lindqwister, A., Hassanpour, S., Lewis, P., & Sin. (2021). AI-RADS: An Artificial Intelligence Curriculum for Residents. *Academic Radiology*, 28(12), 1810–1816. <https://doi.org/10.1016/j.acra.2020.09.017>
- Lombeida, M., Bermúdez, A., Moreira, M., & Hoheb, C. (2025). The role of mathematical simulation in artificial intelligence for video games. *Polo Del Conocimiento*, 10(4), 62–73. <https://doi.org/10.23857/pc.v10i4.9294>
- Morandini, S., Fraboni, F., De Angelis, M., Puzzo, G., Giusino, D., & Pietrantonio, L. (2023). The impact of artificial intelligence on workers' skills: Upskilling and reskilling in organisations. *Informing. Informing Science: The International Journal of an Emerging Transdiscipline*, 26(0), 39–68. <https://doi.org/10.28945/5078>
- Ñaupas, H., Valdivia, M., Palacios, J., & Romero, H. (2018). Metodología de la investigación cuantitativa-cualitativa y redacción de la tesis. *In Ediciones de la U* 54(9) <https://doi.org/10.1017/CBO9781107415324.004>
- Núñez, C., Veloz, V., Agualongo, L., & Bayas, E. (2023). Integración de la Inteligencia Artificial en la Educación para el Desarrollo Sostenible: Oportunidades y Desafíos. *Magazine de las Ciencias: Revista de Investigación e Innovación*, 8(4), 96–108. <https://doi.org/10.33262/rmc.v8i4.2959>
- Okoro, E., Obomanu, T., Sanni, S., Olatunji, D., & Igbinedion, P. (2022). Application of artificial intelligence in predicting the dynamics of bottom hole pressure for under-balanced drilling: Extra tree compared with feed forward neural network model. *Petroleum*, 8(2), 227–236. <https://doi.org/10.1016/j.petlm.2021.03.001>
- Pacha, N., Barba, H., & Sevilla, L. (2024). Análisis sistemático de integración de inteligencia artificial en el aprendizaje de la robótica en la educación secundaria. *Universidad, Ciencia y Tecnología*, 28(123), 111–121. <https://doi.org/10.47460/uct.v28i123.811>
- Panqueban, D., & Huincahue, J. (2024). Artificial Intelligence in Mathematics Education: A Systematic Review. *UNICIENCIA*, 38(1), 1–18. <https://doi.org/10.15359/ru.38-1.20>
- Pantsar, M. (2023). Developing Artificial Human-Like Arithmetical Intelligence (and Why). *Minds and Machines*, 33(3), 379–396. <https://doi.org/10.1007/s11023-023-09636-y>
- Ranjan, R., Partl, R., Erhart, R., Kurup, N., & Schnidar, H. (2021). The mathematics of erythema: Development of machine learning models for artificial intelligence assisted measurement and severity scoring of radiation induced dermatitis. *Computers in Biology and Medicine*, 139, 104952. <https://doi.org/10.1016/j.combiomed.2021.104952>
- Rivas, J., Cevallos, C., & Llange, Z. (2024). Uso de modelos de inteligencia artificial en la optimización de la enseñanza de matemáticas en la educación superior. *REINCISOL*, 3(6), 4334–4355. [https://doi.org/10.59282/reincisol.V3\(6\)4334-4355](https://doi.org/10.59282/reincisol.V3(6)4334-4355)
- Romero, H., Real, J., & Ordoñez, L. (2021). Metodología de la Investigación. In *Edicumbre* 1(1) [https://www.gob.mx/cms/uploads/attachment/file/133491/METODOLOGIA\\_DE\\_INVESTIGACION.pdf](https://www.gob.mx/cms/uploads/attachment/file/133491/METODOLOGIA_DE_INVESTIGACION.pdf)
- Sachini, E., Sioumalas-Christodoulou, K., Christopoulos, S., & Karampekios, N. (2022). AI for AI: Using AI methods for classifying AI science documents. *Quantitative Science Studies*, 3(4), 1119–1132. [https://doi.org/10.1162/qss\\_a\\_00223](https://doi.org/10.1162/qss_a_00223)
- Silador, R. (2023). Manual de Investigación (pp. 1–51). Instituto Superior Tecnológico Universitario. <https://tecnologicolezaeta.edu.ec/wp-content/uploads/2023/09/MANUAL-DE-INVESTIGACION-2023-1.pdf>
- Tóala, M., Giler, J., & Gutiérrez, J. (2024). Las matemáticas y el uso de la inteligencia artificial. *Revista UNESUM-Ciencias*, 8(3),

16–23. <https://doi.org/10.47230/unesum-ciencias.v8.n3.2024.16-23>

Villena, C., Calsin, W., Espinoza, D., & Rengifo, J. (2024). Aplicación de la inteligencia artificial en la resolución de problemas matemáticos en el nivel universitario. *Revista Social Fronteriza*, 4(5), 1–20.

[https://doi.org/10.59814/resofro.2024.4\(5\)e458](https://doi.org/10.59814/resofro.2024.4(5)e458)



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Mario Alberto Ibarra Martínez, Carla Guillermina Mendoza Arce y Manuel Eduardo López Delgado.

