Sage Sphere of Technology, Sciences, Discoveries and Society

ISSN: 3091-1915

Vol. 4 Núm. 1 (2026)

EDITORIAL JOGB

SSTSDS-Vol.4. N1. 147

Geometría diferencial y topología aplicadas al aprendizaje profundo geométrico: fundamentos e implicaciones educativas para el pensamiento matemático y computacional

Differential geometry and topology applied to geometric deep learning: foundations and educational implications for mathematical and computational thinking

Autores:

Jorge Javier Alvarez Sánchez
Colegio Ludoteca Internacional Padre Victor Grados, Quito, Ecuador
jjasz@hotmail.com
https://orcid.org/0000-0001-7405-1183

Bryan Francisco Ilbay Chavez
Investigador autónomo, Riobamba, Ecuador
bryanil_98@hotmail.com
https://orcid.org/0009-0005-6116-8928

Silvana Mariela Cevallos Tituaña
Institución Educativa Fiscal Guayllabamba, Quito, Ecuador
silvis89@live.com
https://orcid.org/0009-0005-5108-6056

Estefania Nicol Cevallos Tituaña
Universidad Nacional de Chimborazo, Cayambe, Ecuador
estefaniacevallos8@gmail.com
https://orcid.org/0009-0005-0933-6242

Isabel Leonor Rodríguez Lino
Institución Educativa Fiscal Guayllabamba, Quito, Ecuador
isarodriguez20@hotmail.com
https://orcid.org/0009-0008-6952-8678

Autor de correspondencia: *Jorge Javier Alvarez Sánchez*, jjasz@hotmail.com

Enviado: 11-08-2026 **Revisado:** 16-09-2026
Aceptado: 04-10- 2026 **Publicado:** 05-10-2026

Doi: https://doi.org/10.63688/5b571j80

Sage Sphere of Technology, Sciences, Discoveries and Society

ISSN: 3091-1915

Vol. 4 Núm. 1 (2026)

Cómo citar este artículo:

Alvarez Sánchez, J. J., Ilbay Chavez, B. F., Cevallos Tituaña, S. M., Cevallos Tituaña, E. N., & Rodríguez Lino, I. L. (2026). Geometría diferencial y topología aplicadas al aprendizaje profundo geométrico: fundamentos e implicaciones educativas para el pensamiento matemático y computacional. *Sage Sphere of Technology, Sciences, Discoveries And Society*, *4*(1), 1-30. https://doi.org/10.63688/5b571j80

© 2026; Los autores. Este es un artículo en acceso abierto, distribuido bajo los términos de una licencia Creative Commons (https://creativecommons.org/licenses/by/4.0) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea correctamente citada.

ABSTRACT

Differential geometry and topology provide relevant mathematical foundations for the analysis and representation of non-Euclidean data within Geometric Deep Learning. This systematic review aimed to analyze the contributions of differential geometry and topology that underpin Geometric Deep Learning and to identify the educational implications that may be derived for the development of mathematical and computational thinking. The PRISMA 2020 guidelines were followed using a qualitative descriptive-analytical approach. The search was conducted in Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink, and Google Scholar. Of the 91 records initially identified, 16 academic publications met the eligibility criteria and were included in the final analysis. The results show that Geometric Deep Learning integrates concepts such as graphs, manifolds, meshes, symmetries, invariance, equivariance, and topological structures to represent and process complex data. Graph neural networks and equivariant architectures enable the preservation of structural and spatial properties, while topological approaches provide information about global connectivity and organization. From an educational perspective, these foundations can establish connections between mathematics, artificial intelligence, and computational thinking through abstraction, modeling, pattern recognition, and problem solving. It is concluded that differential geometry and topology constitute a conceptual bridge between advanced mathematics and artificial intelligence, although further educational research is required to design and evaluate teaching strategies specifically oriented toward Geometric Deep Learning.

Keywords: differential geometry; topology; geometric deep learning; graph neural networks; computational thinking.

.

RESUMEN

La geometría diferencial y la topología proporcionan fundamentos matemáticos relevantes para el análisis y la representación de datos no euclidianos dentro del aprendizaje profundo geométrico (*Geometric Deep Learning*). Esta revisión sistemática tuvo como objetivo analizar los aportes de la geometría diferencial y la topología que sustentan el aprendizaje profundo geométrico e identificar las implicaciones educativas que pueden derivarse para el desarrollo del pensamiento matemático y computacional. Se siguieron las directrices PRISMA 2020 mediante un enfoque cualitativo descriptivo-analítico. La búsqueda se realizó en Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink y Google Scholar. De 91 registros identificados inicialmente, 16 publicaciones académicas cumplieron los criterios de elegibilidad y fueron incluidas en el análisis final. Los resultados muestran que el aprendizaje profundo geométrico integra conceptos como grafos, variedades, mallas, simetrías, invariancia, equivariancia y estructuras topológicas para representar y procesar datos complejos. Las redes neuronales de grafos y las arquitecturas equivariantes permiten conservar propiedades estructurales y espaciales, mientras que los enfoques topológicos aportan información sobre la conectividad y organización global de los datos. Desde una perspectiva educativa, estos fundamentos permiten establecer conexiones entre matemáticas, inteligencia artificial y pensamiento computacional mediante procesos de abstracción, modelización, reconocimiento de patrones y resolución de problemas. Se concluye que la geometría diferencial y la topología constituyen un puente conceptual entre las matemáticas avanzadas y la inteligencia artificial, aunque se requieren mayores investigaciones educativas para diseñar y evaluar estrategias didácticas específicamente orientadas al *Geometric Deep Learning*.

Palabras clave: geometría diferencial; topología; aprendizaje profundo geométrico; redes neuronales de grafos; pensamiento computacional.

1. INTRODUCCIÓN

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

El desarrollo de la inteligencia artificial y del aprendizaje profundo ha transformado la manera en que se analizan grandes volúmenes de información y se construyen modelos capaces de reconocer patrones complejos. Sin embargo, una parte importante de los datos presentes en problemas científicos y tecnológicos no posee una estructura regular semejante a una cuadrícula, sino que puede organizarse mediante grafos, superficies, redes, variedades y otras estructuras no euclidianas. Esta situación ha impulsado el desarrollo del aprendizaje profundo geométrico o Geometric Deep Learning (GDL), un enfoque que incorpora principios de geometría, simetría y estructura matemática dentro del diseño de modelos de aprendizaje automático (Bronstein et al., 2021; Hamilton, 2020).

Dentro de esta perspectiva, la geometría diferencial y la topología adquieren especial relevancia porque proporcionan herramientas para describir espacios cuya estructura no puede representarse adecuadamente mediante coordenadas cartesianas convencionales. La geometría diferencial estudia propiedades locales de curvas, superficies y variedades, mientras que la topología analiza características globales que permanecen invariantes frente a determinadas transformaciones. Estas ideas permiten interpretar matemáticamente relaciones, conectividad, distancias, simetrías y deformaciones presentes en conjuntos de datos complejos y constituyen parte de los fundamentos conceptuales del aprendizaje profundo geométrico (Bronstein et al., 2021; Zia et al., 2024).

Uno de los ejemplos más representativos de esta relación se encuentra en las redes neuronales de grafos (Graph Neural Networks, GNN). En estas arquitecturas, la información se representa mediante nodos y conexiones que permiten describir relaciones entre diferentes elementos. Esta organización amplía las posibilidades del aprendizaje profundo más allá de imágenes o secuencias regulares y permite trabajar con moléculas, redes sociales, sistemas físicos, estructuras biológicas y otros problemas relacionales. La literatura reciente muestra que las GNN han establecido un marco relevante para aprender representaciones a partir de datos estructurados mediante grafos **(Wu et al., 2021; Hamilton, 2020)**

La geometría también permite incorporar en las redes neuronales propiedades matemáticas relacionadas con las simetrías. En muchos problemas, una figura u objeto puede rotarse, trasladarse o reflejarse sin que cambie su significado fundamental. En este contexto, conceptos como invariancia y equivariancia permiten construir modelos capaces de respetar dichas transformaciones. Satorras et al. (2021) desarrollaron redes neuronales de

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

grafos equivariantes respecto de rotaciones, traslaciones, reflexiones y permutaciones, mostrando cómo determinadas propiedades geométricas pueden integrarse directamente en la arquitectura de una red neuronal.

