Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

REVISTA CIENTÍFICA VISIÓN ACADÉMICA https://visionacademica.com/

DOI: https://doi.org/10.70577/kez28y64

Aplicación del álgebra lineal en el desarrollo de modelos de inteligencia artificial y aprendizaje automático

Application of linear algebra in the development of artificial intelligence and machine learning models

Evelyn Pamela Fonseca Bautista[1]
Investigador Independiente
Salcedo - Cotopaxi - Ecuador
p-ame0108@hotmail.com
https://orcid.org/0009-0006-7707-8238

Ilka Pionet Bermudez Zambrano[2]
Docente del Distrito D17H06
ilka.bermudez@educacion.gob.ec
https://orcid.org/0009-0005-3341-6525

Omar Diego Herrera Navas[3]
Docente del Distrito D17H06
omar.herrera@educacion.gob.ec
https://orcid.org/0009-0006-2489-7993

Cómo citar:

Fonseca Bautista, E. P. ., Bermudez Zambrano, . I. P., & Herrera Navas, O. D. (2026). Aplicación del álgebra lineal en el desarrollo de modelos de inteligencia artificial y aprendizaje automático. *Visión Académica*, *4*(4), 526-549. https://doi.org/10.70577/kez28y64

Fecha de recepción: 2026-10-20

Fecha de aceptación: 2026-11-03

Fecha de publicación: 2026-11-17

RESUMEN

El álgebra lineal es uno de los fundamentos matemáticos dentro del desarrollo de los modelos de inteligencia artificial y aprendizaje automático, dado que su aplicación en la representación de los datos, el procesamiento de la información y la optimización de los algoritmos. Sus operaciones permiten la comprensión del funcionamiento de las arquitecturas computacionales como las redes neuronales y los modelos de regresión.

Analizar la aplicación del álgebra lineal en el desarrollo de los modelos de inteligencia artificial y aprendizaje automático, por medio de la identificación de los principales fundamentos matemáticos y el uso de los procesos de representación, optimización y procesamiento de algoritmos.

Se desarrolló la investigación sistemática de la literatura científica en relación con la aplicación del álgebra lineal en los modelos de la inteligencia artificial y el aprendizaje automático. El procedimiento de la selección se organizó de acuerdo con las directrices PRISMA 2020,

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

basándose en los criterios de inclusión y exclusión para la identificación y selección de los documentos.

La investigación identificó que los vectores, los tensores y las matrices intervienen en la representación y el procesamiento de los datos, a la vez, que las transformaciones lineales y las descomposiciones matriciales permiten el desarrollo de los procedimientos de la reducción de la dimensionalidad y la extracción de las características. A la vez, se reconoció la aplicación de los modelos de regresión, las máquinas de soporte vectorial, las redes convolucionales, las redes neuronales artificiales, las redes neuronales de grafos y las arquitecturas transformer. A la vez, se identificaron los procedimientos de optimización computacional, como la utilización de las matrices dispersas y el procesamiento paralelo, que contribuyen a la mejora de la eficiencia de los algoritmos.

Los hallazgos evidenciaron que el álgebra lineal no se limita a la operación específica, sino que interviene de forma transversal en las arquitecturas de la inteligencia artificial y el aprendizaje automático.

El álgebra lineal constituye una base matemática esencial en el desarrollo de los modelos de IA y el aprendizaje automático, dado que permite la organización de los datos, la ejecución de las operaciones computacionales y la optimización de los algoritmos.

Palabras clave: Álgebra lineal, aprendizaje automático, inteligencia artificial, modelos, procesamiento de algoritmos.

ABSTRACT

Linear algebra is a fundamental mathematical pillar in the development of artificial intelligence and machine learning models, as it is applied to data representation, information processing, and algorithm optimization. Its operations facilitate an understanding of how computational architectures—such as neural networks and regression models—function.

To analyze the application of linear algebra in the development of artificial intelligence and machine learning models by identifying key mathematical foundations and examining processes related to data representation, optimization, and algorithmic processing.

A systematic review of scientific literature regarding the application of linear algebra in artificial intelligence and machine learning models was conducted. The selection process followed the PRISMA 2020 guidelines, utilizing specific inclusion and exclusion criteria to identify and select relevant documents.

The research identified that vectors, tensors, and matrices are integral to data representation and processing. Furthermore, linear transformations and matrix decompositions enable techniques such as dimensionality reduction and feature extraction. The study also highlights the application of linear algebra in regression models, support vector machines, convolutional neural networks,

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

artificial neural networks, graph neural networks, and transformer architectures. Additionally, computational optimization techniques—such as the use of sparse matrices and parallel processing—are identified as contributing to improved algorithmic efficiency.

The findings demonstrate that linear algebra is not confined to isolated operations; rather, it plays a cross-cutting role across artificial intelligence and machine learning architectures. Conclusions: Linear algebra serves as an essential mathematical foundation for the development of AI models and machine learning, as it enables data organization, the execution of computational operations, and the optimization of algorithms.

Keywords: Linear algebra, machine learning, artificial intelligence, models, algorithm processing.

INTRODUCCIÓN

La inteligencia artificial (IA) se ha convertido en un campo de desarrollo científico y tecnológico que permite la creación de los sistemas capaces del procesamiento de información, identificación de patrones y ejecución de las tareas que necesitan determinados niveles de aprendizaje y análisis. En este campo, el aprendizaje automático (machine learning) ocupa un lugar importante, dado que usa algoritmos que identifican las relaciones de los datos para la predicción o clasificación. Aunque estos procesos suelen asociarse especialmente con la programación y la capacidad computacional, el funcionamiento también tiene dependencia de los fundamentos matemáticos que permiten la representación, la transformación y el análisis de grandes cantidades de información. Entre los fundamentos se encuentran el álgebra lineal, cuya aplicación es importante para el diseño y funcionamiento de los numerosos modelos de inteligencia artificial (Baggag & Saad, 2025).

La relación entre el álgebra lineal y la inteligencia artificial se evidencia en las operaciones que permiten la organización de los datos, el establecimiento de las relaciones entre las variables y la modificación de los parámetros de los algoritmos en el entrenamiento. Los vectores permiten la representación de las características de los datos, a la vez que las matrices y los tensores facilitan el procesamiento y almacenamiento de grandes cantidades de la información. De manera similar, en base a Baggag y Saad (2025), la multiplicación matricial, las descomposiciones matriciales, las transformaciones lineales, los valores y vectores propios intervienen en diversos procedimientos de aprendizaje automático y aprendizaje profundo. Estas operaciones toman importancia en las redes neuronales, las redes neuronales y los modelos Transformer, cuyas arquitecturas necesitan cálculos algebraicos para el procesamiento de información y la generación de resultados.

Con respecto a los antecedentes científicos, Brito et al. (2025) generaron una investigación acerca del papel del álgebra lineal avanzada en el aprendizaje de algoritmos de machine learning. Por medio del análisis bibliométrico de 895 artículos recopilados en Scopus, identificando la importancia de los fundamentos matemáticos en la eficiencia, diseño y precisión de los modelos. Entre los aportes principales se tiene el uso de matrices, transformaciones

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

lineales y vectores como las herramientas necesarias en la optimización del funcionamiento de los algoritmos. Esto permite reconocer que el conocimiento del álgebra lineal no constituye únicamente el requisito matemático, sino la base de la comprensión y mejora de los procedimientos computacionales usados en la IA.

De forma complementaria, Guzmán et al. (2025), realizaron la revisión bibliométrica de la relación de la inteligencia artificial y el álgebra lineal, por medio de la consulta de publicaciones científicas. La investigación revisó 496 documentos en el análisis, identificando las principales líneas temáticas de la fundamentación matemática del álgebra lineal y la aplicación en las redes neuronales y el aprendizaje autónomo. A la vez, señalan la baja proporción de las colaboraciones internacionales, evidenciando la importancia del fortalecimiento de la cooperación científica en dicha área. Estos resultados son un antecedente esencial en la profundización de la relación de los conceptos algebraicos con el desarrollo de los modelos inteligentes.

En el contexto latinoamericano, el desarrollo de la IA constituye un avance en la investigación científica, aunque la producción no se distribuye de forma homogénea entre los países. Carrasco et al. (2025), en el estudio acerca de la producción científica de inteligencia artificial dentro del periodo 2020- 2025 identificaron la concentración de publicaciones en Brasil, con 45,8%, México con 18,46%, Colombia con 9,41% y Chile con 8,93%. Los resultados ubican a Ecuador con una participación de 5,09%, representando una presencia menor con respecto a los países que lideran la producción científica regional. No obstante, pese al crecimiento de las publicaciones, aún se tienen diferencias estructurales en la capacidad investigativa y la visibilidad internacional. Esto constituye un desafío en el fortalecimiento de las investigaciones realizadas con la IA y los fundamentos matemáticos, entre ellos el álgebra lineal, en la que su comprensión resulta necesaria en el desarrollo y optimización de modelos de aprendizaje automático.

En Ecuador, el problema se manifiesta en la necesidad del fortalecimiento del desarrollo científico y la comprensión de los fundamentos matemáticos intervinientes en las aplicaciones de la IA. Aunque se tienen investigaciones nacionales con relación al aprendizaje automático, estas abordan los diversos aspectos de la aplicación y el funcionamiento. Mendoza y Macías (2024), en su revisión de los tipos de datos, los algoritmos usados y las métricas del rendimiento, evidencian que se tienen aplicaciones acerca de la IA y el aprendizaje automático en el país; No obstante, permite la identificación de la necesidad de la profundización en la relación de las operaciones del álgebra lineal y procedimientos usados en el desarrollo de estos modelos. La representación de los datos por medio de matrices y vectores, las descomposiciones matriciales son elementos que necesitan una explicación articulada para la comprensión de la manera en que se construyen, ejecutan y entrenan los algoritmos. Por lo tanto, es pertinente el análisis de esta relación bajo la perspectiva matemática y computacional, teniendo en cuenta las aplicaciones existentes y los fundamentos que permiten el funcionamiento.

La importancia de abordar la temática se justifica bajo el ámbito científico, académico y tecnológico. Dentro del campo científico, permite analizar y reunir las investigaciones recientes

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

que explican la participación del álgebra lineal bajo el desarrollo de los modelos de la inteligencia artificial y el aprendizaje automático. Bajo la perspectiva tecnológica, se contribuye en la comprensión de las operaciones matemáticas que intervienen en el procesamiento de los datos, la optimización de los algoritmos y el favorecimiento de la articulación entre los conocimientos matemáticos y computacionales, permitiendo reconocer que el álgebra lineal no es solo un contenido teórico, sino la herramienta esencial para la comprensión de los avances actuales de la inteligencia artificial.

La relevancia del estudio está en la relación directa de los fundamentos matemáticos y los avances actuales de la IA, bajo la perspectiva de que el álgebra lineal es una de las bases en el desarrollo de los modelos capaces de aprender, generar predicciones y procesar la información. El estudio permite la comprensión de los procedimientos matemáticos que se ejecutan internamente en los algoritmos, así como el reconocimiento de la importancia de las operaciones matriciales y vectoriales en las arquitecturas del aprendizaje automático. A su vez, toma relevancia en el contexto científico actual debido a su contribución a una comprensión más profunda de las tecnologías que poseen las aplicaciones de diversas áreas del conocimiento, como la ingeniería, la medicina, la economía y las ciencias informáticas.

La utilidad del presente documento se centra en la organización y explicación de los principales conceptos del álgebra lineal que intervienen bajo el desarrollo de los modelos de inteligencia artificial y el aprendizaje automático, con relación a los fundamentos teóricos con las aplicaciones computacionales concretas. La información recopilada permitirá la identificación del uso de los vectores, las transformaciones lineales, las matrices y las descomposiciones matriciales de los procesos de representación de datos, el entrenamiento de las redes neuronales y la optimización de algoritmos. A su vez, el análisis podrá servir como material de la consulta académica para los estudiantes e investigadores interesados dentro de la comprensión de las bases matemáticas de la inteligencia artificial y el fortalecimiento de la aplicación de los conocimientos del álgebra lineal dentro del campo de la computación.

Bajo este sentido, el alcance del artículo se basa en el análisis de las principales aplicaciones del álgebra lineal en el desarrollo de los modelos de inteligencia artificial y el aprendizaje automático, considerando como referencia las publicaciones científicas comprendidas entre 2021 y 2025. El estudio se centra en los conceptos de vectores, valores y vectores propios, matrices, tensores, transformaciones lineales, espacios vectoriales, descomposiciones matriciales y la relación con técnicas de reducción dimensional. A su vez, considera la aplicación en modelos de regresión, redes neuronales de grafos y aprendizaje. De esta forma, se busca la explicación de la contribución de los fundamentos matemáticos en la representación y la optimización de modelos computacionales sin límites del análisis a una sola arquitectura o aplicación tecnológica.

A la vez, a partir de la problemática identificada, el objetivo del presente artículo es analizar la aplicación del álgebra lineal en el desarrollo de los modelos de inteligencia artificial y aprendizaje automático, por medio de la identificación de los principales fundamentos matemáticos y el uso

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

de los procesos de representación, optimización y procesamiento de algoritmos. En correspondencia con este propósito, se detalla la pregunta: ¿Cómo se aplica el álgebra lineal en el desarrollo de modelos de inteligencia artificial y aprendizaje automático, y de qué manera contribuye a los procesos de representación, procesamiento y optimización de los algoritmos?

MATERIAL Y MÉTODOS

El presente artículo se desarrolla por medio de la revisión sistemática de la literatura científica, orientada al análisis de la aplicación del álgebra lineal dentro del desarrollo de los modelos de inteligencia artificial y aprendizaje automático. De esta manera, el proceso metodológico se basa en las directrices de Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA 2020), citada por Page et al. (2025), con la finalidad de organizar las etapas de selección, identificación, evaluación y síntesis de los documentos científicos. A la vez, la revisión considera las investigaciones en relación con los fundamentos matemáticos del álgebra lineal y el uso dentro de los procedimientos computacionales de la inteligencia artificial, especialmente dentro de la representación de los datos, el procesamiento de la información, el entrenamiento de los modelos y la optimización de los algoritmos.

El análisis se orienta conforme a los principales elementos del álgebra lineal que intervienen dentro del funcionamiento de los modelos de aprendizaje automático, entre los que se encuentran los vectores, los espacios vectoriales, las matrices, la multiplicación matricial, los valores y vectores propios y las descomposiciones matriciales. También, se toman en cuenta las aplicaciones de diferentes técnicas y arquitecturas de inteligencia artificial, como la clasificación y los algoritmos de regresión, el aprendizaje profundo, las redes neuronales y demás modelos computacionales que necesitan de operaciones algebraicas para el procesamiento y análisis de las grandes cantidades de información.

La interpretación de los documentos considera los objetivos de los estudios, sus procedimientos metodológicos, los fundamentos matemáticos usados y los resultados con relación a la aplicación del álgebra lineal.