De manera semejante, Fuchs et al. (2020) propusieron el SE(3)-Transformer, una arquitectura diseñada para trabajar con nubes de puntos y grafos tridimensionales manteniendo equivariancia ante rotaciones y traslaciones en el espacio. Este tipo de desarrollo evidencia que conceptos matemáticos que tradicionalmente se estudian desde una perspectiva teórica pueden desempeñar una función concreta en la construcción de modelos inteligentes capaces de interpretar objetos tridimensionales y relaciones espaciales.

Estas aplicaciones no se limitan a los grafos. Las superficies y mallas también pueden analizarse empleando herramientas derivadas de la geometría diferencial. De Haan et al. (2020), por ejemplo, desarrollaron redes convolucionales equivariantes para mallas geométricas que utilizan información relacionada con la orientación y el transporte de características entre puntos de una superficie. Estos planteamientos muestran una conexión directa entre nociones geométricas avanzadas y procedimientos computacionales de aprendizaje automático.

Otra dimensión importante se encuentra en el análisis de información espacial y molecular. Gasteiger et al. (2020) propusieron un sistema de paso de mensajes direccional en el que las relaciones entre elementos incorporan información sobre distancias y ángulos. Este enfoque demuestra que la representación de la geometría de los datos puede mejorar la capacidad de los modelos para interpretar configuraciones espaciales complejas y constituye un ejemplo concreto de cómo conceptos matemáticos pueden traducirse en operaciones computacionales dentro de una red neuronal.

Posteriormente, Gasteiger et al. (2021) profundizaron esta perspectiva mediante GemNet, una red neuronal geométrica que incorpora relaciones direccionales y propiedades asociadas con traslaciones, rotaciones y permutaciones. Este tipo de arquitectura permite comprender que el aprendizaje profundo geométrico no constituye solamente una aplicación de algoritmos informáticos, sino un campo interdisciplinario donde conceptos de geometría, álgebra, grafos y cálculo participan en la representación y procesamiento de información compleja.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

La topología ofrece otra perspectiva complementaria. Mientras ciertos modelos analizan principalmente relaciones entre pares de elementos, los métodos topológicos permiten estudiar propiedades globales como componentes conectados, ciclos y cavidades presentes en los datos. Horn et al. (2022) desarrollaron redes neuronales topológicas que integran información procedente de la homología persistente dentro de arquitecturas de grafos, proporcionando una forma de incorporar características globales de la estructura de los datos que pueden resultar difíciles de detectar mediante métodos convencionales.

Asimismo, la incorporación de conceptos procedentes de la topología algebraica ha permitido formular nuevos modelos de aprendizaje. Bodnar et al. (2022) utilizaron la teoría de haces celulares para analizar procesos de difusión sobre grafos y establecer conexiones entre la estructura matemática de estos espacios y el comportamiento de las redes neuronales. Estos avances evidencian que la topología puede aportar herramientas para comprender tanto la organización de los datos como determinadas limitaciones de las arquitecturas tradicionales de aprendizaje profundo.

Desde una perspectiva educativa, estas conexiones permiten identificar posibilidades de articulación entre contenidos matemáticos avanzados y situaciones contemporáneas relacionadas con la inteligencia artificial. A partir de los fundamentos analizados, puede inferirse que conceptos de geometría y topología podrían vincularse con problemas de representación de datos, reconocimiento de patrones, redes y modelos tridimensionales. Estas posibilidades constituyen implicaciones educativas derivadas de la revisión y no evidencias directas de eficacia didáctica en estudiantes (Nordby et al., 2022).

El pensamiento computacional resulta particularmente pertinente en este proceso debido a que involucra capacidades como descomposición, abstracción, construcción de algoritmos, reconocimiento de patrones y evaluación de soluciones. Tikva y Tambouris (2021) señalan que la programación constituye un medio relevante para desarrollar pensamiento computacional en contextos educativos, mientras que la literatura sobre educación matemática muestra que estas capacidades pueden integrarse con contenidos de la disciplina mediante actividades orientadas a la resolución de problemas.

La incorporación de inteligencia artificial en la educación matemática también ha aumentado durante los últimos años. Panqueban y Huincahue (2024), mediante una revisión sistemática, identificaron diferentes aplicaciones de la inteligencia artificial en procesos de

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

enseñanza y aprendizaje de las matemáticas, particularmente en sistemas inteligentes, evaluación y apoyo al aprendizaje. Estos resultados muestran la expansión de un campo interdisciplinario en el que las herramientas de inteligencia artificial pueden convertirse tanto en recursos educativos como en objetos de estudio para comprender las matemáticas que sustentan su funcionamiento.

En este sentido, introducir elementos de aprendizaje profundo geométrico en contextos educativos no implica trasladar directamente toda la complejidad matemática de los modelos profesionales al aula. El desafío consiste en diseñar experiencias progresivas donde los estudiantes puedan comprender conceptos como grafos, nodos, conexiones, distancias, superficies, transformaciones, simetrías y estructuras topológicas mediante representaciones visuales, problemas contextualizados y herramientas computacionales. La evidencia reciente sobre inteligencia artificial en educación matemática destaca precisamente la necesidad de articular los recursos tecnológicos con objetivos pedagógicos claros y con el desarrollo de capacidades matemáticas, evitando que la tecnología sea utilizada únicamente como un instrumento automático de respuesta (Opesemowo & Adewuyi, 2024; Schindler et al., 2026). Schindler et al. (2026) se utilizó únicamente como referencia contextual para sustentar el panorama reciente de la inteligencia artificial en educación matemática y no formó parte de las 16 publicaciones académicas incluidas en la síntesis final, debido a que su enfoque general sobre inteligencia artificial en educación matemática no aborda de manera directa los fundamentos de geometría diferencial, topología o aprendizaje profundo geométrico considerados en la pregunta de investigación.

En consecuencia, resulta pertinente analizar la geometría diferencial y la topología aplicadas al aprendizaje profundo desde una perspectiva educativa, considerando tanto sus fundamentos matemáticos como sus posibilidades didácticas. Aunque actualmente existe una producción científica creciente sobre Geometric Deep Learning y sobre inteligencia artificial aplicada a la educación matemática, todavía constituye un desafío traducir estos avances hacia propuestas comprensibles para estudiantes y docentes. Por ello, el presente artículo tiene como propósito analizar cómo conceptos relacionados con variedades, grafos, simetrías, estructuras topológicas y redes neuronales geométricas pueden incorporarse progresivamente en estrategias educativas orientadas al fortalecimiento del pensamiento matemático y computacional,promoviendo una aproximación interdisciplinaria

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

entre matemáticas, inteligencia artificial y educación (Thölke & De Fabritiis, 2022; Zia et al., 2024).

¿Qué aportes de la geometría diferencial y la topología sustentan el aprendizaje profundo geométrico y qué implicaciones educativas pueden derivarse para el desarrollo del pensamiento matemático y computacional?

2. METODOLOGÍA

a) Enfoque del estudio

La presente investigación se desarrolló bajo un enfoque cualitativo, mediante una revisión sistemática de la literatura. El propósito de la revisión fue analizar los aportes de la geometría diferencial y la topología que sustentan el aprendizaje profundo geométrico e identificar las implicaciones educativas que pueden derivarse para el desarrollo del pensamiento matemático y computacional.

Este enfoque permitió identificar, organizar, comparar y sintetizar investigaciones relacionadas con geometría diferencial, topología, variedades, grafos, redes neuronales de grafos, aprendizaje profundo geométrico, aprendizaje topológico, simetrías, equivariancia, inteligencia artificial, educación matemática y pensamiento computacional.

La revisión sistemática constituye un procedimiento metodológico estructurado que permite identificar, seleccionar, evaluar y sintetizar investigaciones previas a partir de criterios explícitos y transparentes. Sauer y Seuring (2023) señalan que este tipo de revisión requiere una pregunta de investigación claramente delimitada, criterios de inclusión y exclusión definidos, fuentes de información pertinentes, estrategias de búsqueda estructuradas y procedimientos sistemáticos para seleccionar y sintetizar la literatura.

b) Método

Se aplicó el método de revisión sistemática de la literatura, siguiendo las directrices de PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) como marco para organizar y documentar las fases de identificación, cribado, evaluación de elegibilidad e inclusión de los documentos científicos.

De acuerdo con Page et al. (2021), PRISMA 2020 proporciona lineamientos actualizados destinados a mejorar la transparencia en el reporte de revisiones sistemáticas, permitiendo explicar con claridad por qué se realizó la revisión, qué procedimientos fueron empleados,

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

cómo se identificaron los registros, cuáles fueron evaluados y cuáles se incorporaron finalmente en la síntesis.

El proceso de selección se organizó, por tanto, en cuatro fases principales: identificación, cribado, elegibilidad e inclusión.

c) Estrategia de búsqueda

La búsqueda bibliográfica comprendió publicaciones académicas correspondientes al período 2020–2026. La búsqueda se realizó el 3 de junio de 2026. Para la recuperación de información se consideraron las bases de datos Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink y Google Scholar, debido a su cobertura en las áreas de Matemáticas, Ciencias de la Computación, Inteligencia Artificial, Ingeniería y Educación.

Se combinaron descriptores en español e inglés relacionados con el tema de investigación, entre ellos: *Geometric Deep Learning*, *differential geometry*, *topology*, *topological deep learning*, *graph neural networks*, *geometric neural networks*, *manifold learning*, *equivariant neural networks*, *mathematics education*, *computational thinking*, *artificial intelligence education*, “geometría diferencial”, “topología”, “aprendizaje profundo geométrico”, “redes neuronales de grafos”, “inteligencia artificial”, “educación matemática”, “pensamiento matemático” y “pensamiento computacional”.

Además de las ecuaciones estructuradas presentadas en la Tabla 1, se realizaron búsquedas complementarias más amplias orientadas a recuperar literatura técnica relevante sobre aprendizaje profundo geométrico, redes neuronales de grafos, arquitecturas equivariantes, modelado molecular, mallas, variedades y aprendizaje profundo topológico. Estas búsquedas no exigieron necesariamente la presencia simultánea de términos vinculados con educación, matemáticas o pensamiento computacional. Asimismo, se efectuó una revisión manual de referencias bibliográficas de estudios clave para identificar publicaciones pertinentes que no hubieran sido recuperadas mediante las ecuaciones principales. Todas las publicaciones incorporadas posteriormente fueron sometidas a los mismos criterios de inclusión, exclusión y evaluación de elegibilidad definidos para la revisión.

Tabla 1

Estrategias de búsqueda según base de datos

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915

Vol. 4 Núm. 1 (2026)

Base de datos	Ecuación de búsqueda	Campos consultados	Período	Filtros aplicados
Scopus	TITLE-ABS-KEY(("geometric deep learning" OR "differential geometry" OR topology) AND ("deep learning" OR "graph neural networks") AND (education OR "computational thinking"))	Título, resumen y palabras clave	2020–2026	Artículos y publicaciones académicas; inglés y español; Matemáticas, Computación, IA y Educación
Web of Science	TS=(("geometric deep learning" OR "topological deep learning") AND ("graph neural networks" OR geometry) AND (education OR mathematics))	Tema, título, resumen y palabras clave	2020–2026	Artículos académicos y revisiones; Matemáticas, Ciencias de la Computación y Educación
IEEE Xplore	("Geometric Deep Learning" OR "Graph Neural Networks") AND ("Differential Geometry" OR Topology)	Metadatos, resumen y palabras clave	2020–2026	Artículos, conferencias y publicaciones científicas
ScienceDirect	("geometric deep learning" OR "topological deep learning") AND ("artificial intelligence" OR "mathematics education")	Título, resumen y palabras clave	2020–2026	Artículos científicos y revisiones
SpringerLink	("geometric deep learning" AND topology) OR ("artificial intelligence" AND "mathematics education")	Título, resumen y texto indexado	2020–2026	Artículos, revisiones y capítulos académicos pertinentes
Google Scholar	("geometric deep learning" OR "differential geometry" OR topology) AND ("mathematics education" OR "computational thinking")	Título, resumen y texto disponible	2020–2026	Rango personalizado; español e inglés

Nota. Las ecuaciones de búsqueda fueron adaptadas a las características técnicas de cada base de datos. La estrategia principal se complementó, cuando fue necesario, con búsquedas más amplias sobre aprendizaje profundo geométrico y sus fundamentos técnicos, así como con revisión manual de referencias, con el fin de recuperar literatura relevante no necesariamente indexada con términos educativos.

d) Identificación de los registros

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

La búsqueda inicial estuvo orientada a identificar publicaciones potencialmente relacionadas con la geometría diferencial, la topología y sus aplicaciones en el aprendizaje profundo geométrico, así como estudios vinculados con educación matemática, inteligencia artificial y pensamiento computacional.

Los registros obtenidos mediante búsquedas principales, búsquedas complementarias y revisión manual de referencias fueron integrados en una misma matriz documental antes de iniciar el proceso de eliminación de duplicados y cribado.

Los documentos recuperados fueron organizados en una matriz bibliográfica considerando:

- Autor y año.
- País o contexto de publicación.
- Objetivo del estudio.
- Metodología.
- Área de aplicación.
- Tipo de estructura matemática analizada.
- Arquitectura de aprendizaje profundo utilizada.
- Presencia de elementos de geometría diferencial.
- Presencia de elementos topológicos.
- Uso de grafos, variedades o mallas.
- Relación con inteligencia artificial.
- Relación con educación matemática.
- Relación con pensamiento computacional.
- Principales hallazgos.
- Aporte a la pregunta de investigación.

Los documentos duplicados fueron identificados mediante la comparación del título, autores, año de publicación, revista o fuente y DOI.

Después de eliminar los registros repetidos, los documentos restantes pasaron a la fase de cribado mediante revisión del título, resumen y palabras clave.

e) Selección y evaluación de los estudios

El proceso de selección se desarrolló en tres etapas.

Cribado inicial

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

Durante esta etapa se revisaron los títulos y resúmenes de los documentos recuperados.

Se excluyeron aquellos estudios que:

- No abordaban directamente geometría diferencial, topología o aprendizaje profundo geométrico.
- No presentaban relación con redes neuronales geométricas o grafos.
- Se centraban exclusivamente en aplicaciones informáticas sin fundamento geométrico o topológico relevante.
- No presentaban relación suficiente con el problema de investigación.
- Se encontraban fuera del período comprendido entre 2020 y 2026.
- Correspondían a documentos divulgativos sin suficiente respaldo académico.

Después de esta fase, los trabajos potencialmente pertinentes pasaron a revisión a texto completo.

Evaluación de elegibilidad

Los documentos seleccionados fueron revisados a texto completo para determinar su pertinencia en relación con el objetivo del estudio.