Fuentes de datos y estrategias de búsqueda

Para la identificación de las publicaciones científicas se consideraron las fuentes de búsqueda como Scielo, Scopus, Web of Science, Redalyc, Google Académico y Dialnet. Estas fuentes permiten la localización de las investigaciones con relación a las matemáticas aplicadas, la inteligencia artificial, el álgebra lineal, las ciencias computacionales y el aprendizaje automático. Scopus y Science contribuyen en la identificación de publicaciones científicas de alcance internacional; Scielo y Redalyc contribuye con información de revistas a nivel latinoamericano, mientras que Dialnet ayuda a la localización de la literatura académica en español y Google Académico amplía la búsqueda de artículos científicos y demás documentos académicos con vínculos en el objeto de estudio.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

El periodo de publicación se delimita entre 2021 y 2025, teniendo en cuenta los documentos disponibles en español e inglés, cuya delimitación permite la concentración de la revisión de las investigaciones recientes acerca del desarrollo de la inteligencia artificial y los modelos de aprendizaje automático, sin dejar que se consideren los fundamentos matemáticos que explican el funcionamiento. Se genera la priorización de los estudios que establecen la relación directa entre el álgebra lineal y los procedimientos usados en los algoritmos de inteligencia artificial, así como las que presentan aplicaciones, el análisis teórico o los resultados con relación a la representación y el procesamiento de los datos.

La estrategia de búsqueda se establece por medio de los conceptos centrales de la investigación: el álgebra lineal, la inteligencia artificial, el aprendizaje automático, los modelos computacionales, las matrices, los vectores, las transformaciones lineales, las redes neuronales, el aprendizaje profundo y la optimización de algoritmos. A la vez, se consideran los equivalentes en inglés: linear algebra, artificial intelligence, machine learning, computational models, matrices, vectors, linear transformations, neural networks, deep learning y algorithm optimization. A esta razón, el uso de los dos idiomas permite que se amplíe la recuperación de las publicaciones y el reconocimiento de los aportes científicos desarrollados en los diferentes contextos académicos.

Por otra parte, la estrategia de búsqueda se estructura por la combinación de las palabras clave y operadores booleanos AND y OR para relacionar los fundamentos del álgebra lineal con las aplicaciones en los modelos de la inteligencia artificial y el aprendizaje automático. Entre las expresiones de búsqueda se consideran las siguientes:

- (""álgebra lineal" OR "matrices" OR "vectores") AND ("inteligencia artificial" OR "aprendizaje automático").
- ("álgebra lineal" OR "transformaciones lineales") AND ("machine learning" OR "modelos de aprendizaje automático").
- ("matrices" OR "operaciones matriciales" OR "espacios vectoriales") AND ("redes neuronales" OR "aprendizaje profundo").
- ("valores propios" OR "descomposición matricial" OR "reducción de dimensionalidad") AND ("inteligencia artificial" OR "machine learning").
- ("linear algebra" OR "matrix operations" OR "vector spaces") AND ("artificial intelligence" OR "machine learning").

Las expresiones se adaptan a las características de búsqueda de la plataforma, basándose en los campos de títulos, resumen y palabras clave cuando se encuentran disponibles. La identificación de los documentos se organiza por el registro de las publicaciones recuperadas y la relación de las expresiones usadas. Luego, se hace la revisión de los títulos y resúmenes, la comprobación y la identificación de los documentos duplicados con los criterios establecidos en la investigación.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

Criterios de inclusión y exclusión

La selección de los documentos se orienta por los criterios establecidos con la finalidad de garantizar la pertinencia científica y temática de las publicaciones con relación a la aplicación del álgebra lineal del desarrollo de los modelos de inteligencia artificial y el aprendizaje automático. Estos criterios permiten la delimitación de los estudios que aportan la información teórica, aplicada o metodológica acerca de los fundamentos matemáticos que intervienen en el funcionamiento de los algoritmos.

Criterios de inclusión

- Artículos científicos originales, las revisiones científicas, las investigaciones empíricas que aborden la aplicación del álgebra lineal en la inteligencia artificial o el aprendizaje automático.
- Las investigaciones que examinen el uso de los vectores, las matrices, los espacios vectoriales y las transformaciones lineales en el desarrollo de los modelos computacionales.
- Las publicaciones que realicen el análisis de las operaciones matriciales, los valores propios, los vectores propios, las descomposiciones matriciales en relación con el procesamiento de datos.
- Los estudios que expliquen la relación del álgebra lineal con los algoritmos de aprendizaje automático, los modelos de aprendizaje profundo y las redes neuronales.
- Las investigaciones que tienen aplicaciones del álgebra lineal en los procesos de representación, el entrenamiento, el procesamiento y la optimización de los modelos de la inteligencia artificial.
- Las publicaciones que estaban fuera del periodo establecido.
- Las publicaciones disponibles en diversos idiomas fuera de los considerados en la revisión.
- Los documentos que brinden información suficiente acerca de los objetivos, los fundamentos teóricos, los procedimientos metodológicos y los resultados.

Criterios de exclusión

- Las investigaciones que se centran solo en el desarrollo de los modelos de la inteligencia artificial y no explican ni establecen la relación con los fundamentos del álgebra lineal.
- Las publicaciones que consideren conceptos matemáticos sin presentar la relación directa con la inteligencia artificial o el aprendizaje automático.
- Los estudios que menciones el álgebra lineal solo de forma secundaria, sin que se analice la aplicación de los procedimientos computacionales.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

- Los documentos que presenten la información insuficiente acerca de los objetivos, la metodología, los fundamentos matemáticos o los resultados.

- Las publicaciones que no sean de artículos científicos, revisiones académicas o las investigaciones con la información verificable para el análisis.

- Las editoriales, las opiniones, las cartas al editor y los resúmenes que no tengan en cuenta la información científica para la evaluación respecto al tema.

- Los registros que lleven más de una originalidad o se encuentre duplicados en tema, resumen, metodología o versión del documento.

Procedimiento de selección de artículos

El procedimiento de selección se organizó conforme con las etapas de identificación, la eliminación de duplicados, la selección y evaluación de la elegibilidad establecidas en las directrices PRISMA. Bajo la primera etapa se identificaron 100 registros procedentes de la búsqueda bibliográfica, teniendo en cuenta las palabras clave y las combinaciones de búsqueda en función del álgebra línea, el aprendizaje y la inteligencia artificial. Cabe considerar que los documentos recuperados se organizaron para facilitar la revisión y comprobar la correspondencia con el tema investigativos.

En la segunda etapa se tuvo la identificación y eliminación de 25 registros duplicados, dado que correspondían a las publicaciones que aparecían repetidamente en las fuentes consultadas. De esta manera, el procedimiento permitió que se evite que una misma investigación se la contabilice más de una vez. Como resultado, se quedaron 75 artículos científicos para continuar con el proceso de revisión y selección.

En la tercera etapa se examinaron los temas y resúmenes de los registros disponibles, en base a los criterios de inclusión y exclusión establecidos previamente. En esta revisión se excluyeron 50 documentos dado que no cumplían con los criterios definidos en la investigación, especialmente debido a que no abordaban los fundamentos matemáticos requeridos, no tenían información suficiente acerca del objeto de estudio o no correspondían al enfoque temático establecido. Luego de esta depuración se tuvieron 25 documentos para continuar con la evaluación.

Finalmente, en la cuarta etapa se hizo la revisión más detallada de los documentos restantes, teniendo en cuenta el contenido, objetivos, los fundamentos teóricos y resultados. En esta evaluación se excluyeron 5 investigaciones por falta de pertinencia con el título, porque no desarrollaban una relación directa entre el álgebra lineal y los modelos de la inteligencia artificial o el aprendizaje automático. Al final, se establecieron 20 documentos que cumplieron las condiciones de selección y conformaron el conjunto de los estudios incluidos en el análisis de la revisión.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

Es decir, en resumen, el proceso de selección es el siguiente:

Figura 1.

Proceso de selección de los estudios.



Nota 1:

- Síntesis de los estudios revisados y el procedimiento de selección final.

Fuente: Adaptado por la metodología PRISMA 2020.