Las publicaciones empleadas únicamente como referencias contextuales en la introducción o discusión no se contabilizaron dentro del corpus final cuando no presentaban una relación directa con la geometría diferencial, la topología o el aprendizaje profundo geométrico. Este fue el caso de Schindler et al. (2026), utilizado para contextualizar la inteligencia artificial en educación matemática, pero no incluido en la muestra documental analizada.

Durante esta etapa se excluyeron los documentos cuyo contenido no se centraba suficientemente en Geometric Deep Learning, geometría diferencial, topología o redes neuronales geométricas; aquellos cuyos resultados no presentaban una relación clara con la pregunta de investigación; los estudios con información conceptual o metodológica insuficiente; y las publicaciones que no correspondían al período establecido.

Inclusión final

Después de aplicar los criterios establecidos, se seleccionaron 16 publicaciones académicas principales, publicadas entre 2020 y 2026, que presentaban relación directa con los fundamentos geométricos y topológicos del aprendizaje profundo, las redes neuronales geométricas, la inteligencia artificial, la educación matemática y el pensamiento computacional.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

Evaluación de la calidad metodológica

Debido a la heterogeneidad de las publicaciones incluidas —estudios teóricos, computacionales, revisiones sistemáticas, artículos metodológicos e investigaciones educativas— no se utilizó un instrumento estandarizado diseñado para un único tipo de estudio. En su lugar, se elaboró una rúbrica de valoración cualitativa aplicable de manera uniforme a los 16 documentos seleccionados.

La rúbrica consideró seis criterios: 1) claridad del objetivo del estudio; 2) coherencia conceptual y metodológica; 3) suficiencia de la información presentada; 4) correspondencia entre resultados y conclusiones; 5) relevancia científica; y 6) pertinencia respecto a la pregunta de investigación.

Cada criterio fue valorado mediante una escala de tres niveles: 0 = no cumple, 1 = cumple parcialmente y 2 = cumple adecuadamente. La puntuación máxima posible fue de 12 puntos. Para interpretar los resultados se establecieron tres niveles de calidad: alta (10–12 puntos), moderada (7–9 puntos) y baja (0–6 puntos). Los documentos clasificados con calidad baja debían ser reconsiderados para su inclusión en la síntesis final.

Este procedimiento permitió aplicar criterios comunes a fuentes metodológicamente heterogéneas y hacer más transparente y reproducible el proceso de valoración crítica**.**

Tabla 2.

Evaluación de la calidad metodológica de los estudios incluidos

Estudio	Objetivo	Coherencia	Información	Resultados-conclusiones	Relevancia	Pertinencia	Total /12
Hamilton (2020)	2	1	2	1	2	2	10
Wu et al. (2021)	2	2	2	2	2	2	12
Fuchs et al. (2020)	2	2	2	2	2	1	11
De Haan et al. (2020)	2	2	2	2	2	1	11
Gasteiger et al. (2020)	2	2	2	2	2	1	11
Bronstein et al. (2021)	2	2	2	2	2	1	11
Satorras et al. (2021)	2	2	2	2	2	1	11
Gasteiger et al. (2021)	2	2	2	2	2	1	11

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915

Vol. 4 Núm. 1 (2026)

Estudio	Objetivo	Coherencia	Información	Resultados-conclusiones	Relevancia	Pertinencia	Total /12
Tikva y Tambouris (2021)	2	2	2	2	2	2	12
Horn et al. (2022)	2	2	2	2	2	1	11
Bodnar et al. (2022)	2	2	2	1	2	1	10
Thölke y De Fabritiis (2022)	2	2	2	2	2	1	11
Nordby et al. (2022)	2	2	2	2	2	2	12
Panqueban y Huincahue (2024)	2	2	2	2	2	2	12
Opesemowo y Adewuyi (2024)	2	2	2	2	2	2	12
Zia et al. (2024)	2	2	2	2	2	2	12

Nota. La calidad metodológica de las 16 publicaciones académicas incluidas se evaluó mediante una rúbrica de seis criterios: claridad del objetivo, coherencia conceptual y metodológica, suficiencia de la información, correspondencia entre resultados y conclusiones, relevancia científica y pertinencia respecto a la pregunta de investigación. Cada criterio se calificó en una escala de 0 a 2 puntos, donde 0 = no cumple, 1 = cumple parcialmente y 2 = cumple adecuadamente. La puntuación máxima fue de 12 puntos. Se consideró calidad alta entre 10 y 12 puntos, moderada entre 7 y 9 puntos y baja entre 0 y 6 puntos.

La aplicación de la rúbrica mostró que las 16 publicaciones incluidas alcanzaron un nivel de calidad metodológica alta, con puntuaciones comprendidas entre 10 y 12 puntos. Los estudios con mayor puntuación presentaron objetivos claramente definidos, adecuada coherencia conceptual y metodológica, información suficiente, correspondencia entre resultados y conclusiones y una relación directa con la pregunta de investigación. Ninguna publicación obtuvo una puntuación correspondiente a calidad moderada o baja, por lo que no fue necesario excluir documentos adicionales durante esta fase de valoración**.**

f) Diagrama de flujo PRISMA 2020

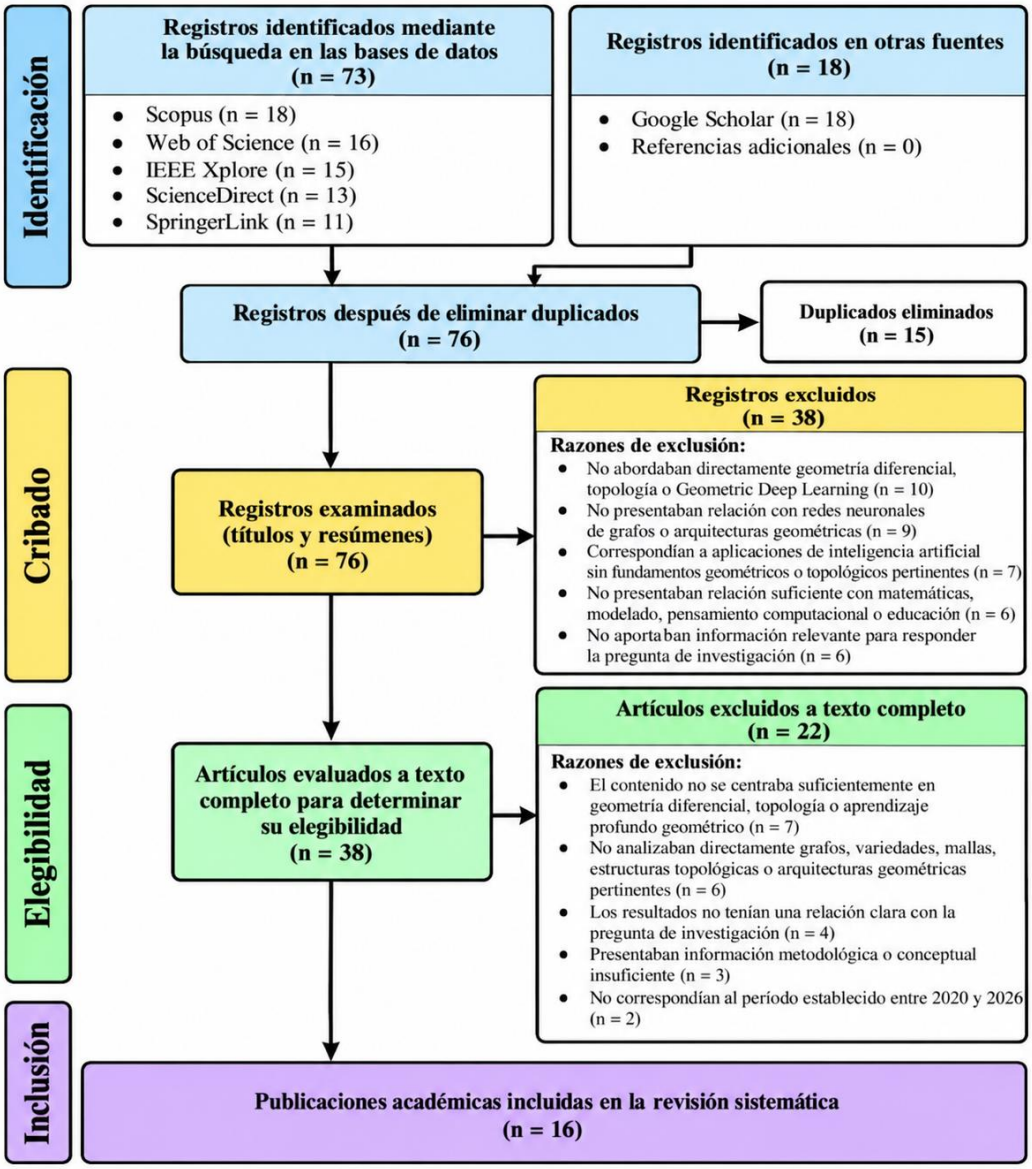
Figura 1.