Evaluación de la calidad metodológica de los estudios

En la valoración de la calidad metodológica de los documentos seleccionados se consideraron la revisión de los elementos que permiten la determinación de la consistencia y utilidad de la información científica presentada. Para lo cual, se examinó la correspondencia de los objetivos y el contenido de la investigación, la descripción de los procedimientos usados, la claridad de los fundamentos teóricos y la relación entre los resultados y las conclusiones. Esta evaluación permite el reconocimiento de la solidez de los aportes científicos y el establecimiento si la información brindada es adecuada para que se explique la aplicación del algebra lineal bajo los modelos de inteligencia artificial y aprendizaje automático.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

La revisión también tiene en cuenta la claridad con la que los estudios describen los procesos matemáticos y computacionales empleados, así como la identificación de las operaciones algebraicas que intervienen dentro del desarrollo de los modelos. Se coloca atención a la explicación de las operaciones vectoriales y matriciales, los métodos de descomposición, las transformaciones lineales y los procedimientos de optimización por el enfoque de cada publicación.

Es por ello por lo que se procuró que los documentos incluidos tengan información verificable y relacionada con el objetivo de la investigación, lo que evita el uso de las publicaciones que solo mencionen el álgebra lineal sin la explicación de la contribución al funcionamiento de los algoritmos.

Extracción y análisis de datos

La extracción de la información se organizó por medio de una matriz de registro bibliográfico que permitió sistematizar los datos principales de los 20 documentos seleccionados. Dentro de la matriz se consideró el desarrollo del contexto, el objeto de investigación, los fundamentos de álgebra lineal abordados, los modelos de inteligencia artificial analizados, los principales resultados y las aplicaciones identificadas. La organización de dichos elementos facilita la comparación de los estudios, permitiendo el reconocimiento de los aportes específicos de la investigación con respecto al tema del artículo.

Igualmente, la información se clasificó en categorías temáticas con relación a los objetivos de la revisión. Las categorías comprenden los elementos del álgebra lineal usados en la inteligencia artificial, las matrices aplicadas al proceso de datos, las operaciones vectoriales, la representación de la información, las transformaciones lineales y el uso de los valores y vectores propios. Además, se consideran las aplicaciones de los procedimientos en algoritmos de aprendizaje automático y los modelos de aprendizaje profundo.

El análisis se desarrolló por la síntesis temática para comparar los resultados de las investigaciones, reconociendo las coincidencias, diferencias y aportes en función de la aplicación del álgebra lineal. La síntesis narrativa permite la integración de los principales hallazgos de los documentos, a su vez que la organización temática facilita la identificación de los conceptos matemáticos que intervienen en los diversos modelos computacionales. Por este proceso se examinó cómo las operaciones algebraicas ayudan a la representación de datos, el procesamiento de la información y la optimización de los modelos de la inteligencia artificial.

Por consiguiente, la interpretación de los resultados permitió el establecimiento de la visión conjunta de la relación de los fundamentos del álgebra lineal y el desarrollo de las técnicas de aprendizaje automático. Se consideraron los aportes teóricos como las aplicaciones computacionales descritas dentro de las publicaciones, con la finalidad de explicar la relevancia de las estructuras vectoriales y matriciales del funcionamiento de los modelos. En efecto, la revisión brinda una base organizada para la comprensión de la contribución del álgebra lineal en

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

el desarrollo de la inteligencia artificial y el reconocimiento de la importancia en los avances actuales de la computación.

RESULTADOS

El análisis de la literatura científica permitió la identificación de que el álgebra lineal es uno de los fundamentos matemáticos importantes en el desarrollo, entrenamiento y optimización de los modelos de inteligencia artificial y el aprendizaje automático. La aplicación no se limita a operaciones matemáticas aisladas, sino que tiene intervención en todo el funcionamiento de estos sistemas; desde la representación inicial de los datos hasta la generación de las predicciones, la clasificación de la información, el reconocimiento de los patrones y el procesamiento de las estructuras complejas.

Los resultados se organizaron considerando las principales aplicaciones identificadas: las representaciones matemáticas, la reducción de la dimensionalidad, el entrenamiento de las redes neuronales, la optimización de los modelos, el procesamiento de grafos, el funcionamiento de arquitecturas transformer y la eficiencia computacional. A partir de estos ámbitos se identificaron los problemas que pueden presentarse en el desarrollo de los modelos y las soluciones matemáticas y computacionales que permiten enfrentarlos.

Aplicación de vectores, matrices y tensores en la representación de datos

Uno de los principales resultados encontrados consiste en que los vectores, matrices y tensores permiten transformar los datos originales en las estructuras matemáticas que pueden procesarse por los algoritmos de inteligencia artificial. Los datos de imágenes, registros numéricos, textos, sensores, señales y otras fuentes deben convertirse en representaciones organizadas para que los modelos se identifiquen en relaciones y características relevantes.

En el aprendizaje automático, un conjunto de datos se puede representar por una matriz X, en la que cada fila responde a una observación y cada columna constituye una característica. Por ejemplo, en el sistema de predicción de precios de viviendas, las filas representan diferentes inmuebles y las columnas información acerca de superficie, antigüedad, número de habitantes y la ubicación codificada numéricamente. De esta manera, esta organización permite la realización de las operaciones matriciales para la identificación de patrones y el establecimiento de las relaciones entre las variables.

En las redes neuronales, los vectores constituyen las características de la observación, mientras que las matrices detallan los parámetros o pesos que determinan la transformación de los datos de las diferentes capas. Los tensores amplían esta representación cuando se trabaja con la información de mayor complejidad como las imágenes, las secuencias del texto y los conjuntos de los datos multidimensionales. Por ello, Baggag y Saad (2025), aluden que las arquitecturas de aprendizaje profundo usan las estructuras para la representación de datos, efectuar las

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

transformaciones y ejecución de los procedimientos numéricos necesarios en el entrenamiento y la inferencia.

Tabla 1.

Estructuras del álgebra lineal usadas en los modelos de inteligencia artificial.

Estructura matemática	Aplicación en inteligencia artificial	Resultado que permite obtener
Vectores	Representación de características de una observación, palabra o elemento.	Conversión de datos en valores numéricos procesables.
Matrices	Organización de conjuntos de datos y almacenamiento de pesos de las redes neuronales.	Procesamiento simultáneo de múltiples variables y observaciones.
Tensores	Representación de imágenes, secuencias y datos multidimensionales.	Tratamiento de información compleja en modelos de aprendizaje profundo.
Matriz de pesos	Transformación de las entradas entre capas neuronales.	Obtención de nuevas representaciones de los datos.
Matriz de características	Organización de las propiedades de los datos de entrada.	Identificación de patrones y relaciones entre variables.
Matrices de covarianza	Identificación de relaciones estadísticas entre variables.	Detección de redundancias y reducción de dimensionalidad.

Nota 1:

- Síntesis de los estudios del álgebra lineal usados en los modelos de IA.

Fuente: Adaptado de (Baggag & Saad, 2025)).

La aplicación de las estructuras permite la resolución del problema esencial: la dificultad del proceso de grandes cantidades de información sin la representación matemática organizada. Cuando los datos se transforman en vectores y matrices, los algoritmos pueden ejecutar las operaciones de forma sistemática, eficiente y reproducible. Por ello, la solución consiste en el establecimiento de la representación numérica adecuada antes de que se aplique los modelos, basándose de la naturaleza de los datos, sus dimensiones y las características que se pretende analizar.

Reducción de dimensionalidad por el álgebra lineal

Otro resultado importante corresponde a la reducción de la dimensionalidad, procedimiento que permite la disminución de la cantidad de variables de un conjunto de datos sin que se pierda en la medida de lo posible, la información necesaria para el aprendizaje. Este proceso es esencial debido a que los conjuntos de datos pueden contener numerosas características, algunas de las que aportan la información repetida, afectada por ruido o poco relevante.

La investigación identificó que la descomposición en valores singulares (SVD) y el análisis de los componentes principales (PCA) son procedimientos especialmente esenciales para que se aborde este problema. Los dos usan las propiedades de las matrices para la obtención de las representaciones de menor dimensión, facilitando el análisis de los datos y la disminución de la complejidad de ciertos procesos computacionales.

El PCA transforma las variables originales en las nuevas variables denominadas componentes principales que responden a la combinación lineal de las características iniciales. Estos

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

componentes se ordenan conforme con la cantidad de la variabilidad que representan. Por lo tanto, es posible conservar las dimensiones que contienen la mayor información y la reducción de aquellas que brindan una contribución menor al análisis. Greenacre et al. (2022) indica que este proceso permite que se aproxime la matriz de los datos usando un número reducido de los componentes, además de facilitar la interpretación de las relaciones de las observaciones y variables.

Por ello, la descomposición de valores singulares permite expresar la matriz por medio de tres matrices resultantes de su descomposición. Esta propiedad facilita la identificación de las estructuras de bajo rango, permitiendo aproximar los datos originales usando la cantidad menor de componentes. En los modelos de aprendizaje automático, dichas aproximaciones pueden contribuir a la disminución del almacenamiento requerido y el costo de las determinadas operaciones.

La factorización matricial también permite que se identifiquen las estructuras latentes dentro de los datos. Por ejemplo, en el sistema de recomendación, la matriz puede constituir las valoraciones que los usuarios asignan a diversos productos. Por medio de la factorización, el sistema puede estimar las características compartidas de los usuarios y productos, incluso cuando se tienen valoraciones faltantes. De acuerdo con Lin y Quan (2023), las aplicaciones de las técnicas de factorización matricial en el aprendizaje automático se centran en el procesamiento de señales y la estadística, destacando la utilidad para la representación de la información y la extracción de las estructuras relevantes.

Tabla 2.

Técnicas de álgebra lineal para la reducción de la dimensionalidad y simplificación de los datos.

Técnica	Procedimiento matemático	Problema que resuelve
Análisis de componentes principales (PCA)	Calcula componentes principales a partir de las relaciones de covarianza entre variables.	Exceso de características y redundancia de información.
Descomposición en valores singulares (SVD)	Descompone una matriz en matrices de vectores singulares y valores singulares.	Matrices de grandes dimensiones y dificultad para identificar estructuras relevantes.
Factorización matricial	Expresa una matriz como producto de matrices de menor dimensión.	Información dispersa, redundante o incompleta.
Factorización no negativa (NMF)	Descompone una matriz en componentes no negativas.	Dificultad para identificar patrones interpretables en datos no negativos.
PCA incremental	Actualiza la reducción de dimensionalidad mediante bloques de datos.	Limitaciones de memoria al procesar conjuntos de gran tamaño.
Técnica	**Procedimiento matemático**	**Problema que resuelve**

Nota 1:

- Síntesis de las técnicas del álgebra lineal conforme los procedimientos matemáticos.

Fuente: Adaptado de (Lin & Quan, 2023)

Los resultados muestran que la reducción de la dimensionalidad ayuda a simplificar los conjuntos de los datos y la mejora de la eficiencia de los procesos de aprendizaje. No obstante, la reducción de varias dimensiones provoca la pérdida de información importante. Por dicha razón, la solución

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

no se basa en la disminución indiscriminada de la cantidad de variables, sino en la selección de las dimensiones conforme con la información que conservan y con el objetivo del modelo.

Como afirma Ayaz (2025) determina que la selección inadecuada de las dimensiones puede afectar la estabilidad, la capacidad de la generalización de los modelos y la interpretabilidad. Entre las alternativas para enfrentar las dificultades se tienen la estimación de las dimensionalidades intrínsecas, el ajuste de los algoritmos y la evaluación de la estabilidad de las representaciones conforme con las características de los datos.

Aplicación de matrices en el funcionamiento y entrenamiento de las redes neuronales

Los resultados indican que las matrices son una herramienta importante en el funcionamiento de las redes neuronales, dado que permite la representación de los parámetros que intervienen en las transformaciones de la información realizada por cada capa. En el procesamiento, los datos de entrada se multiplican por las matrices de pesos y se combinan en los vectores de sesgo para la generación de nuevas representaciones.

Este procedimiento se expresa por medio de la siguiente operación:

$$h^{(l)} = \sigma\left(W^{(l)}h^{(l-1)} + b^{(l)}\right)$$

Donde:

$h^{(l)} = constituye\ la\ salida\ de\ la\ capa\ neuronal$

$W^{(l)}: Responde\ la\ matriz\ de\ pesos$

$h^{(l-1)}: es\ la\ información\ procedente\ de\ la\ capa\ anterior$

$b^{(l)}: constituye\ el\ vector\ del\ sesgo$

$\sigma: constituye\ la\ función\ de\ activación$

Esta operación indica que las redes neuronales realizan las transformaciones sucesivas de los vectores por medio de las matrices de los pesos. En cada capa se obtiene la representación de diversos datos, lo que permite que el modelo identifique las características progresivamente más complejas.

El álgebra lineal interviene dentro del entrenamiento por medio de la retro propagación del error. Este proceso calcula la manera en que deben modificarse los parámetros de la red en la disminución de la diferencia de las predicciones y los valores esperados. A su vez, los gradientes obtenidos se usan para actualizar las matrices de los pesos y los vectores de sesgo, de forma que el modelo mejore los resultados (Whittington & Bogacz, 2021).

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

Tabla 3.

Operaciones de álgebra lineal aplicadas al entrenamiento de redes neuronales.

Operación	Operación	Operación
Aplicación dentro de la red neuronal	Aplicación dentro de la red neuronal	Aplicación dentro de la red neuronal
Resultado	Resultado	Resultado
Multiplicación de matrices	Multiplicación de matrices	Multiplicación de matrices
Combina las entradas con los pesos de cada capa.	Combina las entradas con los pesos de cada capa.	Combina las entradas con los pesos de cada capa.
Transforma la información recibida.	Transforma la información recibida.	Transforma la información recibida.
Suma de vectores	Suma de vectores	Suma de vectores

Nota 1:

- Síntesis de las operaciones de álgebra lineal aplicada al entrenamiento de las redes neuronales.

Fuente: Adaptado de (Lin & Quan, 2023)

Por estos resultados se identifican que una de las soluciones en la mejora del entrenamiento de las redes neuronales consiste en la optimización de las optimizaciones de las operaciones matriciales que se dan repentinamente en el proceso. Esto incluye el uso de las multiplicaciones matriciales eficientes, la organización adecuada de los datos y la aplicación de los procedimientos de optimización que permitan la actualización de los parámetros sin la realización de cálculos innecesarios.

A la vez, la correcta inicialización de los pesos, el control de los gradientes y la normalización de los datos son medidas esenciales para evitar las dificultades del entrenamiento. Estas acciones contribuyen a la reducción de los problemas como la inestabilidad numérica y las variaciones excesivas de los valores de los parámetros.

Aplicación del álgebra lineal en la optimización del aprendizaje automático

La optimización constituye otro ámbito dentro del álgebra lineal. Los modelos de aprendizaje automático tienen que encontrar los parámetros que permitan la minimización en función de pérdida, el cuál mide la diferencia de las predicciones realizadas y los resultados esperados.

Para que se logre, los algoritmos usan los procedimientos matemáticos que calculan los gradientes de la función de la pérdida respecto a los parámetros del modelo. Estos gradientes se los representan por medio de los vectores o matrices, dependiendo de la cantidad y de la organización de los parámetros que tienen que actualizarse.