Proceso de selección de estudios según PRISMA 2020

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915

Vol. 4 Núm. 1 (2026)



Nota. El diagrama representa las fases de identificación, cribado, elegibilidad e inclusión de los documentos científicos conforme a las recomendaciones de PRISMA 2020. El proceso permitió seleccionar 16 publicaciones académicas pertinentes para analizar la geometría diferencial y la topología aplicadas al aprendizaje profundo geométrico y su relación con el desarrollo del pensamiento matemático y computacional (Page et al., 2021).

Se identificaron 91 registros. Después de eliminar 15 duplicados, se cribaron 76 documentos. Durante el cribado se excluyeron 38 registros y 38 documentos fueron evaluados a texto completo. En la fase de elegibilidad se excluyeron 22 documentos y finalmente se incluyeron 16 publicaciones en la revisión sistemática.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

g) Criterios de inclusión y exclusión

Se establecieron los siguientes criterios:

- Publicaciones académicas publicadas entre 2020 y 2026.
- Artículos científicos revisados por pares, revisiones y publicaciones académicas pertinentes.
- Documentos escritos en español o inglés.
- Investigaciones relacionadas con Geometric Deep Learning.
- Estudios vinculados con geometría diferencial aplicada al aprendizaje profundo.
- Investigaciones relacionadas con topología y aprendizaje automático.
- Estudios sobre redes neuronales de grafos.
- Trabajos relacionados con variedades, mallas y estructuras no euclidianas.
- Investigaciones relacionadas con simetría, invariancia o equivariancia.
- Estudios sobre inteligencia artificial aplicada a las matemáticas.
- Investigaciones relacionadas con educación matemática.
- Estudios sobre pensamiento matemático y pensamiento computacional.
- Documentos con información metodológica o conceptual suficiente.
- Investigaciones cuyos resultados contribuyeran directamente a responder la pregunta de investigación.

Criterios de exclusión

Se excluyeron:

- Documentos duplicados.
- Publicaciones anteriores a 2020.
- Estudios no relacionados con geometría diferencial, topología o Geometric Deep Learning.
- Investigaciones exclusivamente técnicas sin una relación suficiente con los fundamentos matemáticos considerados.
- Estudios sin relación con inteligencia artificial, aprendizaje profundo o estructuras geométricas.
- Artículos de opinión o publicaciones sin sustento académico suficiente.
- Documentos con información metodológica o conceptual insuficiente.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

- Estudios cuyos resultados no permitieran establecer una relación con la pregunta de investigación.
- Publicaciones cuyo texto o información bibliográfica no permitieran verificar adecuadamente su contenido.

h) Fuentes y muestra documental

Las fuentes utilizadas fueron Scopus, Web of Science, IEEE Xplore, ScienceDirect, SpringerLink y Google Scholar.

Después de aplicar los procedimientos de identificación, cribado y elegibilidad, la muestra documental final estuvo constituida por 16 publicaciones académicas publicadas entre 2020 y 2026.

Tabla 3

Características de las publicaciones incluidas en la revisión sistemática

N.º	Autor(es) y año	Tema principal	Contexto	Diseño o tipo	Principal aporte
1	Hamilton (2020)	Aprendizaje de representaciones en grafos	Inteligencia artificial	Monografía académica	Sistematiza fundamentos y técnicas para representar información mediante grafos.
2	Wu et al. (2021)	Redes neuronales de grafos	Aprendizaje automático	Revisión científica	Examina modelos, fundamentos y aplicaciones de Graph Neural Networks.
3	Fuchs et al. (2020)	Equivarianza tridimensional	Datos y grafos 3D	Estudio computacional	Desarrolla el SE(3)-Transformer para conservar propiedades ante rotaciones y traslaciones.
4	De Haan et al. (2020)	Geometría sobre mallas	Superficies y mallas	Estudio computacional	Integra principios geométricos y equivariancia en redes convolucionales sobre mallas.
5	Gasteiger et al. (2020)	Geometría molecular	Grafos moleculares	Estudio computacional	Incorpora distancias y ángulos en mecanismos de paso de mensajes.
6	Bronstein et al. (2021)	Geometric Deep Learning	Matemáticas e IA	Trabajo teórico	Propone un marco conceptual que integra grafos, grupos,

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915

Vol. 4 Núm. 1 (2026)

N.º	Autor(es) y año	Tema principal	Contexto	Diseño o tipo	Principal aporte
					geodésicas, simetrías y estructuras geométricas.
7	Satorras et al. (2021)	Redes neuronales equivariantes	Grafos geométricos	Estudio computacional	Integra equivariancia E(n) respecto de rotaciones, traslaciones, reflexiones y permutaciones.
8	Gasteiger et al. (2021)	Redes geométricas direccionales	Modelado molecular	Estudio computacional	Desarrolla GemNet e incorpora información geométrica en redes neuronales.
9	Tikva y Tambouris (2021)	Pensamiento computacional	Educación	Revisión sistemática	Analiza la relación entre programación y desarrollo del pensamiento computacional.
10	Horn et al. (2022)	Redes neuronales topológicas	Grafos y topología	Estudio computacional	Integra información topológica en arquitecturas neuronales basadas en grafos.
11	Bodnar et al. (2022)	Topología y redes neuronales	Grafos	Estudio teórico-computacional	Aplica teoría de haces celulares a procesos de difusión en GNN.
12	Thölke y De Fabritiis (2022)	Transformers equivariantes	Modelado molecular	Estudio computacional	Desarrolla arquitecturas que respetan propiedades geométricas del espacio.
13	Nordby et al. (2022)	Pensamiento computacional y matemáticas	Educación matemática	Revisión sistemática	Analiza la incorporación del pensamiento computacional en la enseñanza de matemáticas.
14	Panqueban y Huincahue (2024)	Inteligencia artificial y matemáticas	Educación matemática	Revisión sistemática	Examina aplicaciones de IA en procesos de enseñanza y aprendizaje de las matemáticas.
15	Opesemowo y Adewuyi (2024)	IA en educación matemática	Educación	Revisión sistemática	Identifica tendencias y posibilidades de uso de la inteligencia artificial en educación matemática.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

N.º	Autor(es) y año	Tema principal	Contexto	Diseño o tipo	Principal aporte
16	Zia et al. (2024)	Topological Deep Learning	Inteligencia artificial	Revisión científica	Sistematiza fundamentos, modelos y aplicaciones del aprendizaje profundo topológico.