A su vez, con respecto al descenso del gradiente, los parámetros se modifican en base a la dirección opuesta al gradiente determinado. Este proceso permite que el modelo se ajuste de forma progresiva a los valores disminuyendo el error.

$$\theta_{t+1} = \theta_t - \eta \nabla L(\theta_t)$$

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

Donde:

θ_t: *Son los parámetros actuales*

η: *es la tasa de aprendizaje*

$\nabla L(\theta_t)$: *es el gradiente de la función de pérdida*

La investigación permite la identificación de que la selección de la tasa de aprendizaje adecuada es esencial para que se eviten las actualizaciones demasiado grandes o pequeñas. Si el valor es excesivo, el modelo puede tener oscilaciones y dificultades para que se alcance la solución estable, mientras que, si es demasiado reducido, el entrenamiento se puede prolongar de forma innecesaria.

Otro problema se relaciona con la aparición de los gradientes que aumentan o desaparecen de forma excesiva en el entrenamiento de las redes profundas. Estas situaciones dificultan la actualización de los parámetros e impiden que el modelo aprenda de forma adecuada (Pankaj, 2021). A la vez, conforme con Fei y Kiu (2025) en su análisis de las limitaciones de los procedimientos de optimización convencional del aprendizaje profundo, presenta la optimización geométrica como la alternativa para que se trabaje con modelos que incorporen las estructuras y restricciones específicas.

Tabla 4.

Problemas de optimización y las soluciones por procedimientos.

Problema identificado	Causa o manifestación	Solución propuesta	Beneficio esperado
Entrenamiento lento	Gran cantidad de parámetros y operaciones repetitivas.	Optimizar las operaciones matriciales y utilizar procesamiento por lotes.	Reducir el tiempo de entrenamiento.
Gradientes que desaparecen	Disminución excesiva de los gradientes durante la retropropagación.	Utilizar inicialización adecuada, normalización y arquitecturas que faciliten el flujo de gradientes.	Mejorar la actualización de los parámetros.
Gradientes explosivos	Crecimiento excesivo de los valores del gradiente.	Aplicar normalización y recorte de gradientes.	Evitar actualizaciones inestables.
Sobreajuste	El modelo aprende características específicas de los datos de entrenamiento.	Incorporar regularización y validación con datos independientes.	Mejorar la capacidad de generalización.
Actualizaciones inestables	Tasa de aprendizaje inadecuada.	Ajustar la tasa de aprendizaje y utilizar algoritmos adaptativos.	Favorecer un entrenamiento más estable.
Parámetros redundantes	Existencia de información repetida en las representaciones.	Aplicar regularización y técnicas de reducción de dimensionalidad.	Disminuir la complejidad del modelo

Nota 1:

- Síntesis de las operaciones de optimización y soluciones mediante procedimientos.

Fuente: Adaptado de (Fei & Kiu, 2025)

Los resultados indican que el álgebra lineal permite que se ejecute y exprese los procedimientos de optimización necesarios en el aprendizaje automático. No obstante, la utilización tiene que acompañarse de estrategias que controlen evaluación de los modelos.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

Aplicación de las matrices en las redes neuronales de grafos

Las redes neuronales de grafos son una aplicación esencial del álgebra lineal debido a que permiten el proceso de la información en la que los datos están relacionados entre sí. A diferencia de los conjuntos de datos convencionales, en los que las observaciones se suelen organizar en filas y columnas, los grafos constituyen elementos mediante nodos y conexiones denominadas aristas.

Estas estructuras se dan en sistemas de transporte, redes sociales, relaciones de los productos y usuarios, las redes de comunicación y las estructuras moleculares. Por ende, para procesarlas, los modelos usan matrices de descripción de las conexiones y características de los elementos.

La matriz de adyacencia permite la representación de las relaciones de los nodos. Cuando dos nodos están conectados, el elemento de la matriz registra la relación. Por su parte, la matriz de grado contiene la información acerca del número de las conexiones de los nodos y la matriz laplaciana permite el estudio de la estructura y las propiedades del grafo.

Dichas matrices se usan en las redes neuronales de grafos para la combinación de la información de los nodos con relación y generación de nuevas representaciones. De esta manera, el modelo aprende de las características individuales de cada elemento y de las relaciones que mantienen con los demás.

De acuerdo con Gutiérrez y Peraza (2025), las redes neuronales de grafos tienen relación directa con el álgebra lineal aplicada, especialmente por el procesamiento de las matrices dispersas y las operaciones usadas para la representación de las conexiones de los elementos. A la vez, indican que las redes neuronales convencionales no siempre son adecuadas para trabajar con matrices dispersas de dimensiones variables, por ello, se necesitan arquitecturas que tengan en cuenta la estructura de los datos.

Tabla 5.

Aplicación de las estructuras matriciales en las redes neuronales de grafos

Herramienta matemática	Función en el procesamiento de grafos	Aplicación
Matriz de adyacencia	Representa las conexiones existentes entre los nodos.	Identificación de relaciones en redes sociales y de transporte.
Matriz de grado	Registra la cantidad de conexiones de cada nodo.	Análisis de la importancia estructural de los elementos.
Matriz laplaciana	Describe las relaciones entre nodos y las propiedades estructurales del grafo.	Agrupación y análisis de redes.
Matriz de características	Almacena los atributos asociados a cada nodo.	Clasificación de elementos y reconocimiento de patrones.
Valores y vectores propios	Permiten analizar las propiedades espectrales de las matrices.	Detección de comunidades y agrupación de nodos.
Matrices dispersas	Almacenan principalmente los valores diferentes de cero.	Reducción del almacenamiento y procesamiento de grafos con pocas conexiones.

Nota 1:

- Síntesis de la aplicación de las herramientas en los procesamientos de grafos.

Fuente: Adaptado de (Moore & Siefert, 2025)

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

La aplicación de las herramientas contribuye en la resolución del problema de proceso de información en la cual las relaciones entre los elementos poseen tanta importancia como las características individuales. Es decir, en un sistema de recomendación, una red puede ser usuarios y productos por nodos, a la vez, que las interacciones de ellos se registran como las conexiones. El modelo usa las relaciones para la identificación de los patrones y generación de recomendaciones.

La aplicación de las redes neuronales de grafos en las tareas de clasificación de nodos, el análisis de las relaciones complejas y la clasificación de grafos, identifican arquitecturas como Graph Convolutional Networks, GraphSAGE y Graph Attention Networks, que consideran diversos procedimientos para la integración de la información estructural y las características de los nodos (Khemani & Patil, 2024).

Modelos de inteligencia artificial y aprendizaje automático que utilizan el álgebra lineal

La revisión permitió la identificación que el álgebra lineal se aplica en los diversos modelos de inteligencia artificial y el aprendizaje automático, como algoritmos tradicionales como las arquitecturas de aprendizaje profundo. El uso depende del tipo de problemas que se busca dar solución, la naturaleza de los datos y la estructura matemática del modelo. Entre los principales modelos identificados se tienen los algoritmos de regresión, los métodos de reducción de dimensionalidad, las máquinas de soporte vectorial, las redes neuronales artificiales, las redes neuronales de los grafos, las redes neuronales convolucionales y los modelos transformer.

En los algoritmos tradicionales de aprendizaje automático como la regresión logística y lineales, el álgebra lineal permite la representación de las características de los datos por vectores y matrices, el cálculo de los parámetros del modelo y la obtención de las predicciones. En las máquinas de soporte vectorial (SVM), las relaciones geométricas y las operaciones vectoriales permiten el establecimiento de límites de separación de diversas categorías de datos. A su vez, los métodos de agrupamiento y la reducción de las dimensionalidades usan distancias, descomposiciones matriciales y proyecciones para la identificación de similitudes y estructuras en los conjuntos de información. Castro y Sánchez (2023) relacionan de forma directa las herramientas del álgebra lineal y la optimización con los modelos de regresión, la clasificación por métodos kernel, las máquinas de soporte vectorial y los sistemas de recomendación.

A la vez, dentro del aprendizaje profundo, las redes neuronales y las redes convolucionales usan matrices de pesos, tensores y vectores de sesgo para el procesamiento de la información. Las redes convolucionales se emplean de forma directa en el reconocimiento y clasificación de las imágenes, en la que las operaciones de convolución permiten la identificación de las características visuales como las formas, bordes y patrones. En estos modelos, las operaciones matriciales permiten las transformaciones de las imágenes y la generación de representaciones que luego se pueden usar en una clasificación.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

Por su parte, los modelos transformes como GPT, BERT Y Llama, usan vectores y matrices para la representación de las palabras, el cálculo de las relaciones entre los elementos de la secuencia y la generación de predicciones o respuestas. ChatGPT, Manus y Geminis, son un ejemplo de aplicaciones basadas en los modelos del lenguaje de gran tamaño que usan las arquitecturas transformer. En estos sistemas el mecanismo de atención depende de las multiplicaciones matriciales para el establecimiento de qué elementos de la información necesitan de mayor importancia en el procesamiento (Calero & Mabel, 2026).

A la vez, se identificaron las redes neuronales de grafos (GNN), que se usan cuando los datos tienen relaciones entre los elementos. Estas arquitecturas pueden aplicarse en diversos análisis de las redes sociales, los sistemas de recomendación, las estructuras moleculares y las redes de transporte.

Tabla 6.

Modelos de la inteligencia artificial y el aprendizaje automático y la relación con el álgebra lineal

Modelo o arquitectura	Ejemplos de modelos o sistemas	Aplicación principal	Herramientas de álgebra lineal utilizadas
Regresión lineal	Modelos predictivos de regresión.	Predicción de valores numéricos, como precios, demanda o consumo.	Vectores, matrices, productos matriciales y mínimos cuadrados.
Regresión logística	Clasificadores binarios y multiclase.	Clasificación de datos, como detección de categorías o identificación de riesgos.	Vectores de características, matrices de parámetros y operaciones de optimización.
Máquinas de soporte vectorial (SVM)	SVM lineal y SVM con funciones kernel.	Clasificación de imágenes, textos y datos estructurados.	Productos escalares, vectores, matrices de similitud y optimización.
Análisis de componentes principales (PCA)	Modelos de reducción de dimensionalidad.	Simplificación de datos y selección de características.	Matrices de covarianza, valores propios y vectores propios.
Redes neuronales artificiales (ANN/MLP)	Perceptrones multicapa.	Clasificación, predicción y reconocimiento de patrones.	Matrices de pesos, vectores de sesgo, gradientes y multiplicaciones matriciales.
Redes neuronales convolucionales (CNN)	AlexNet y otras arquitecturas convolucionales.	Reconocimiento y clasificación de imágenes.	Tensores, filtros, convoluciones y multiplicaciones matriciales.

Nota 1:

- Síntesis de la aplicación de las herramientas en los procesamientos de grafos.

Fuente: Adaptado de (Moore & Siefert, 2025) (Baggag & Saad, 2025) (Brito, Cargua, & Vera, 2025) (Calero & Mabel, 2026)

La comparación permite la visualización de que no se tiene un único modelo de inteligencia artificial que use el álgebra lineal. Mientras que, al contrario, diversas arquitecturas emplean las herramientas conforme a la tarea que se tiene que desarrollar. Los modelos de regresión y las máquinas de soporte vectorial usan especialmente los vectores, los productos escalares y los sistemas de ecuaciones para la realización de predicciones y clasificaciones; las redes neuronales y la ampliación de las matrices de los pesos y las operaciones sucesivas para que se aprendan los patrones, a la vez, que los modelos transformes usan grandes estructuras matriciales para el proceso de secuencias y el establecimiento de las relaciones de las palabras y elementos de información.

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

De manera similar, la elección de los modelos depende solo de la necesidad que se pretende atender. Para la predicción de los valores numéricos pueden usarse los modelos de regresión, para la clasificación de la información, las redes neuronales y las máquinas de soporte vectorial, para el reconocimiento de las imágenes, las redes convolucionales, en el procesamiento del lenguaje y la generación de texto, los modelos transformes y para el análisis de las relaciones de los elementos, las redes neuronales de grafos. Esta selección permite la renacionalización de los elementos.

DISCUSIÓN

Los resultados de la investigación indican que el álgebra lineal es una base de la matemática indispensable dentro del desarrollo de los modelos de inteligencia artificial y el aprendizaje automático. Dado que interviene en la representación de los datos, la reducción de la dimensionalidad, la optimización de las operaciones computacionales y el entrenamiento de las redes neuronales. Al contrastar los hallazgos con demás investigaciones científicas, se visualiza que se tienen coincidencias con la importancia de las matrices, las transformaciones lineales, los vectores y la factorización matricial. No obstante, cada estudio profundiza en las aplicaciones y los procedimientos específicos que permitan la comprensión de estas herramientas que resuelvan los problemas concretos en los modelos.

El presente estudio identificó que las matrices, las transformaciones lineales y los vectores intervienen dentro de las diferentes etapas del aprendizaje automático, desde los datos hasta los parámetros de actualización de los modelos. Erazo y Vacas (2026) definieron que el dominio de las matrices, las transformaciones lineales y los vectores es esencial en el diseño y la implementación de la optimización de los algoritmos del aprendizaje automático. La coincidencia de los trabajos permite el establecimiento de que el álgebra lineal no es solo un conocimiento matemático complementario, sino una herramienta que participa de forma directa en la construcción de los modelos. Cabe considerar que, en el estudio, se enfocaron en la identificación de tendencias de investigación por el análisis biométrico, profundizando la relación de las operaciones matemáticas y las aplicaciones en arquitecturas específicas como los modelos transformer, las redes neuronales y las redes grafos.

Por otra parte, los resultados de esta investigación evidenciaron que la reducción de dimensionalidad permite disminuir la complejidad de los conjuntos de datos y facilitar su procesamiento mediante técnicas como el análisis de componentes principales, la descomposición en valores singulares y la factorización matricial. Este resultado coincide con Haro (2025) identificó que las técnicas de reducción permiten la selección de representaciones más compactas con la disminución de los efectos asociados a la denominada maldición de la dimensionalidad. Dicha relación confirma que las herramientas del álgebra lineal brindan soluciones con respecto al crecimiento de los datos y la presencia de las características redundantes. No obstante, los resultados permiten que se reconozca la diferencia de reducción de las dimensiones que no garantiza por sí sola la mejora del modelo, puesto que la eliminación

Volumen: 4, Número: 4, Año: 2026 páginas 526-549
E-ISSN: 3103-1536
Bajo licencia: CC BY-SA 4.0

excesiva de las características puede generar pérdida de datos. Por lo cual, además de disminuir la cantidad de variables, se requiere la evaluación de la información conservada y la comprobación de que la representación resultante tenga la capacidad predictiva del algoritmo.

Asimismo, esta investigación identificó que la factorización matricial permite representar conjuntos de datos complejos mediante estructuras de menor dimensión, reconocer factores latentes y reducir información redundante. Este resultado coincide con Camilli y Mézard (2023) quienes demostraron que el procedimiento propuesto permite factorizar matrices de rango extenso y eliminar ruido de manera eficiente, especialmente en problemas de aprendizaje de diccionarios, sistemas de recomendación y aprendizaje automático. La coincidencia se encuentra en que ambos trabajos reconocen la factorización como una herramienta para extraer información relevante de matrices complejas. Sin embargo, mientras el presente estudio aborda la factorización como una técnica aplicable a diferentes modelos de inteligencia artificial, Camilli y Mézard se concentran en una propuesta específica que integra la descomposición matricial con redes neuronales. Esta diferencia evidencia que las operaciones del álgebra lineal no solamente permiten preparar los datos antes del entrenamiento, sino que también pueden incorporarse directamente en el diseño de nuevos algoritmos de aprendizaje.