Nota. La tabla presenta las principales características de las 16 publicaciones incluidas en la revisión sistemática, considerando autoría, año de publicación, tema principal, contexto, diseño o tipo de estudio y aporte relevante. La selección se realizó de acuerdo con los criterios de inclusión y exclusión establecidos y con la pertinencia de cada documento respecto al análisis de la geometría diferencial, la topología, el aprendizaje profundo geométrico, la educación matemática y el pensamiento computacional.

i) Procedimiento de análisis de datos

El análisis comenzó con la definición de descriptores y categorías relacionadas directamente con la pregunta de investigación.

Los documentos fueron organizados en una matriz documental que incluyó:

- Autor.
- Año.
- País o contexto.
- Objetivo.
- Diseño metodológico.
- Área de aplicación.
- Tipo de información analizada.
- Estructura matemática empleada.
- Presencia de geometría diferencial.
- Presencia de conceptos topológicos.
- Uso de grafos.
- Uso de variedades o mallas.
- Presencia de simetrías.
- Uso de invariancia o equivariancia.
- Tipo de arquitectura neuronal.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

- Relación con inteligencia artificial.
- Relación con educación matemática.
- Relación con pensamiento matemático.
- Relación con pensamiento computacional.
- Principales resultados.
- Aporte a la pregunta de investigación.

La información obtenida de los 16 documentos fue posteriormente sintetizada en cinco categorías analíticas:

1. Geometría diferencial y representación de datos no euclidianos

Incluye variedades, superficies, espacios geométricos, métricas, distancias, geodésicas, mallas y representación de datos cuya estructura no corresponde a espacios euclidianos regulares.

2. Grafos y redes neuronales geométricas

Comprende nodos, aristas, Graph Neural Networks, mecanismos de paso de mensajes, aprendizaje de representaciones y procesamiento de información estructurada mediante grafos.

3. Topología y aprendizaje profundo topológico

Incluye conectividad, estructuras topológicas, homología persistente, complejos, características globales de los datos y modelos de aprendizaje profundo que incorporan información topológica.

4. Simetrías, invariancia y equivariancia

Comprende rotaciones, traslaciones, reflexiones, permutaciones, grupos de simetría y arquitecturas neuronales diseñadas para conservar propiedades geométricas relevantes.

5. Integración educativa y desarrollo del pensamiento matemático y computacional

Incluye enseñanza interdisciplinaria, inteligencia artificial aplicada a la educación matemática, modelización, resolución de problemas, pensamiento computacional y estrategias didácticas orientadas a relacionar conceptos geométricos con tecnologías de inteligencia artificial.

Estas categorías permitieron responder a la pregunta de investigación:

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

¿Qué aportes de la geometría diferencial y la topología sustentan el aprendizaje profundo geométrico y qué implicaciones educativas pueden derivarse para el desarrollo del pensamiento matemático y computacional?

3. RESULTADOS

El análisis de las 16 publicaciones académicas seleccionadas permitió identificar las principales tendencias relacionadas con la aplicación de la geometría diferencial y la topología en el aprendizaje profundo geométrico (Geometric Deep Learning), así como su vinculación potencial con el desarrollo del pensamiento matemático y computacional.

Los estudios se concentraron principalmente en cinco áreas: fundamentos del Geometric Deep Learning, redes neuronales de grafos, geometría y equivariancia, topología aplicada al aprendizaje profundo e integración de inteligencia artificial y pensamiento computacional en educación matemática. Los hallazgos permitieron identificar los principales aportes de la geometría diferencial y la topología al aprendizaje profundo geométrico, así como las implicaciones educativas que pueden derivarse de dichos fundamentos.

En términos generales, la evidencia revisada muestra que el aprendizaje profundo geométrico amplía los modelos tradicionales de aprendizaje profundo al permitir trabajar con datos cuya estructura no corresponde necesariamente a espacios regulares. Bronstein et al. (2021) plantean un marco unificado fundamentado en principios geométricos para comprender diferentes arquitecturas neuronales, incluyendo redes convolucionales, redes neuronales de grafos y otros modelos que aprovechan regularidades y simetrías presentes en los datos.

Asimismo, los trabajos revisados muestran que grafos, estructuras tridimensionales, variedades, mallas y propiedades topológicas permiten representar relaciones que no pueden describirse adecuadamente mediante estructuras euclidianas convencionales. En este contexto, las transformaciones geométricas, la equivariancia y las propiedades globales de los datos adquieren importancia para el diseño de arquitecturas capaces de conservar información estructural relevante.

Geometric Deep Learning y representación de datos no euclidianos

Los estudios revisados muestran que el Geometric Deep Learning permite incorporar la estructura geométrica del dominio de los datos dentro de los modelos de aprendizaje profundo. Esta perspectiva facilita el procesamiento de grafos, mallas, nubes de puntos y

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

otras estructuras no euclidianas, en las que las relaciones entre los elementos constituyen un componente esencial de la información.

Redes neuronales de grafos

Las redes neuronales de grafos constituyen una de las áreas con mayor presencia dentro del corpus analizado. Los resultados evidencian que estas arquitecturas permiten representar información mediante nodos y relaciones, ampliando las posibilidades del aprendizaje profundo hacia problemas caracterizados por estructuras relacionales y conectividad compleja.

Geometría, simetría y equivariancia

Las publicaciones incluidas evidencian que conceptos como simetría, invariancia y equivariancia pueden incorporarse directamente en el diseño de arquitecturas neuronales. Estas propiedades permiten conservar información relevante frente a transformaciones geométricas como rotaciones, traslaciones, reflexiones y permutaciones. Asimismo, la utilización de distancias, ángulos y relaciones direccionales permite representar de manera explícita la organización espacial de los datos.

Topología y aprendizaje profundo topológico

Los resultados muestran que la topología aporta información complementaria al análisis geométrico al considerar propiedades globales de los datos, como conectividad, componentes y ciclos. La incorporación de características topológicas en modelos de aprendizaje profundo permite analizar no solo propiedades locales, sino también la organización estructural general de conjuntos de datos complejos.

Inteligencia artificial y educación matemática

Los estudios relacionados con el ámbito educativo evidencian un creciente interés por la incorporación de la inteligencia artificial en la enseñanza y el aprendizaje de las matemáticas. Los hallazgos muestran posibilidades de vincular herramientas de inteligencia artificial con conceptos matemáticos que sustentan su funcionamiento, como grafos, transformaciones, relaciones espaciales y estructuras topológicas.

Pensamiento matemático y pensamiento computacional

La evidencia analizada muestra que el pensamiento computacional puede relacionarse con procesos propios de la actividad matemática, entre ellos la abstracción, descomposición, reconocimiento de patrones, secuenciación, representación de problemas y

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

elaboración de procedimientos. A partir de estas coincidencias conceptuales, se plantea como implicación educativa la posibilidad de diseñar experiencias interdisciplinarias que relacionen geometría, topología, computación e inteligencia artificial. Sin embargo, esta posibilidad debe entenderse como una proyección derivada de la revisión y no como una estrategia cuya eficacia haya sido comprobada directamente en estudiantes.