CONCLUSIONES

Por medio de las investigaciones se identificó que el álgebra lineal constituye uno de los fundamentos matemáticos esenciales para el desarrollo de los modelos de inteligencia artificial y aprendizaje automático. Su aplicación se encuentra presente en las diferentes etapas del funcionamiento de los algoritmos, desde la representación y organización de los datos hasta el procesamiento de la información, el entrenamiento de las redes neuronales y la generación de predicciones. En este sentido, los vectores, las matrices, los tensores y las transformaciones lineales no representan únicamente herramientas matemáticas complementarias, sino estructuras necesarias para el funcionamiento de los modelos computacionales.

Respecto a la representación y el procesamiento de los datos, se concluye que las operaciones vectoriales y matriciales permiten organizar grandes volúmenes de información mediante estructuras numéricas que pueden ser procesadas por los algoritmos. Asimismo, las técnicas de reducción de dimensionalidad, como el análisis de componentes principales y la descomposición en valores singulares, contribuyen a disminuir la complejidad de los conjuntos de datos, reducir los costos computacionales y facilitar la identificación de patrones relevantes. Sin embargo, su aplicación requiere conservar la información significativa, debido a que una reducción excesiva puede ocasionar la pérdida de características importantes para el aprendizaje.

En relación con los modelos de inteligencia artificial y aprendizaje automático, se identificó que el álgebra lineal interviene en diferentes arquitecturas, entre ellas los modelos de regresión, las máquinas de soporte vectorial, las redes neuronales artificiales, las redes convolucionales, las redes neuronales recurrentes, las redes neuronales de grafos y los modelos transformer. Cada

una de estas arquitecturas utiliza operaciones específicas, como productos matriciales, multiplicaciones de vectores, transformaciones lineales y descomposiciones de matrices, para representar los datos, identificar relaciones y generar resultados. Por consiguiente, la comprensión de estos procedimientos permite explicar las bases matemáticas que sustentan el funcionamiento de las aplicaciones actuales de inteligencia artificial.

REFERENCIAS BIBLIOGRÁFICAS

Ayaz, A. (2025). Comprehensive review of dimensionality reduction algorithms: challenges, limitations, and innovative solutions. PeerJ Comput, 10(11), 21. Obtenido de https://pmc.ncbi.nlm.nih.gov/articles/PMC12453773/

Baggag, A., & Saad, Y. (2025). Aprendizaje profundo, transformadores y redes neuronales gráficas: una perspectiva desde el álgebra lineal. Numerical Algorithms, 21(34), 40. Obtenido de https://link.springer.com/content/pdf/10.1007/s11075-025-02218-2.pdf

Brito, C., Cargua, S., & Vera, M. (2025). Álgebra lineal avanzada y su rol en el aprendizaje de algoritmos de machine learning. Reincisol, 4(7), 3440-3466. doi:https://doi.org/10.59282/reincisol.V4(7)3440-3466

Calero, E., & Mabel, C. (2026). Inteligencia artificial generativa y pensamiento algebraico en educación matemática: tendencias, aportes y desafíos desde una revisión sistemática. Ciencia Latina revista multidisciplinar, 10(4), 23. Obtenido de https://ciencialatina.org/index.php/cienciala/article/view/25108

Camilli, F., & Mézard, M. (2023). Factorización de matrices con redes neuronales. Revisión física E, 2(107), 17. Obtenido de https://journals.aps.org/pre/abstract/10.1103/PhysRevE.107.064308

Carrasco, C., Castillo, G., & Palacios, G. (2025). Producción Científica sobre Inteligencia Artificial en América Latina. Revista Epistemus, 19(38), 24. Obtenido de https://dialnet.unirioja.es/servlet/articulo?codigo=10467185

Castro, M., & Sánchez, C. (2023). Aplicación del Álgebra Lineal en la Ingeniería. Dominio De Las Ciencias, 9(2), 1639–1656. Obtenido de https://dominiodelasciencias.com/ojs/index.php/es/article/view/3364

Erazo, V., & Vacas, S. (2026). Inteligencia artificial generativa para la enseñanza de matemáticas y programación en educación superior: Revisión sistemática. Revista de Ciencias Sociales, 32(2), 320-340. Obtenido de https://www.redalyc.org/journal/280/28085624021/html/

Fei, Y., & Kiu, Y. (2025). Un estudio sobre la optimización geométrica para el aprendizaje profundo: del espacio euclidiano a la variedad riemanniana. Revista ACM, 57(5), 1-37. Obtenido de https://dl.acm.org/doi/10.1145/3708498

Greenacre, M., Groenen, P., & Lodice, A. (2022). Análisis de componentes principales. Revista Nature, 2(22), 18. Obtenido de https://www.nature.com/articles/s43586-022-00184-w

Gutiérrez, M., & Peraza, A. (2025). Álgebra lineal como eje del desarrollo de la inteligencia artificial moderna. Revista Digital de Tecnologías Informáticas y Sistemas, 9(1), 11.

doi:https://doi.org/10.61530/redtis.vol9.n1.2025.276

Guzmán, C., Estrada, M., & Burga, R. (2025). Impacto de la Inteligencia Artificial en el Álgebra Lineal. Una revisión bibliométrica. Refleziones de la sociedad y economía, 2(2), 1-24. doi:https://doi.org/10.62776/rse.v2i2.48

Haro, J. (2025). La IA en el aula de matemáticas. Revista Aosma, 2(34), 13. doi:ISNN-e: 1887-3952

Khemani, B., & Patil, S. (2024). Una revisión de las redes neuronales gráficas: conceptos, arquitecturas, técnicas, desafíos, conjuntos de datos, aplicaciones y direcciones futuras. Revista de Big Data, 11(18), 21. Obtenido de https://link.springer.com/article/10.1186/s40537-023-00876-4

Lin, K., & Quan, Z. (2023). Técnicas de factorización matricial en aprendizaje automático, procesamiento de señales y estadística. Matemáticas, 11(12), 21. Obtenido de https://www.mdpi.com/2227-7390/11/12/2674

Mendoza, J., & Macías, L. (2024). Modelos de aprendizaje automático: Aplicación y eficiencia. Revista Científica de Informática ENCRIPTAR, 7(14), 27. doi:https://doi.org/10.56124/encriptar.v7i14.005

Moore, N., & Siefert, C. (2025). Vigilancia vecinal en mecánica: modelos no locales y convolución. Revista Siam, 67(1), 141–175. Obtenido de 137/22M1541721

Page, M., McKenzie, J., & Bossuy, P. (2025). Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. Revista española de cardiología, 74(9), 21. Obtenido de https://www.revespcardiol.org/es-declaracion-prisma-2020-una-guia-articulo-S0300893221002748

Pankaj, M. (2021). Una introducción al aprendizaje automático para físicos, con un alto sesgo y baja varianza. National Library of Medicine, 8(14), 23. Obtenido de https://pmc.ncbi.nlm.nih.gov/articles/PMC6688775/

Whittington, J., & Bogacz, R. (2021). Teorías de la retropropagación de errores en el cerebro. Tendencias en Ciencias Cognitivas, 23(5), 235-250. Obtenido de https://pmc.ncbi.nlm.nih.gov/articles/PMC6382460/

Agradecimientos

Se expresa un agradecimiento a los docentes y profesionales que, por medio de su orientación, aportaciones académicas y conocimientos, contribuyeron al desarrollo del presente artículo, y facilitaron la comprensión de los fundamentos del álgebra lineal y la aplicación dentro de los modelos de inteligencia artificial y aprendizaje automático.

Financiación

La presente investigación no recibió financiación externa de organismos privados o públicos ni de las instituciones financiadoras. Puesto que su desarrollo se hizo con recursos propios.