Síntesis de los principales hallazgos

Tabla 4

Síntesis temática de los resultados

Categoría	Evidencia identificada	Contribución potencial al aprendizaje
Geometric Deep Learning	Representación de información estructurada mediante principios geométricos	Relación entre conceptos matemáticos y modelos de inteligencia artificial
Redes neuronales de grafos	Uso de nodos, aristas y relaciones	Desarrollo del pensamiento relacional y representación de problemas
Geometría y equivariancia	Rotaciones, traslaciones, reflexiones, distancias y direcciones	Comprensión de transformaciones, simetrías y propiedades espaciales
Topología	Conectividad y propiedades globales de los datos	Análisis estructural y comprensión de relaciones complejas
Inteligencia artificial y educación matemática	Uso creciente de sistemas inteligentes en procesos educativos	Integración entre matemática, tecnología y resolución de problemas
Pensamiento computacional	Abstracción, descomposición, algoritmos y reconocimiento de patrones	Desarrollo de estrategias para representar y resolver problemas

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

Nota. La evidencia identificada corresponde a los principales hallazgos del corpus analizado. Las contribuciones educativas señaladas representan posibilidades e implicaciones derivadas de la revisión y no deben interpretarse como efectos empíricamente comprobados en estudiantes, debido a que la evidencia específica sobre la enseñanza de Geometric Deep Learning es todavía limitada.

De esta manera, los grafos, las relaciones espaciales, las simetrías y las características topológicas dejan de ser únicamente objetos matemáticos abstractos y pasan a formar parte del funcionamiento de determinados modelos de inteligencia artificial.

Asimismo, la geometría diferencial y la topología desempeñan funciones complementarias. La primera contribuye principalmente a comprender propiedades locales, transformaciones, distancias, superficies y relaciones espaciales, mientras que la segunda permite estudiar propiedades estructurales globales relacionadas con la conectividad y la forma de los datos. El aprendizaje profundo geométrico integra estos principios con algoritmos capaces de aprender representaciones a partir de información estructurada.

Desde la perspectiva educativa, los resultados muestran una oportunidad de relacionar estos conceptos con el pensamiento matemático y computacional. Sin embargo, la evidencia educativa localizada se concentra principalmente en inteligencia artificial en educación matemática y pensamiento computacional, y no en intervenciones escolares o universitarias específicamente diseñadas para enseñar Geometric Deep Learning. Esta diferencia constituye un aspecto relevante para la discusión, pues evidencia un espacio todavía poco explorado entre los avances técnicos del aprendizaje profundo geométrico y su traducción a estrategias didácticas.

4. DISCUSIÓN

Los hallazgos de esta revisión muestran una convergencia entre los estudios analizados respecto a la importancia de la geometría diferencial, la topología y las estructuras relacionales en el desarrollo del *Geometric Deep Learning*. En conjunto, la literatura revisada coincide en que la estructura matemática de los datos no constituye únicamente una forma de representación, sino un elemento que puede incorporarse directamente en el diseño de las arquitecturas de aprendizaje profundo.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

Bronstein et al. (2021), Hamilton (2020) y Wu et al. (2021) coinciden en destacar el valor de los grafos y de las relaciones estructurales como fundamento para representar información no euclidiana. Mientras Bronstein et al. (2021) proponen una visión unificada basada en principios geométricos, Hamilton (2020) y Wu et al. (2021) profundizan en el papel de las representaciones mediante grafos. Esta coincidencia permite interpretar que el aprendizaje profundo geométrico se sustenta en una transición desde modelos centrados exclusivamente en valores individuales hacia modelos que consideran explícitamente las relaciones entre los elementos.

Las investigaciones de Fuchs et al. (2020), Satorras et al. (2021) y Gasteiger et al. (2020, 2021) muestran perspectivas complementarias sobre el tratamiento de la información espacial. Fuchs et al. y Satorras et al. enfatizan la conservación de propiedades frente a transformaciones geométricas, mientras que Gasteiger et al. destacan la incorporación de distancias, ángulos y direcciones dentro de los modelos. Estas aproximaciones evidencian que la geometría no se limita a describir la forma de los datos, sino que puede condicionar directamente la manera en que una arquitectura neuronal procesa e interpreta información compleja.

De manera similar, los aportes de De Haan et al. (2020), Horn et al. (2022), Bodnar et al. (2022) y Zia et al. (2024) permiten establecer una distinción entre propiedades geométricas locales y propiedades topológicas globales. Mientras la geometría diferencial facilita el análisis de superficies, orientaciones, distancias y transformaciones, la topología aporta herramientas para estudiar conectividad, organización estructural y relaciones globales. Esta complementariedad amplía las posibilidades de representación de fenómenos complejos dentro del aprendizaje automático.

Desde el ámbito educativo, los estudios de Tikva y Tambouris (2021), Nordby et al. (2022), Panqueban y Huincahue (2024) y Opesemowo y Adewuyi (2024) permiten interpretar que la relación entre matemáticas, programación e inteligencia artificial puede contribuir al desarrollo del pensamiento computacional. Los procesos de abstracción, descomposición, reconocimiento de patrones, representación y resolución de problemas identificados en estos trabajos resultan compatibles con una enseñanza interdisciplinaria que vincule contenidos matemáticos con aplicaciones contemporáneas de inteligencia artificial.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

Sin embargo, la revisión evidencia una diferencia importante entre el desarrollo técnico del *Geometric Deep Learning* y su incorporación educativa. Mientras existe una producción científica amplia sobre redes neuronales geométricas, grafos, equivariancia y estructuras topológicas, la evidencia empírica sobre estrategias didácticas específicamente diseñadas para enseñar estos fundamentos continúa siendo limitada. Esta brecha constituye uno de los principales hallazgos de la revisión y sugiere la necesidad de avanzar hacia investigaciones educativas aplicadas.

En este sentido, la geometría diferencial, la topología, los grafos y las simetrías pueden considerarse puntos potenciales de conexión entre contenidos matemáticos avanzados y situaciones tecnológicas actuales. A partir de los hallazgos de la revisión, se infiere como posible línea de desarrollo didáctico el diseño de secuencias progresivas apoyadas en representaciones visuales, construcción de grafos, análisis de redes, transformaciones geométricas, simulaciones y actividades computacionales. Estas propuestas constituyen implicaciones educativas derivadas del análisis documental y requieren ser diseñadas, implementadas y evaluadas empíricamente antes de establecer conclusiones sobre su eficacia en estudiantes.

Desde esta perspectiva, los hallazgos permiten formular la hipótesis educativa de que estos contenidos podrían contribuir al desarrollo de procesos de abstracción, modelización, análisis estructural, reconocimiento de patrones y pensamiento computacional. No obstante, esta relación constituye una posibilidad teórica derivada de la literatura revisada y requiere validación mediante investigaciones educativas aplicadas.

En síntesis, la evidencia revisada permite interpretar que la geometría diferencial y la topología no solo constituyen fundamentos matemáticos del aprendizaje profundo geométrico, sino que también ofrecen posibilidades para contextualizar el aprendizaje matemático mediante problemas contemporáneos. No obstante, su aplicabilidad educativa todavía requiere mayor desarrollo teórico, diseño didáctico y validación empírica.

Limitación metodológica: Debido a la heterogeneidad de los diseños y tipos de publicaciones incluidas, no se aplicó una única herramienta estandarizada para evaluar su calidad metodológica. La valoración crítica se realizó mediante criterios cualitativos de pertinencia, coherencia y suficiencia de la información, lo que puede introducir un componente de juicio interpretativo en el proceso de evaluación.

Doi: https://doi.org/10.63688/5b571j80

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

5. CONCLUSIONES

La revisión permitió identificar que la geometría diferencial y la topología aportan fundamentos matemáticos esenciales para el aprendizaje profundo geométrico, particularmente en la representación de datos no euclidianos, grafos, mallas, simetrías, transformaciones y propiedades topológicas. A partir de estos aportes pueden derivarse implicaciones educativas relacionadas con la abstracción, la modelización, el reconocimiento de patrones y el pensamiento computacional; sin embargo, estas implicaciones requieren validación mediante investigaciones educativas aplicadas.

Los estudios revisados evidencian que las redes neuronales de grafos constituyen uno de los principales mecanismos para representar información relacional. Asimismo, conceptos como invariancia y equivariancia permiten diseñar modelos capaces de conservar propiedades relevantes frente a transformaciones como rotaciones, traslaciones, reflexiones y permutaciones. De esta manera, la geometría no funciona únicamente como un recurso descriptivo, sino como parte de la estructura matemática de los modelos.

Asimismo, el análisis muestra que geometría y topología desempeñan funciones complementarias. La geometría diferencial permite estudiar propiedades relacionadas con distancias, direcciones, superficies y transformaciones, mientras que la topología facilita el análisis de características globales asociadas con conectividad y organización estructural. La integración de ambas perspectivas amplía las posibilidades para representar y analizar datos complejos mediante aprendizaje profundo.

Desde la perspectiva educativa, la revisión permite identificar posibles conexiones entre los fundamentos matemáticos del Geometric Deep Learning y el desarrollo del pensamiento matemático y computacional. Los grafos, transformaciones, simetrías, relaciones espaciales y estructuras topológicas pueden considerarse recursos conceptuales potenciales para diseñar futuras propuestas didácticas. Sin embargo, estas posibilidades corresponden a implicaciones inferidas a partir del corpus revisado y no constituyen evidencia directa de eficacia educativa.

Sin embargo, la evidencia educativa directamente relacionada con la enseñanza del *Geometric Deep Learning* todavía es limitada. La mayor parte de los estudios identificados se concentra en el desarrollo técnico de modelos geométricos o en aplicaciones generales de inteligencia artificial y pensamiento computacional en educación. Esto evidencia la

Doi: https://doi.org/10.63688/5b571j80

necesidad de diseñar y evaluar propuestas didácticas que permitan traducir progresivamente estos fundamentos matemáticos a contextos educativos.

REFERENCIAS BIBLIOGRÁFICAS

Bodnar, C., Di Giovanni, F., Chamberlain, B. P., Liò, P., & Bronstein, M. M. (2022). Neural sheaf diffusion: A topological perspective on heterophily and oversmoothing in GNNs. *Advances in Neural Information Processing Systems, 35*, 18527–18541. https://openreview.net/forum?id=vbPsD-BhOZ

Bronstein, M. M., Bruna, J., Cohen, T., & Veličković, P. (2021). *Geometric deep learning: Grids, groups, graphs, geodesics, and gauges* [Preprint]. arXiv. https://doi.org/10.48550/arXiv.2104.13478

De Haan, P., Weiler, M., Cohen, T., & Welling, M. (2021). Gauge equivariant mesh CNNs: Anisotropic convolutions on geometric graphs. *International Conference on Learning Representations*. https://openreview.net/forum?id=Jnspzp-oIZE

Fuchs, F. B., Worrall, D. E., Fischer, V., & Welling, M. (2020). SE(3)-Transformers: 3D roto-translation equivariant attention networks. *Advances in Neural Information Processing Systems, 33*, 1970–1981. https://proceedings.neurips.cc/paper/2020/hash/15231a7ce4ba789d13b722cc5c955834-Abstract.html

Gasteiger, J., Groß, J., & Günnemann, S. (2020). Directional message passing for molecular graphs. *International Conference on Learning Representations*. https://openreview.net/forum?id=B1eWbxStPH

Gasteiger, J., Becker, F., & Günnemann, S. (2021). GemNet: Universal directional graph neural networks for molecules. *Advances in Neural Information Processing Systems, 34*, 6790–6802. https://proceedings.neurips.cc/paper/2021/hash/35cf8659cfcb13224cbd47863a34fc58-Abstract.html

Hamilton, W. L. (2020). *Graph representation learning*. Morgan & Claypool Publishers. https://doi.org/10.2200/S01045ED1V01Y202009AIM046

Horn, M., De Brouwer, E., Moor, M., Moreau, Y., Rieck, B., & Borgwardt, K. (2022). Topological graph neural networks. *International Conference on Learning Representations*. https://openreview.net/forum?id=oxxUMeFwEHd

Nordby, S. K., Bjerke, A. H., & Mifsud, L. (2022). Computational thinking in the primary mathematics classroom: A systematic review. *Digital Experiences in Mathematics Education, 8*, 27–49. https://doi.org/10.1007/s40751-022-00102-5

Opesemowo, O. A. G., & Adewuyi, H. O. (2024). A systematic review of artificial intelligence in mathematics education: The emergence of 4IR. *Eurasia Journal of Mathematics, Science and Technology Education, 20*(7), em2478. https://doi.org/10.29333/ejmste/14762

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., … Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ, 372*, n71. https://doi.org/10.1136/bmj.n71

Panqueban, D., & Huincahue, J. (2024). Artificial intelligence in mathematics education: A systematic review. *Uniciencia, 38*(1), 1–17. https://doi.org/10.15359/ru.38-1.20

Satorras, V. G., Hoogeboom, E., & Welling, M. (2021). E(n) equivariant graph neural networks. *Proceedings of the 38th International Conference on Machine Learning, 139*, 9323–9332. https://proceedings.mlr.press/v139/satorras21a.html

Sauer, P. C., & Seuring, S. (2023). How to conduct systematic literature reviews in management research: A guide in 6 steps and 14 decisions. *Review of Managerial Science, 17*, 1899–1933. https://doi.org/10.1007/s11846-023-00668-3

Schindler, M., Cevikbas, M., & Lilienthal, A. J. (2026). Artificial intelligence in mathematics education: A two-dimensional conceptual framework and meta-review. *ZDM – Mathematics Education, 58*, 831–850. https://doi.org/10.1007/s11858-026-01827-y

Thölke, P., & De Fabritiis, G. (2022). Equivariant transformers for neural network based molecular potentials. *International Conference on Learning Representations*. https://openreview.net/

Tikva, C., & Tambouris, E. (2021). Mapping computational thinking through programming in K–12 education: A conceptual model based on a systematic literature review. *Computers & Education, 162*, 104083. https://doi.org/10.1016/j.compedu.2020.104083

ISSN: 3091-1915
Vol. 4 Núm. 1 (2026)

Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., & Yu, P. S. (2021). A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems, 32*(1), 4–24. https://doi.org/10.1109/TNNLS.2020.2978386

Zia, A., Khamis, A., Nichols, J., Tayab, U. B., Hayder, Z., Rolland, V., Stone, E., & Petersson, L. (2024). Topological deep learning: A review of an emerging paradigm. *Artificial Intelligence Review, 57*, 77. https://doi.org/10.1007/s10462-024-10710-9

CONFLICTS OF INTEREST

None.

FUNDING

Not applicable.

AUTHOR CONTRIBUTIONS (CRediT)

Conceptualización: Jorge Javier Alvarez Sánchez, Bryan Francisco Ilbay Chavez, Silvana Mariela Cevallos Tituaña, Estefania Nicol Cevallos Tituaña, Isabel Leonor Rodríguez Lino.
Metodología: Jorge Javier Alvarez Sánchez, Bryan Francisco Ilbay Chavez, Silvana Mariela Cevallos Tituaña, Estefania Nicol Cevallos Tituaña, Isabel Leonor Rodríguez Lino.
Investigación: Jorge Javier Alvarez Sánchez, Bryan Francisco Ilbay Chavez, Silvana Mariela Cevallos Tituaña, Estefania Nicol Cevallos Tituaña, Isabel Leonor Rodríguez Lino.
Redacción – borrador original: Jorge Javier Alvarez Sánchez, Bryan Francisco Ilbay Chavez, Silvana Mariela Cevallos Tituaña, Estefania Nicol Cevallos Tituaña, Isabel Leonor Rodríguez Lino.
Redacción – revisión y edición: Jorge Javier Alvarez Sánchez, Bryan Francisco Ilbay Chavez, Silvana Mariela Cevallos Tituaña, Estefania Nicol Cevallos Tituaña, Isabel Leonor Rodríguez Lino.